



Uniwersytet Rzeszowski

DZIEDZINA NAUK INŻYNIERYJNO-TECHNICZNYCH

DYSCYPLINA INFORMATYKA TECHNICZNA I TELEKOMUNIKACJA

ROZPRAWA DOKTORSKA

Inteligentne harmonogramowanie zadań lotniczych dla floty UAV z wykorzystaniem technologii algebraczo-logicznego meta-modelowania w warunkach dynamicznych ograniczeń operacyjnych

Autor: Ewa Żesławska

Promotor rozprawy: dr hab. Michał Kruk, prof. SGGW
Promotor pomocniczy: dr Zbigniew Gomółka

Praca wykonana: Wydział Nauk Ścisłych i Technicznych

Rzeszów, 2026



University of Rzeszów

FIELD OF SCIENCE ENGINEERING AND TECHNOLOGY

SCIENTIFIC DISCIPLINE INFORMATION AND COMMUNICATION TECHNOLOGY

DOCTORAL THESIS

Intelligent Scheduling of UAV Mission Tasks Using
Algebraic-Logical Meta-Modeling under Dynamic Operational
Constraints

Author: Ewa Zeslawska

First supervisor: Michał Kruk, Ph.D., D.Sc., Professor of SGGW

Assisting supervisor: Zbigniew Gomółka, Ph.D.

Completed in: Faculty of Exact and Technical Sciences

Rzeszów, 2026

Pragnę złożyć serdeczne podziękowania Pani **prof. dr hab. inż. Ewie Dudek-Dyduch** za wieloletnią opiekę naukową nad realizacją niniejszej rozprawy doktorskiej. Jej wiedza, doświadczenie, życzliwość oraz inspirujące wskazówki badawcze miały fundamentalne znaczenie dla rozwoju przedstawionych w pracy koncepcji oraz kształtowania mojego warsztatu naukowego. Znacząca część rozprawy powstała pod Jej kierunkiem i dzięki nieocenionemu wsparciu merytorycznemu.

Szczególne wyrazy wdzięczności kieruję do Pana **dr hab. Michała Kruka, prof. SGGW** za podjęcie się opieki promotorskiej na końcowym etapie przygotowania rozprawy. Dziękuję za cenne uwagi, merytoryczne konsultacje oraz wsparcie w finalizacji pracy. Jego życzliwe zaangażowanie miało kluczowe znaczenie dla pomyślnego zwieńczenia moich wieloletnich badań.

Serdecznie dziękuję również Panu **dr Zbigniewowi Gomółce**, promotorowi pomocniczemu, za nieustanne wsparcie naukowe, gotowość do dzielenia się wiedzą, pomoc w analizach badawczych oraz liczne merytoryczne dyskusje. Jego zaangażowanie, cierpliwość i rzeczowe podejście stanowiły nieocenioną pomoc podczas realizacji rozprawy oraz źródło motywacji w pokonywaniu kolejnych wyzwań badawczych.

Pragnę także wyrazić wdzięczność **mojej rodzinie i przyjaciołom** za nieustające wsparcie, wyrozumiałość, cierpliwość oraz wiarę w moje możliwości. Ich obecność i życzliwość dodawały mi siły oraz determinacji w realizacji celów naukowych, przyczyniając się do ukończenia niniejszej rozprawy.

*Pracę tę dedykuję moim **Rodzicom**,
z najgłębszą wdzięcznością za ich bezwarunkową miłość, nieustające
wsparcie oraz cierpliwość, które towarzyszyły mi na każdym etapie mo-
jej drogi.*

*To dzięki ich mądrości, zrozumieniu i cichej obecności mogłam rozwi-
jać swoje pasje, realizować ambitne cele oraz z odwagą podejmować
kolejne wyzwania. Ich poświęcenie, troska i niezachwiana wiara w sens
podejmowanego przeze mnie wysiłku stanowiły źródło siły w chwilach
zwątpienia i motywację do dalszej pracy.*

*Niech niniejsza rozprawa będzie wyrazem mojego szacunku, wdzięcz-
ności oraz podziękowania za wszystko, co od Nich otrzymałam.*

Streszczenie

Rozprawa poświęcona jest problemowi inteligentnego harmonogramowania zadań logistycznych realizowanych przez flotę bezzałogowych statków powietrznych (UAV) w warunkach dynamicznie zmieniającej się dostępności przestrzeni powietrznej, występowania ograniczeń czasowo-przestrzennych oraz zakłóceń operacyjnych wpływających na dostępność zasobów i wykonalność zadań. Problem ten należy do klasy złożonych problemów decyzyjnych o charakterze dynamicznym i wieloograniczeniowym, dla których istniejące podejścia optymalizacyjne oraz heurystyczne wykazują ograniczoną zdolność adaptacji w środowisku wymagającym podejmowania decyzji w czasie zbliżonym do rzeczywistego.

Celem rozprawy było opracowanie formalizmu modelowania oraz metod adaptacyjnego sterowania procesem harmonogramowania zadań UAV, umożliwiających generowanie oraz dynamiczną rekonfigurację harmonogramów operacyjnych z uwzględnieniem zmiennych ograniczeń środowiskowych i zasobowych. W pracy zaproponowano autorski formalizm oparty na technologii Algebraiczno-Logicznego Meta-Modelowania (ALMM), pozwalający na formalny opis procesu decyzyjnego jako dyskretnego, wieloetapowego procesu sterowania z ograniczeniami.

Istotnym wkładem naukowym rozprawy jest opracowanie kaskadowego formalizmu algebraiczno-logicznego umożliwiającego modelowanie oraz dynamiczną rekonfigurację procesu harmonogramowania flot UAV w warunkach zmiennej dostępności zasobów i przestrzeni powietrznej. Zaproponowana struktura obejmuje model bazowy procesu harmonogramowania oraz jego rozszerzenia uwzględniające mechanizmy alokacji slotów czasowych, współdzielenia korytarzy powietrznych, ograniczenia wynikające z okien czasowych dostępności przestrzeni operacyjnej oraz dynamiczną rekonfigurację harmonogramu w odpowiedzi na zakłócenia występujące podczas realizacji misji. Opracowana architektura modelowa zapewnia spójność formalną całego procesu decyzyjnego przy jednoczesnym zachowaniu modularności i skalowalności rozwiązania.

Na bazie opracowanego formalizmu zaprojektowano zestaw algorytmów konstrukcji harmonogramów, generowania trajektorii stanów procesu oraz mechanizmów lokalnej reoptymalizacji umożliwiających adaptacyjną rekonfigurację przyszłego segmentu harmonogramu bez konieczności pełnego przeliczania planu globalnego. Podejście to pozwala na znaczące ograniczenie kosztu obliczeniowego rekonfiguracji oraz umożliwia wykorzystanie opracowanego rozwiązania w zastosowaniach on-line.

Walidację opracowanego podejścia przeprowadzono w środowisku symulacyjnym oraz w warunkach zbliżonych do rzeczywistych, wykorzystując scenariusze testowe inspirowane rzeczywistą dostępnością przestrzeni powietrznej i typowymi zakłóceniami eksploatacyjnymi. Badania eksperymentalne objęły analizę scenariuszy ograniczonej dostępności korytarzy powietrznych, awarii jednostek UAV, anulowania zadań

oraz dynamicznego pojawiania się nowych zleceń logistycznych. Uzyskane wyniki potwierdziły zdolność opracowanego podejścia do zachowania poprawności formalnej procesu harmonogramowania, skutecznej adaptacji do zmian środowiska operacyjnego oraz utrzymania wysokiej efektywności realizacji zadań.

Przeprowadzona analiza porównawcza względem reprezentatywnych metod raportowanych w literaturze wykazała, że opracowane podejście osiąga efektywność harmonogramowania porównywalną z klasycznymi metodami optymalizacyjnymi, metaheurystycznymi i hybrydowymi, przy jednoczesnym zachowaniu istotnie krótszego czasu reakcji na zakłócenia oraz pełnej interpretowalności procesu decyzyjnego.

Uzyskane rezultaty potwierdzają postawioną w rozprawie tezę, że technologia Algebraiczno-Logicznego Meta-Modelowania stanowi skuteczną podstawę formalnego modelowania oraz adaptacyjnego harmonogramowania zadań operacyjnych flot UAV funkcjonujących w warunkach zmiennej dostępności przestrzeni powietrznej i zasobów operacyjnych. Opracowane rozwiązanie wnosi oryginalny wkład do obszaru inteligentnych systemów decyzyjnych dla autonomicznych systemów transportowych oraz rozszerza zakres zastosowań technologii ALMM o klasę problemów dynamicznego harmonogramowania i rekonfiguracji procesów decyzyjnych. Uzyskane wyniki mogą stanowić podstawę dalszych badań nad integracją opracowanego formalizmu z systemami UTM/ATM, mechanizmami predykcji zakłóceń oraz architekturami wieloagentowymi.

Abstract

This dissertation addresses the problem of intelligent scheduling of logistics tasks performed by a fleet of Unmanned Aerial Vehicles (UAVs) operating under conditions of dynamically changing airspace availability, temporal and spatial constraints, and operational disruptions affecting resource availability and task feasibility. The considered problem belongs to the class of complex dynamic and multi-constrained decision-making problems, for which existing optimization and heuristic approaches exhibit limited adaptability in environments requiring near real-time decision making.

The main objective of the dissertation was to develop a formal modelling framework and adaptive control methods for UAV task scheduling processes, enabling both the generation and dynamic reconfiguration of operational schedules under changing environmental and resource constraints. To achieve this objective, an original formalism based on Algebraic-Logical Meta-Modeling (ALMM) was proposed. The formalism enables the representation of the scheduling process as a discrete multi-stage decision-making process with explicitly defined states, decisions, transition functions, and admissibility constraints.

A significant scientific contribution of the dissertation is the development of a cascade of algebraic-logical models enabling the modelling and dynamic reconfiguration of UAV fleet scheduling processes under conditions of varying resource and airspace availability. The proposed structure comprises a base scheduling model and its successive extensions incorporating time-slot allocation mechanisms, shared air corridor management, time-window constraints, and dynamic schedule reconfiguration in response to operational disruptions occurring during mission execution. The resulting modelling architecture ensures formal consistency of the decision-making process while preserving modularity and scalability.

Based on the developed formalism, a set of algorithms was designed for schedule generation, state trajectory construction, and local re-optimization. The proposed mechanisms enable adaptive reconfiguration of the future segment of a schedule without the need to recompute the entire global plan. This approach significantly reduces the computational cost of reconfiguration and enables the application of the developed solution in online decision-support systems.

The proposed approach was validated both in a simulation environment and under conditions closely resembling real-world operations. Experimental studies included scenarios involving limited availability of air corridors, UAV failures, task cancellations, and the dynamic arrival of new logistics requests. The obtained results confirmed the ability of the proposed approach to preserve the formal correctness of the scheduling process, adapt effectively to changing operational conditions, and maintain a high level of task execution efficiency.

A comparative analysis against representative methods reported in the literature demonstrated that the proposed approach achieves scheduling performance comparable to classical optimization, metaheuristic, and hybrid methods while providing significantly shorter response times to operational disruptions and full interpretability of the decision-making process.

The obtained results confirm the dissertation thesis that Algebraic-Logical Meta-Modeling constitutes an effective formal foundation for modelling and adaptive scheduling of UAV fleet operations under conditions of dynamically changing airspace and resource availability. The developed solution provides an original contribution to the field of intelligent decision-support systems for autonomous transportation systems and extends the application domain of ALMM technology to dynamic scheduling and decision-process reconfiguration problems. The presented results may serve as a foundation for future research concerning the integration of the proposed formalism with UTM/ATM systems, disruption prediction mechanisms, and multi-agent system architectures.

Spis treści

Spis ważniejszych oznaczeń	x
1 Wstęp	1
1.1 Wprowadzenie	1
1.2 Cel i teza pracy	9
1.3 Struktura pracy	11
2 Inteligentna technologia algebraiczno-logiczna meta-modelowania ALMM	13
2.1 Terminologia algebraiczno logicznego meta - modelu	13
2.2 Struktura stanu i decyzji w modelu ALMM	15
2.3 Koncepcja i struktura Inteligentnego ALMM Systemu	16
2.4 Przegląd wykorzystania technologii ALMM	23
3 Problem harmonogramowania zadań flot UAV w obszarze okołolotniskowym	25
3.1 Charakterystyka problemu harmonogramowania	25
3.2 Charakterystyka zasobów UAV	27
3.3 Charakterystyka destynacji lotniczych	28
3.4 Charakterystyka trajektorii realizacji zadań	31
3.5 Charakterystyka slotów	32
3.6 Charakterystyka danych dotyczących zadań lotniczych	38
3.7 Charakterystyka zakłóceń	41
4 Modele ALMM dla harmonogramowania zadań operacyjnych dla floty UAV	44
4.1 Model bazowy ALMM harmonogramowania zadań dla floty UAV	45
4.2 Model ALMM-TS uwzględniający ograniczenia dostępności czasowej UAV	49
4.3 Model ALMM-CS uwzględniający dostępność korytarzy powietrznych	54
4.4 Model ALMM-TW uwzględniający okna czasowe zadań	57
4.5 Model ALMM-D uwzględniający zakłócenia procesu harmonogramowania	59
4.6 Zadanie optymalizacji w modelach ALMM	67
5 Metodologia i algorytmy rozwiązywania problemu harmonogramowania zadań dla floty UAV	71
5.1 Własności problemu i wynikające z nich założenia algorytmiczne	72
5.2 Heurystyka redukcji przestrzeni decyzji	73

5.3	Algorytm planowania zadań UAV z ograniczeniami korytarzy powietrznych	75
5.4	Algorytm przydziału zadań do slotów czasowych UAV	77
5.5	Algorytm generowania trajektorii lotu UAV	79
5.6	Architektura zintegrowanego systemu harmonogramowania zadań floty UAV	80
5.7	Algorytmy dynamicznego harmonogramowania z predykcją zakłóceń i realokacją	82
6	Wyniki badań eksperymentalnych	91
6.1	Środowisko i zakres walidacji eksperymentalnej	91
6.2	Wyniki bazowych eksperymentów symulacyjnych harmonogramowania zadań UAV	95
6.3	Wyniki eksperymentów symulacyjnych z uwzględnieniem ograniczeń czasowych korytarzy	106
6.4	Walidacja modelu ALMM-D w warunkach dynamicznych zakłóceń zasobowych i zadaniowych	117
6.5	Walidacja eksperymentalna opracowanego systemu w warunkach zbliżonych do rzeczywistych	136
6.6	Analiza porównawcza otrzymanych rezultatów z innymi podejściami	143
7	Podsumowanie	147
	Spis rysunków	151
	Spis tabel	154
	Spis algorytmów	156
	Bibliografia	157

Spis ważniejszych oznaczeń

Oznaczenia ogólne technologii ALMM

- P – dyskretny, wieloetapowy proces decyzyjny
- U – zbiór decyzji sterujących
- S – zbiór stanów uogólnionych procesu
- s – stan uogólniony procesu
- s_0 – stan początkowy procesu
- x – stan właściwy procesu
- x_0 – początkowy stan właściwy procesu
- t – czas procesu
- t_0 – chwila początkowa procesu
- f – funkcja przejścia procesu
- S_N – zbiór stanów niedopuszczalnych
- S_G – zbiór stanów docelowych
- Q – kryterium optymalizacji
- $\Pi = (P, Q)$ – problem optymalizacji opisany przez proces P oraz kryterium Q
- $\tilde{s}$ – trajektoria stanów procesu
- $\tilde{u}$ – sekwencja decyzji wyznaczająca trajektorię procesu
- U_d – zbiór decyzji dopuszczalnych
- ALMM – Algebraiczno-Logiczny Meta-Model

Oznaczenia modeli harmonogramowania UAV

- $J = \{1, \dots, n\}$ – zbiór zadań
- $K = \{1, \dots, m\}$ – zbiór bezzałogowych statków powietrznych UAV
- $J^* = J \cup \{0\}$ – rozszerzony zbiór zadań z zadaniem pustym
- $p(j, k)$ – czas realizacji zadania j przez UAV k
- $x^0 \subseteq J$ – pierwsza współrzędna stanu właściwego reprezentująca zbiór zadań ukończonych
- $x^k = (\beta^k, \tau^k)$ – stan k -tego UAV
- β^k – zadanie aktualnie realizowane przez UAV k
- τ^k – pozostały czas realizacji zadania przez UAV k
- S_F – zbiór stanów dopuszczalnych niebędących stanami docelowymi
- $J_M(s)$ – zbiór zadań aktualnie realizowanych w stanie s
- Δt_i – przyrost czasu do najbliższego zdarzenia procesu
- J_{cmp} – zbiór zadań zakończonych w bieżącym przejściu

Oznaczenia ograniczeń czasowych i przestrzennych

- $[B^r, F^r]$ – r -ty slot dostępności czasowej UAV
- B^r – początek r -tego slotu dostępności
- F^r – koniec r -tego slotu dostępności
- ILs – liczba slotów dostępności czasowej
- u^* – decyzja specjalna oznaczająca przejście do kolejnego slotu dostępności
- $C = \{1, \dots, q\}$ – zbiór korytarzy powietrznych
- $\gamma(j)$ – korytarz powietrzny wymagany do realizacji zadania j
- A_c – zbiór przedziałów dostępności korytarza c
- $[B_c^r, F_c^r]$ – r -ty przedział dostępności korytarza c
- E_c – efektywna dostępność czasowa korytarza c
- $r(j)$ – najwcześniejszy dopuszczalny moment rozpoczęcia zadania j
- $d(j)$ – najpóźniejszy dopuszczalny moment zakończenia zadania j
- $W_j = [r(j), d(j)]$ – okno czasowe realizacji zadania j

Oznaczenia modeli rozszerzonych ALMM

- $U_d^{TS}(s)$ – zbiór decyzji dopuszczalnych w modelu ALMM-TS
- $U_d^{CS}(s)$ – zbiór decyzji dopuszczalnych w modelu ALMM-CS
- $U_d^{TW}(s)$ – zbiór decyzji dopuszczalnych w modelu ALMM-TW
- $U_d^D(s_i, \delta_i)$ – zbiór decyzji dopuszczalnych w modelu ALMM-D
- S_N^{TS} – zbiór stanów niedopuszczalnych w modelu ALMM-TS
- S_N^{CS} – zbiór stanów niedopuszczalnych w modelu ALMM-CS
- S_N^{TW} – zbiór stanów niedopuszczalnych w modelu ALMM-TW
- S_N^D – zbiór stanów niedopuszczalnych w modelu ALMM-D
- $\mathcal{D}$ – zbiór możliwych zakłóceń procesu
- δ_i – zakłócenie ujawnione w i -tym kroku procesu
- $p_\delta(j, k, i)$ – czas realizacji zadania j przez UAV k po uwzględnieniu zakłócenia δ_i
- $K_{av}(s_i, \delta_i)$ – zbiór UAV dostępnych operacyjnie po uwzględnieniu zakłócenia δ_i
- $E_c^D(i)$ – efektywna dostępność korytarza c po uwzględnieniu zakłóceń w kroku i
- $U^{ra}(s_i, \delta_i)$ – zbiór decyzji realokacyjnych
- S_G^D – zbiór stanów docelowych w modelu ALMM-D

Skróty operacyjne i techniczne

- AGL – wysokość nad poziomem terenu, ang. *Above Ground Level*
- BVLOS – operacje poza zasięgiem widoczności wzrokowej, ang. *Beyond Visual Line of Sight*
- CTR – strefa kontrolowana lotniska, ang. *Control Zone*
- HIL – środowisko testowe typu *Hardware-in-the-Loop*
- SIL – środowisko testowe typu *Software-in-the-Loop*
- UAV – bezzałogowy statek powietrzny, ang. *Unmanned Aerial Vehicle*
- UTM – system zarządzania ruchem bezzałogowym, ang. *Unmanned Traffic Management*
- ATM – system zarządzania ruchem lotniczym, ang. *Air Traffic Management*
- VLOS – operacje w zasięgu widoczności wzrokowej, ang. *Visual Line of Sight*

Rozdział 1

Wstęp

1.1 Wprowadzenie

Rozwój koncepcji Free Route Airspace (FRA), rozwijanej w ramach inicjatyw Europejskiej Organizacji Bezpieczeństwa Żeglugi Powietrznej (EUROCONTROL), wskazuje na potrzebę poszukiwania nowych metod planowania i zarządzania ruchem lotniczym. Celem tych działań jest zwiększenie efektywności wykorzystania przestrzeni powietrznej przy jednoczesnym zachowaniu wymaganego poziomu bezpieczeństwa. W obecnych systemach przygotowanie planu lotu oraz jego synchronizacja z innymi użytkownikami przestrzeni powietrznej pozostają zadaniami złożonymi, szczególnie w warunkach dynamicznych zmian tras, ograniczeń czasowych oraz pojawiających się zakłóceń [4, 64, 66].

Równolegle obserwuje się intensywny rozwój zastosowań bezzałogowych statków powietrznych (ang. Unmanned Aerial Vehicle, UAV). Początkowo wykorzystywane głównie w zastosowaniach wojskowych, obecnie UAV znajdują zastosowanie m.in. w geodezji, rolnictwie, monitoringu infrastruktury, ratownictwie, logistyce oraz transporcie. Szczególnie istotny jest rozwój zastosowań transportowych, obejmujących dostawy ostatniej mili, dostawy do obszarów trudno dostępnych, transport medyczny, wsparcie działań kryzysowych oraz monitorowanie infrastruktury transportowej.

Rozwój zastosowań UAV w obszarze transportu i logistyki prowadzi do powstawania nowych modeli operacyjnych, w których kluczową rolę odgrywa efektywne planowanie i koordynacja działań. Do najważniejszych kierunków zastosowań należą:

- dostawy ostatniej mili, umożliwiające skrócenie czasu realizacji zamówień oraz redukcję kosztów transportu,
- realizacja dostaw do obszarów trudno dostępnych, gdzie infrastruktura naziemna jest ograniczona,
- transport medyczny (np. leki, próbki, materiały biologiczne), wymagający wysokiej niezawodności i krótkich czasów realizacji,
- wsparcie działań kryzysowych poprzez szybkie dostarczanie zasobów w warunkach zakłóceń infrastruktury,
- monitorowanie i inspekcja infrastruktury transportowej,

- optymalizacja tras przelotu z uwzględnieniem kryteriów czasowych i energetycznych,
- rozwój modeli współdzielenia zasobów (np. *drone-as-a-service*),
- integracja operacji UAV z koncepcją miejskiej mobilności lotniczej (UAM), w tym wykorzystanie dedykowanych korytarzy powietrznych.

Zastosowania te wskazują, że systemy UAV funkcjonują w środowisku o wysokiej dynamice, w którym konieczne jest jednocześnie uwzględnienie wielu ograniczeń operacyjnych, w tym czasowych, przestrzennych oraz zasobowych, co bezpośrednio prowadzi do złożonych problemów optymalizacyjnych i decyzyjnych.

Wykorzystanie floty UAV w zadaniach logistycznych wymaga jednak rozwiązania złożonego problemu planowania i harmonogramowania. Należy uwzględnić nie tylko przydział zadań do poszczególnych statków UAV, lecz także ograniczenia wynikające z dostępności zasobów, dostępności przestrzeni powietrznej, okien czasowych realizacji zadań oraz możliwości występowania zakłóceń operacyjnych. W warunkach okołolotniskowych problem ten staje się szczególnie istotny, ponieważ planowane trajektorie UAV muszą być synchronizowane z ograniczeniami wynikającymi z organizacji ruchu lotniczego.

Z tego względu potrzebne są metody umożliwiające formalny opis procesu decyzyjnego oraz jego adaptację do zmieniających się warunków operacyjnych. W niniejszej pracy przyjęto podejście oparte na technologii algebraiczno-logicznego meta-modelowania (ALMM), które pozwala opisać proces harmonogramowania jako wieloetapowy proces decyzyjny z jawnie określoną przestrzenią stanów, zbiorem decyzji, funkcją przejścia oraz zbiorami stanów dopuszczalnych, niedopuszczalnych i docelowych. Takie ujęcie stanowi podstawę do budowy formalnych modeli oraz algorytmów inteligentnego harmonogramowania, umożliwiających adaptacyjne podejmowanie decyzji w warunkach dynamicznie zmieniających się zasobów i ograniczeń operacyjnych.

Przegląd literatury

Harmonogramowanie zadań oraz zarządzanie przestrzenią powietrzną dla UAV stanowi obecnie jedno z kluczowych zagadnień w dziedzinie inteligentnych systemów transportowych oraz robotyki autonomicznej. Klasyczne problemy optymalizacyjne, takie jak elastyczny problem szeregowania zadań (JSSP), problem harmonogramowania przepływowego (flow-shop scheduling) czy problem trasowania pojazdów (VRP), zostały zaadaptowane i rozszerzone na potrzeby platform powietrznych, uwzględniając specyficzne ograniczenia związane z charakterystyką lotu, takie jak zasięg, trajektoria, ograniczenia energetyczne czy zgodność z regulacjami przestrzeni powietrznej [33, 39, 51, 53, 62, 73, 90].

Współczesne badania nad harmonogramowaniem misji UAV integrują podejścia wypracowane w innych obszarach, m.in. w logistyce, działaniach ratunkowych, inspekcji infrastruktury oraz systemach obliczeń brzegowych (edge computing). W ostatnich latach zaproponowano szereg zaawansowanych metod optymalizacyjnych, których skuteczność potwierdzono w scenariuszach o wysokiej złożoności przestrzenno-czasowej, przy jednoczesnym uwzględnieniu ograniczeń zasobowych, zależności czasowych pomiędzy zadaniami, synchronizacji wielu jednostek mobilnych oraz konieczności dynamicznej rekonfiguracji planu misji [34, 38, 45, 74, 77, 78, 83, 97].

W celu identyfikacji aktualnych trendów badawczych przeanalizowano wybrane publikacje dotyczące harmonogramowania misji UAV, ze szczególnym uwzględnieniem problemów zintegrowanych z transportem naziemnym. Analiza wskazuje na dużą różnorodność modeli systemowych, sposobów reprezentacji niepewności oraz metod obliczeniowych stosowanych do rozwiązywania problemów klasy PDSTSP (Problem Dostaw wspieranych przez Drony z Czasami Zwolnienia).

Przykładowo, w pracy [86] zaprezentowano rozwiązanie problemu harmonogramowania dronów dostarczających ładunki do statków będących w ruchu (DSP-SSD). Problem sformułowano jako model programowania całkowitoliczbowego (MIP) oparty na siatce czasowej, a jego rozwiązanie uzyskano za pomocą algorytmu typu Branch-and-Price-and-Cut, co umożliwia precyzyjne odwzorowanie ograniczeń czasowych i pojemnościowych w dynamicznych warunkach operacyjnych.

W pracy [93] rozważono problem dynamicznej współpracy ciężarówek i dronów, w którym dopuszcza się start i lądowanie UAV na różnych pojazdach naziemnych. Zaproponowano dekompozycję problemu na podproblemy alokacji, trasowania oraz harmonogramowania, rozwiązane z wykorzystaniem matheurystyki opartej na generowaniu kolumn oraz schematach pakowania.

Z kolei w [5] przedstawiono podejście do harmonogramowania misji UAV w kontekście systemów obliczeń rozproszonych, uwzględniające wielolokalizacyjny charakter zadań oraz ograniczenia zasobowe. Zastosowanie modeli predykcyjnych oraz strategii harmonogramowania współbieżnego pozwoliło na poprawę efektywności wykorzystania zasobów oraz skalowalności rozwiązania.

Planowanie zadań oraz trajektorii UAV stanowi istotny obszar badań, szczególnie w kontekście logistyki, dostaw oraz mobilnych systemów przetwarzania brzegowego (MEC). Problematyka ta obejmuje szereg wyzwań wynikających z ograniczeń operacyjnych UAV, takich jak ograniczony czas lotu, ograniczona ładowność, zużycie energii zmienność warunków przestrzeni powietrznej [11, 14, 15, 28, 32, 50, 61, 67, 70–72, 79]. Jednym z kluczowych zagadnień w tym obszarze jest Drone Scheduling Problem (DSP), stanowiący rozszerzenie klasycznego problemu trasowania pojazdów (VRP) o ograniczenia charakterystyczne dla platform powietrznych.

W literaturze rozważane są liczne warianty tego problemu, m.in. Vehicle Routing Problem with Drones (VRPD), Flying Salesman Problem with UAV Assistant (FSTSP) oraz Traveling Salesman Problem with Drones (TSPD). Modele te koncentrują się najczęściej na optymalizacji tras, alokacji zadań oraz minimalizacji kosztów realizacji misji przy uwzględnieniu ograniczeń takich jak czas lotu, pojemność energetyczna, ładowność oraz możliwość współpracy UAV z pojazdami naziemnymi [2, 3, 7, 16, 39, 48, 65, 84].

Istotnym kierunkiem badań jest również optymalizacja efektywności energetycznej, szczególnie w systemach MEC, w których UAV pełnią funkcję mobilnych węzłów obliczeniowych lub komunikacyjnych. W tym ujęciu planowanie trajektorii musi uwzględniać zarówno koszt przemieszczenia, jak i koszt przetwarzania lub transmisji danych, co prowadzi do problemów wielokryterialnych obejmujących czas, energię oraz dostępność zasobów obliczeniowych [1, 52, 88].

Szczególną grupę prac stanowią podejścia łączące harmonogramowanie zadań, planowanie trajektorii oraz rozmieszczenie zasobów UAV. W pracach tych problem decyzyjny obejmuje jednocześnie wybór zadań, przydział jednostek UAV, wyznaczanie tras oraz optymalizację parametrów komunikacyjnych lub obliczeniowych, co prowadzi do modeli o wysokiej złożoności obliczeniowej. Tego typu podejścia są szcze-

gólnie istotne w systemach wielozadaniowych i wieloresursowych, gdzie harmonogramowanie i trasowanie nie mogą być rozpatrywane niezależnie [6, 12, 27, 36, 49, 59, 75, 82, 85, 96]

Zdecydowana większość analizowanych prac dotyczy systemów złożonych z pojazdów naziemnych oraz jednej lub wielu jednostek UAV. W pracach [54, 56, 57] analizowane są scenariusze z wieloma ciężarówkami i dronami, natomiast w [44, 87] rozważane są konfiguracje bardziej ograniczone. W części badań uwzględnia się również drony wspierające, co pozwala modelować bardziej złożone strategie współdziałania zasobów powietrznych [7, 16, 62, 65, 69].

Istotnym aspektem modelowania jest również uwzględnienie niepewności, która najczęściej dotyczy czasu przelotu UAV [8, 40, 92], czasu przejazdu pojazdu naziemnego lub zapotrzebowania klientów [89, 94]. W niektórych pracach analizowane są także specyficzne scenariusze, np. dostawy krytyczne [76], zmienność prędkości i strefy zakazu lotów [68], niepewność czasów podróży [35] oraz odporność harmonogramów na zakłócenia operacyjne i dynamiczne zmiany środowiska misji [37, 46, 75, 77, 80]. Ważnym elementem modelowania jest wybór punktu spotkania UAV z pojazdem naziemnym, który może być lokalizacją klienta, punktem zewnętrznym lub rozwiązaniem hybrydowym [7, 13, 87, 95].

W zakresie metod obliczeniowych dominują podejścia heurystyczne i metaheurystyczne, stosowane przede wszystkim do dużych instancji problemów [34, 44, 54, 58]. Równolegle rozwijane są metody dokładne i hybrydowe, w tym programowanie całkowitoliczbowe mieszane, programowanie z ograniczeniami, generowanie kolumn, dekompozycja Bendersa oraz algorytmy z rodziny branch-and-price i branch-and-check [8, 12, 27, 47, 55, 56, 63, 87, 97, 98]. Metody te umożliwiają uzyskanie rozwiązań wysokiej jakości, jednak ich zastosowanie w środowiskach dynamicznych wymaga dodatkowych mechanizmów adaptacji i reoptymalizacji.

W Tabeli 1.1 przedstawiono zestawienie wybranych prac dotyczących problemu PDSTSP (Problem Dostaw wspieranych przez Drony z Czasami Zwolnienia), w ujęciu zgrupowanym. Zaprezentowana struktura tabelaryczna pozwala na syntetyczne porównanie kluczowych elementów poszczególnych badań. Kolumna Konfiguracja (T/UAV_s/UAV_p) obejmuje liczbę wykorzystywanych pojazdów: ciężarówek (T), dronów serwisowych (UAV_s) oraz dronów wspierających (UAV_p), przy czym oznaczenie „M” wskazuje na modelowanie wielu jednostek, a „-” na brak informacji lub brak zastosowania danego komponentu. W kolumnie Niepewności i założenia uwzględniono czasy zwolnienia (RT), rozpatrywane źródła niepewności (m.in. czas lotu UAV, czas przejazdu ciężarówki, zapotrzebowanie, warunki środowiskowe) oraz typ punktu spotkania (klient, lokalizacja zewnętrzna). Ostatnia kolumna Metoda rozwiązania obejmuje szerokie spektrum podejść obliczeniowych - od klasycznych algorytmów heurystycznych i metaheurystyk, przez programowanie liniowe całkowitoliczbowe mieszane (MILP) i programowanie z ograniczeniami, aż po algorytmy rozgałęzień i cen, metody uczenia ze wzmocnieniem czy dekompozycję Bendersa opartą na logice. Takie zestawienie umożliwia identyfikację głównych kierunków badawczych, analizę dominujących metod oraz porównanie sposobów radzenia sobie z niepewnością i złożonością operacyjną w badanym problemie.

Tabela 1.1: Reprezentatywne prace dotyczące harmonogramowania i trasowania UAV

Literatura	Konfiguracja	Niepewności i założenia	Metoda rozwiązania
Pina-Pardo et al. (2021) [62]	– / 1 / –	RT; Punkt spotkania: klient	Algorytm heurystyczny
Nguyen et al. (2022) [57]	M / M / –	–	Metaheurystyka (GRASP + VNS)
Saleu et al. (2022) [54]	M / M / –	–	Metaheurystyka (GRASP + ILS)
Lei and Chen (2022) [44]	1 / M / –	–	Metaheurystyka (VNS improved)
Jung and Kim (2022) [40]	– / – / –	Niepewność czasu lotu UAV oraz czasu przejazdu ciężarówki	Programowanie liniowe całkowitoliczbowe mieszane (MILP Mixed Integer Linear Programming)
Zhao et al. (2024) [94]	1 / 1 / –	Punkt spotkania: klient lub lokalizacja zewnętrzna/niebędąca klientem	Heurystyka
Zhao et al. (2022b) [95]	1 / 1 / –	Niepewność środowiska nawigacyjnego oraz niepewność zapotrzebowania. Punkt spotkania: klient lub lokalizacja zewnętrzna/niebędąca klientem	Programowanie mieszane robust (MILP + C&CG)
Zhu et al. (2022) [98]	– / – / –	–	Algorytm generowania kolumn i ograniczeń
Nguyen and Ha (2023) [58]	– / – / –	–	Metaheurystyka + MILP (collective drones)
Montemanni et al. (2023) [55]	M / M / –	–	Programowanie z ograniczeniami (CP)
Zhang et al. (2023) [92]	– / – / –	Niepewność dostępności węzłów/krawędzi (selective routing, scenariusze zakłóceń)	Algorytm rozwidleń i cen
Yang et al. (2023) [87]	1 / 1 / –	Niepewność czasu przejazdu ciężarówki. Punkt spotkania: klient	Programowanie robust (B&Price&Cut)

ciąg dalszy na następnej stronie

Tabela 1.1: Reprezentatywne prace dotyczące harmonogramowania i trasowania UAV - (cd.)

Literatura	Konfiguracja	Niepewności i założenia	Metoda rozwiązania
Wang et al. (2023) [76]	– / – / –	Niepewność podaży (equity) i czasów dostaw	Dekompozycja Bendersa (robust 2-stage)
Bruni et al. (2023) [8]	– / – / –	Niepewność latency i czasów przelotu UAV (scenariuszowa)	Programowanie stochastyczne (MILP + Branch&Check)
Yin et al. (2023) [89]	– / – / –	Niepewność czasu przejazdu ciężarówki oraz niepewność zapotrzebowania. Punkt spotkania: klient	Programowanie dwustopniowe robust (B&Cut)
Montemanni et al. (2024) [56]	– / – / –	–	Programowanie z ograniczeniami
Chen and Wang (2024) [13]	– / M / –	Punkt spotkania: klient	Algorytm uczenia ze wzmocnieniem
Pina-Pardo et al. (2024) [63]	– / M / M	RT; Punkt spotkania: klient	Metaheurystyka (hybrydowa VNS)
Barzanjeh et al. (2025) [7]	– / M / –	Niepewne czasy lotu UAV; Punkt spotkania: lokalizacja zewnętrzna	Dekompozycja logic-based Benders (LBBD)

Legenda: **T** - liczba ciężarówek, **UAV_s** - liczba UAV serwisowych, **UAV_p** - liczba UAV wspierających; **M** - wiele jednostek; – - brak informacji/nie dotyczy; **RT** - uwzględniono czasy zwolnienia (release times).

Jednocześnie nawet najnowsze prace dotyczące wspólnej optymalizacji tras, zadań i zasobów UAV koncentrują się najczęściej na wyspecjalizowanych wariantach problemu, takich jak systemy dostawcze, inspekcyjne, MEC lub układy UAV–pojazd naziemny, natomiast rzadziej proponują uogólniony formalizm umożliwiający jednolite modelowanie zasobów, slotów, trajektorii, okien czasowych oraz zakłóceń w ramach jednego procesu decyzyjnego.

Powyższa analiza wskazuje na kilka dominujących kierunków badawczych:

- Po pierwsze, większość prac koncentruje się na statycznym lub pół-dynamicznym planowaniu zadań (ex-ante), zakładając znaną strukturę problemu oraz ograniczoną zmienność środowiska operacyjnego. W takich podejściach proces decyzyjny realizowany jest jednorazowo lub z ograniczoną liczbą iteracji reoptymalizacyjnych.
- Po drugie, choć w wielu modelach uwzględnia się wybrane źródła niepewności (np. czas przelotu, zapotrzebowanie, warunki środowiskowe), to najczęściej mają one charakter parametryczny lub scenariuszowy, co ogranicza możliwość pełnej adaptacji modelu do dynamicznych zmian struktury procesu.

- Po trzecie, dominujące metody obliczeniowe, zarówno metaheurystyki, jak i metody dokładne, koncentrują się na wyznaczaniu rozwiązań optymalnych lub przybliżonych dla ustalonej postaci problemu, bez jawnego modelowania procesu decyzyjnego jako ewoluującego systemu stanów i decyzji.

W konsekwencji istnieje luka badawcza związana z brakiem podejść umożliwiających jednocześnie:

- formalne modelowanie struktury procesu decyzyjnego,
- uwzględnienie dynamicznych zmian zasobów i ograniczeń,
- adaptacyjne generowanie decyzji w czasie rzeczywistym.

W niniejszej pracy zaproponowano podejście oparte na technologii algebraiczno-logicznego meta-modelowania (ALMM), które umożliwi opis procesu harmonogramowania jako wieloetapowego procesu decyzyjnego z jawnie zdefiniowaną przestrzenią stanów, zbiorem decyzji oraz relacjami przejścia. Takie ujęcie pozwala na dynamiczną adaptację harmonogramu w odpowiedzi na zmiany struktury procesu oraz pojawiające się zakłócenia operacyjne.

Na podstawie przedstawionego przeglądu wytypowano również grupę prac referencyjnych, które wykorzystano w dalszej części pracy do analizy porównawczej opracowanej metody. Wyniki tej analizy przedstawiono w rozdziale 6.6, koncentrując się na ocenie efektywności, odporności oraz interpretowalności podejmowanych decyzji w środowisku dynamicznym.

Uzasadnienie podjęcia tematu

Analiza przedstawionych w przeglądzie literatury podejść wskazuje na dużą różnorodność strategii harmonogramowania zadań UAV, zależnych od charakteru misji, konfiguracji systemu oraz przyjętych założeń modelowych. Jednocześnie ujawnia ona istotne ograniczenia istniejących metod, szczególnie w kontekście zastosowań operujących w dynamicznie zmieniającym się środowisku przestrzeni powietrznej.

W szczególności większość dostępnych rozwiązań koncentruje się na statycznym lub ograniczonym dynamicznie planowaniu zadań, przy założeniu znanej struktury problemu oraz względnie stabilnych warunków operacyjnych. Podejścia te nie uwzględniają w pełni zmienności dostępnych zasobów ani konieczności adaptacyjnego podejmowania decyzji w czasie rzeczywistym. Problem ten staje się szczególnie istotny w przypadku operacji UAV realizowanych w przestrzeni powietrznej regulowanej czasowo-przestrzennie.

Rosnące znaczenie koncepcji korytarzy powietrznych oraz integracji ruchu bezzałogowego z ruchem załogowym powoduje, że przestrzeń powietrzna staje się zasobem ograniczonym, którego dostępność ma charakter dynamiczny. W takim środowisku planowanie misji UAV wymaga jednoczesnego uwzględnienia ograniczeń czasowych, przestrzennych oraz operacyjnych, a także synchronizacji wielu obiektów w warunkach występowania zakłóceń.

Złożoność problemu wzrasta dodatkowo w przypadku konieczności reagowania na zdarzenia nieprzewidziane, takie jak awarie statków powietrznych, zmiany dostępności przestrzeni powietrznej czy opóźnienia w realizacji zadań. Klasyczne metody optymalizacji dyskretniej, choć skuteczne w warunkach statycznych, nie zapewniają wystarczających mechanizmów adaptacji do takich zmian bez konieczności ponownego rozwiązywania problemu od podstaw.

Istniejące systemy zarządzania ruchem lotniczym oraz planowania operacji (np. rozwiązania rozwijane w ramach European ATM Master Plan) nie oferują obecnie w pełni autonomicznych mechanizmów inteligentnego zarządzania flotą UAV, uwzględniających dynamiczną synchronizację decyzji w czasie rzeczywistym.

Istotnym uzupełnieniem analizy literaturowej jest przegląd istniejących rozwiązań technologicznych oraz systemów wspomagających podejmowanie decyzji w procesach harmonogramowania i zarządzania zasobami, które znajdują zastosowanie w obszarach pokrewnych do rozważanego problemu.

W rozwiązaniu opracowanym przez amerykański zespół badawczy związany z technologią pt.: *Intelligent Decision Synchronization in Real Time for both Discrete and Continuous Process Industries*, proponowany jest system inteligentnej synchronizacji decyzji w czasie rzeczywistym zarówno dla dyskretnych, jak i ciągłych procesów przemysłowych. Podejście to wykorzystuje mechanizmy konstruowania decyzji na podstawie wcześniej zdefiniowanych heurystyk procesu. Pomimo wysokiej efektywności w stabilnych warunkach, rozwiązanie to nie zapewnia pełnej adaptacyjności do dynamicznie zmieniającej się struktury procesu, gdyż wymaga wcześniejszej znajomości możliwych trajektorii stanów oraz nie umożliwia autonomicznego dostosowania modelu do nowych warunków operacyjnych [60].

Kolejnym przykładem jest system *Optimization method for task allocation and path planning joint problem of multiple unmanned aerial vehicles*, dotyczący wspólnego problemu przydziału zadań i planowania tras wielu UAV. W podejściu tym zastosowano konstrukcję drzewa decyzyjnego, w którym zadania są przydzielane iteracyjnie, a trajektorie wyznaczane są w oparciu o statyczny model środowiska. Rozwiązanie to jest efektywne dla niewielkich flot oraz stabilnych warunków operacyjnych, jednak w przypadku wystąpienia zakłóceń lub zmian dostępności zasobów wymaga ponownej konstrukcji drzewa decyzyjnego, co ogranicza jego zastosowanie w środowiskach dynamicznych [81].

Modelowanie algebraiczno-logiczne, rozwijane m.in. w pracach Bubnickiego [9, 10] oraz Dudek-Dyduch [18, 19], umożliwia reprezentację procesów decyzyjnych z wykorzystaniem struktur wyższego rzędu, takich jak zbiory i relacje. Podejście to pozwala na elastyczne odwzorowanie zarówno struktury procesu, jak i jego ewolucji w warunkach zmiennych ograniczeń operacyjnych.

Dodatkowo, w pracach [20, 21, 24, 29, 30, 91] przedstawiono rozwój podejścia algebraiczno-logicznego oraz jego zastosowania w wybranych problemach sterowania i wspomagania decyzji. Badania te potwierdzają przydatność technologii ALMM w środowiskach wymagających uwzględnienia złożonych zależności oraz adaptacji do zmieniających się warunków. Jednocześnie należy zauważyć, że dotychczasowe prace nie koncentrują się na problemie dynamicznego harmonogramowania zadań dla flot UAV w przestrzeni powietrznej o ograniczonej dostępności zasobów. W szczególności brak jest podejść integrujących modelowanie algebraiczno-logiczne z problemami synchronizacji operacji UAV oraz dynamicznej dostępności korytarzy powietrznych, co stanowi bezpośrednią motywację dla niniejszej pracy.

Przeprowadzona analiza wskazuje, że istniejące rozwiązania, zarówno w literaturze naukowej, jak i w systemach technologicznych, nie zapewniają mechanizmów umożliwiających dynamiczne dostosowanie procesu decyzyjnego do zmieniających się warunków operacyjnych bez konieczności jego rekonstrukcji. Stanowi to istotną lukę badawczą w obszarze harmonogramowania zadań UAV.

Zidentyfikowana luka badawcza oraz ograniczenia istniejących metod i systemów stanowią bezpośrednie uzasadnienie podjęcia tematu niniejszej pracy, której celem jest opracowanie modelu i metod harmonogramowania umożliwiających adaptacyjne zarządzanie flotą UAV w warunkach dynamicznie zmieniającej się dostępności przestrzeni powietrznej.

1.2 Cel i teza pracy

Celem niniejszej pracy jest opracowanie modelu oraz metod harmonogramowania zadań logistycznych dla flot bezzałogowych statków powietrznych (UAV), operujących w warunkach dynamicznie zmieniającej się dostępności przestrzeni powietrznej. W pracy przyjęto podejście oparte na technologii Algebraiczno-Logicznego Meta-Modelowania (ALMM), umożliwiające formalny opis procesu decyzyjnego jako wieloetapowego procesu o zmiennej strukturze, w którym uwzględnia się ograniczenia czasowe, przestrzenne oraz dostępność zasobów.

Realizacja celu głównego pracy obejmuje następujące cele szczegółowe:

- opracowanie formalnego modelu harmonogramowania zadań UAV z uwzględnieniem dynamicznej dostępności korytarzy powietrznych,
- opracowanie metod wyznaczania sekwencji decyzji (trajektorii stanów procesu decyzyjnego) w warunkach występowania zakłóceń operacyjnych, z uwzględnieniem mechanizmów adaptacyjnej reoptymalizacji,
- integracja metod optymalizacyjnych z modelem algebraiczno-logicznym w celu wyznaczania rozwiązań dopuszczalnych i efektywnych,
- przeprowadzenie badań symulacyjnych oraz weryfikacji modelu w warunkach zbliżonych do rzeczywistych.

Na podstawie sformułowanego celu pracy przyjęto następującą tezę rozprawy:

Zastosowanie technologii algebraiczno-logicznego meta-modelowania umożliwia konstrukcję modeli harmonogramowania zadań dla flot UAV, które zapewniają wyznaczanie dopuszczalnych i efektywnych rozwiązań w warunkach dynamicznie zmieniających się ograniczeń przestrzeni powietrznej oraz występowania zakłóceń operacyjnych, bez konieczności każdorazowej rekonstrukcji modelu decyzyjnego.

Zakres realizacji celów pracy

Realizacja sformułowanych celów pracy obejmuje następujące zadania badawcze i implementacyjne:

1. Opracowanie formalnego modelu algebraiczno-logicznego procesu harmonogramowania misji UAV, uwzględniającego:
 - dostępność korytarzy powietrznych i slotów czasowych,

- reprezentację misji UAV jako trajektorii przestrzenno-czasowych,
 - występowanie zakłóceń operacyjnych.
2. Opracowanie metod harmonogramowania oraz wyznaczania sekwencji decyzji (trajektorii stanów procesu) z uwzględnieniem mechanizmów adaptacyjnej reoptymalizacji w warunkach zakłóceń.
 3. Integracja wybranych metod optymalizacyjnych (w tym heurystyk i matheurystyk) z modelem algebraiczno-logicznym w celu wspomagania procesu podejmowania decyzji oraz wyznaczania rozwiązań dopuszczalnych i efektywnych.
 4. Implementacja środowiska obliczeniowego umożliwiającego realizację oraz analizę opracowanego modelu i metod harmonogramowania.
 5. Przeprowadzenie badań symulacyjnych oraz walidacja zaproponowanego podejścia w warunkach zbliżonych do rzeczywistych, z wykorzystaniem:
 - danych odwzorowujących rzeczywistą organizację przestrzeni powietrznej,
 - scenariuszy dynamicznych uwzględniających różne typy zakłóceń,
 - analizy jakości uzyskanych rozwiązań.

Nowatorskie podejście i wkład pracy

Niniejsza praca wnosi wkład do dziedziny harmonogramowania misji UAV poprzez zaproponowanie spójnego modelu oraz metod planowania zadań, które jawnie uwzględniają dynamiczną dostępność przestrzeni powietrznej, w tym korytarzy i slotów czasowych. Rozważany problem dotyczy synchronizacji i harmonogramowania operacji UAV realizujących czasowo wrażliwe misje logistyczne w środowisku o zmiennej dostępności zasobów oraz występowaniu zakłóceń operacyjnych. Proponowane podejście łączy formalny opis procesu decyzyjnego z mechanizmami adaptacyjnej reoptymalizacji, co umożliwia wyznaczanie rozwiązań wykonalnych w warunkach dynamicznych. Szczegółowy wkład pracy obejmuje:

- Opracowanie algebraiczno-logicznego modelu harmonogramowania zadań UAV, uwzględniającego dynamiczną dostępność przestrzeni powietrznej oraz ograniczenia czasowo-przestrzenne.
- Opracowanie metod wyznaczania sekwencji decyzji (trajektorii stanów procesu) w warunkach występowania zakłóceń, z uwzględnieniem mechanizmów adaptacyjnej reoptymalizacji.
- Integrację wybranych metod optymalizacyjnych (w szczególności heurystyk i matheurystyk) z podejściem algebraiczno-logicznym w celu wyznaczania rozwiązań dopuszczalnych i efektywnych w środowisku dynamicznym.
- Uwzględnienie danych operacyjnych odwzorowujących rzeczywistą organizację przestrzeni powietrznej (np. sloty czasowe, dostępność korytarzy) w procesie harmonogramowania UAV.
- Opracowanie mechanizmów dynamicznej realokacji zadań w odpowiedzi na zakłócenia operacyjne, z wykorzystaniem strategii priorytetowych.

- Weryfikację zaproponowanego podejścia w środowisku symulacyjnym odwzorowującym rzeczywiste ograniczenia operacyjne przestrzeni powietrznej.

1.3 Struktura pracy

Struktura rozprawy została zaprojektowana w sposób zapewniający logiczne i systematyczne przejście od identyfikacji problemu badawczego, poprzez jego formalizację i modelowanie matematyczne, aż do opracowania algorytmicznych metod rozwiązania oraz eksperymentalnej walidacji zaproponowanej technologii. Układ pracy odzwierciedla kolejne etapy procesu badawczego prowadzącego do opracowania kompletnej technologii inteligentnego harmonogramowania zadań operacyjnych dla floty bezałogowych statków powietrznych z wykorzystaniem paradygmatu algebraiczno-logicznego meta-modelowania. Rozprawa składa się z siedmiu rozdziałów, których układ podporządkowano realizacji celu pracy oraz weryfikacji postawionej tezy badawczej.

Rozdział 1 stanowi wprowadzenie do problematyki badawczej rozprawy. Przedstawiono w nim motywację podjęcia badań, sformułowano cel główny pracy, cele szczegółowe oraz tezę rozprawy. Omówiono także przesłanki naukowe i aplikacyjne uzasadniające potrzebę opracowania nowych metod harmonogramowania zadań UAV w środowiskach dynamicznych i zakłócanych.

Rozdział 2 prezentuje podstawy teoretyczne technologii algebraiczno-logicznego meta-modelowania (ALMM), stanowiącej formalny fundament opracowanego podejścia badawczego. Przedstawiono w nim formalną strukturę meta-modelu algebraiczno-logicznego, definicję przestrzeni stanów i decyzji oraz funkcji przejścia procesu decyzyjnego. Omówiono również architekturę Inteligentnego ALMM Systemu oraz dotychczasowe zastosowania technologii ALMM w problemach optymalizacji dyskretniej. Rozdział ten ustanawia aparat formalny wykorzystywany w dalszych etapach modelowania problemu harmonogramowania UAV.

Rozdział 3 zawiera formalny i aplikacyjny opis rozważanego problemu zarządzania flotą UAV w środowisku okołolotniskowym. Scharakteryzowano w nim zasoby systemowe, strukturę zadań operacyjnych, przestrzeń realizacji misji, sloty czasowe, korytarze powietrzne oraz rodzaje zakłóceń wpływających na przebieg procesu harmonogramowania. Rozdział ten definiuje rzeczywiste uwarunkowania operacyjne analizowanego problemu i stanowi podstawę do jego dalszej formalizacji w strukturze modeli ALMM.

Rozdział 4 przedstawia autorską formalizację problemu harmonogramowania UAV w postaci kaskady modeli algebraiczno-logicznych. Opracowano kolejno model bazowy ALMM oraz jego rozszerzenia: ALMM-TS, ALMM-CS, ALMM-TW i ALMM-D, odpowiadające kolejnym poziomom złożoności operacyjnej i ograniczeń środowiskowych. Dla każdego modelu zdefiniowano strukturę stanu, przestrzeń decyzji, funkcję przejścia oraz zbiory stanów dopuszczalnych i niedopuszczalnych. Rozdział kończy sformułowanie zadania optymalizacji procesu harmonogramowania jako problemu przeszukiwania trajektorii dopuszczalnych w przestrzeni stanów procesu decyzyjnego.

Rozdział 5 poświęcony został opracowaniu metodologii i algorytmów rozwiązywania sformalizowanego problemu harmonogramowania. Przedstawiono w nim autorskie heurystyki redukcji przestrzeni decyzyjnej, algorytmy planowania zadań, procedury przydziału do slotów czasowych, metody generowania trajektorii lotu oraz algorytmy dynamicznej rekonfiguracji harmonogramu w odpowiedzi na zakłócenia. Za-

prezentowane rozwiązania stanowią operacyjną implementację modeli formalnych przedstawionych w rozdziale poprzednim i tworzą kompletną warstwę obliczeniową proponowanej technologii.

Rozdział 6 zawiera wyniki badań eksperymentalnych służących walidacji opracowanej technologii. Przedstawiono środowisko badawcze oraz zakres przeprowadzonych eksperymentów symulacyjnych i walidacyjnych. Następnie zaprezentowano wyniki eksperymentów dla kolejnych wariantów modeli i scenariuszy operacyjnych, obejmujących zarówno warunki bazowe, jak i środowiska z ograniczeniami czasowo-przestrzennymi oraz zakłóceniami dynamicznymi. Rozdział obejmuje również walidację systemu w warunkach zbliżonych do rzeczywistych oraz analizę porównawczą uzyskanych rezultatów względem wybranych podejść literaturowych.

Rozdział 7 stanowi syntetyczne podsumowanie rozprawy. Dokonano w nim oceny stopnia realizacji założonych celów badawczych, weryfikacji postawionej tezy oraz identyfikacji głównych osiągnięć naukowych pracy. Wskazano również ograniczenia opracowanego podejścia oraz możliwe kierunki dalszego rozwoju technologii w obszarze inteligentnych systemów planowania i zarządzania flotami autonomicznych statków powietrznych.

Uzupełnieniem pracy są spisy oznaczeń, rysunków, tabel i algorytmów.

Rozdział 2

Inteligentna technologia algebraiczno-logiczna meta-modelowania ALMM

W niniejszym rozdziale przedstawiona zostaje koncepcja algebraiczno-logicznego meta-modelowania, stanowiąca formalną podstawę dla inteligentnego wspomaganie procesów decyzyjnych w problemach optymalizacji dyskretniej. Zaprezentowany paradygmat umożliwia ujednolicone modelowanie wieloetapowych procesów decyzyjnych z uwzględnieniem złożonych zależności logicznych i ograniczeń algebraicznych. Technologia ALMM znajduje zastosowanie w systemach wspierających rozwiązywanie problemów NP-trudnych, w szczególności w ramach Inteligentnego ALMM Systemu (ALMM Solver), którego skuteczność została potwierdzona w licznych pracach.

Pomimo wysokiego poziomu ogólności i uniwersalności, paradygmat ALMM wymaga opracowania wyspecjalizowanych instancji modeli algebraiczno-logicznych dla konkretnych klas problemów. W szczególności, w literaturze brakuje formalnych modeli ALMM dedykowanych problemowi harmonogramowania zadań dla floty bezzałogowych statków powietrznych (UAV), który charakteryzuje się złożonymi ograniczeniami czasowymi, przestrzennymi oraz dynamicznymi zakłóceniami.

W związku z powyższym, przedstawiony w niniejszym rozdziale aparat formalny stanowi podstawę do budowy autorskich modeli ALMM dla problemu UAV, które zostaną zaprezentowane w Rozdziale 4. Niniejszy rozdział zawiera formalną definicję uogólnionego modelu ALMM, strukturę stanów i decyzji, a także prezentuje architekturę Inteligentnego ALMM Systemu wraz z jego kluczowymi modułami.

2.1 Terminologia algebraiczno logicznego meta - modelu

Inteligentny ALMM System oparty jest na paradygmacie Algebraiczno Logicznego Meta-Modelu wieloetapowych procesów decyzyjnych. W pracy nad ALMM Systemem przewiduje się opracowanie nowych metod i algorytmów optymalizacji dyskretniej oraz modelowanie i rozwijanie systemu informatycznego - ALMM Systemu. Algebraiczno Logiczny Meta-Model wieloetapowych procesów decyzyjnych, stanowi pewien jednolity schemat (wzór) tworzenia formalnego zapisu wszystkich ograniczeń i informacji o deter-

ministycznych problemach, których rozwiązania mogą być przedstawiane jako ciąg lub zbiór decyzji. Jest odpowiedni dla szeregu zagadnień optymalizacji dyskretniej, procesów produkcyjnych, procesów logistycznych, zarządzania projektami czy ogólniej planowania i innych. W oparciu o paradygmat ALMM stworzono tzw. technologię ALMM, która obejmuje:

- Sposób budowy formalnych modeli problemów optymalizacji dyskretniej, tzw. algebraiczno logiczne modele (AL modele).
- Stworzenie terminologii opartej o paradygmat ALMM, w szczególności zdefiniowanie szeregu pojęć wykorzystywanych do analizy problemów optymalizacji dyskretniej i ich AL modeli.
- Formalne zdefiniowanie własności problemów, istotnych dla ich analizy i rozwiązywania.
- Specyfikację metod i algorytmów optymalizacji wyrażonych za pomocą terminologii ALMM.

Wyróżnia się dwie podstawowe klasy wieloetapowych procesów decyzyjnych:

- zwykłe – niezależne od czasu (CMDP - common multistage decision process),
- dynamiczne – zależne od czasu (MDDP - Multistage Dynamic Decision Process).

Dla dynamicznego wieloetapowego procesu decyzyjnego wprowadzono pojęcie tzw. stanu uogólnionego $s = (x, t)$, gdzie: x - stan właściwy oraz t - moment czasu. W niniejszej pracy przez określenie „dyskretny proces decyzyjny” będziemy rozumieć proces, którego model określa Definicja 2.1 [17–19, 21].


Definicja 2.1. Algebraiczno logicznym meta - modelem dynamicznego, wieloetapowego procesu decyzyjnego nazywamy dyskretny proces $P = (U, S, s_0, f, S_N, S_G)$, określony przez sześć składowych. Funkcja $f : U \times S \rightarrow S$ jest funkcją częściową (określoną tylko dla pewnych par) $(u, s) \in U \times S$ zwaną funkcją przejścia, przy czym: zbiór U jest nazywany zbiorem decyzji sterujących lub sygnałów sterowania, zbiór $S = X \times T$ nazywany jest zbiorem stanów uogólnionych, gdzie $T \subset \mathbb{R}^+$ jest podzbiorem nieujemnych liczb rzeczywistych reprezentujących chwile czasowe, a zbiór X nazywany jest zbiorem stanów właściwych. Zbiory U, X, T są niepuste. Funkcja przejścia f , zdefiniowana jest przy pomocy dwóch funkcji $f = (f_x, f_t)$, gdzie: $f_x : U \times X \times T \rightarrow X$ określa następny stan właściwy, $f_t : U \times X \times T \rightarrow T$ określa następny moment czasu i spełnia następujący warunek $\Delta t = f_t(u, x, t) - t$, $0 < \Delta t < \infty$ oraz przyjmuje wartość skończoną. W postaci uporządkowanej zapiszemy zatem $f(u, s) = (f_x(u, x, t), f_t(u, x, t))$, $s = (x, t)$. Uogólniony stan początkowy reprezentowany jest przez $s_0 = (x_0, t_0)$, $s_0 \in S$, $S_N \subset S$ jest zbiorem uogólnionych stanów niedopuszczalnych oraz niepusty zbiór uogólnionych stanów docelowych $S_G \subset S$, a więc stanów, w których proces powinien się znaleźć w wyniku działania właściwych sterowań, przy czym $S_N \cap S_G = \emptyset$. Stany i decyzje nie muszą być zdefiniowane za pomocą zmiennych przyjmujących wartości w przestrzeniach liczbowych. Wartościami zmiennych mogą być nazwy elementów pewnych zbiorów, podzbiory, czy inne obiekty. W konsekwencji, modele definiowane mogą być za pomocą zarówno zależności algebraicznych jak i formuł logicznych - stąd nazwa meta-model algebraiczno-logiczny [18].

2.2 Struktura stanu i decyzji w modelu ALMM

W najogólniejszym przypadku zbiory U oraz X można przedstawić jako iloczyny kartezjańskie $U = U^1 \times U^2 \times \dots \times U^m$, $X = X^1 \times X^2 \times \dots \times X^n$ (górne wskaźniki oznaczają kolejne zbiory, a nie potęgi zbiorów). Najogólniej zarówno decyzja u jak i stan x są wektorami $u = (u^1, u^2, \dots, u^m)$, $x = (x^1, x^2, \dots, x^n)$, w których poszczególne współrzędne wektora reprezentują odrębne decyzje. Należy podkreślić, że w odróżnieniu od sterowania za pomocą sygnałów fizycznych, w procesach decyzyjnych moment podejmowania decyzji nie musi pokrywać się z momentem rozpoczęcia jej realizacji. W oparciu o przedstawiony model paradygmatu można:

- projektować modele szerokiej klasy dyskretnych problemów optymalizacji, w szczególności problemów dynamicznych (AL modele), logistycznych i planowania;
- definiować w oparciu o tak zwaną terminologię ALMM, własności zarówno procesu P jak i kryterium Q ;
- wyjaśniać istniejące algorytmy heurystyczne oraz projektować nowe metaheurystyki.

Model dyskretnego problemu optymalizacji składa się z modelu wieloetapowego procesu decyzyjnego zawierającego w sobie wszystkie ograniczenia, oznaczanego jako P oraz model kryterium optymalizacji Q . Zatem model problemu optymalizacji (P, Q) można zapisać jako $\Pi = (P, Q)$. Indywidualny proces P jest określany przez jego zestaw trajektorii. Poszukiwana jest sekwencja decyzji określająca dopuszczalną lub optymalną trajektorię. Trajektoria opisuje sekwencję stanów określoną przez funkcję przejścia do sekwencji decyzji. Początek trajektorii znajduje się w stanie początkowym s_0 . Koniec trajektorii znajduje się w zbiorze stanów docelowych S_G , natomiast trajektorie niedopuszczalne prowadzą do zbioru stanów niedopuszczalnych S_N . Graficzną interpretację trajektorii indywidualnego procesu P przedstawiono na Rysunku 2.1.




Rysunek 2.1: Przykładowa trajektoria indywidualnego procesu P

Rysunek 2.1 przedstawia hipotetyczną przestrzeń stanów, w której znajdują się przykładowe trajektorie prowadzącego do stanów niedopuszczalnych lub docelowych. Zarówno długość trajektorii, osiągane czasy przejścia do stanu docelowego mogą stanowić przedmiot rozważań dotyczących przyjętego kryterium optymalizacji.

2.3 Koncepcja i struktura Inteligentnego ALMM Systemu

Początkowa koncepcja ALMM Solver została zaproponowana przez Ewę Dudek-Dyduch i opisana w [20, 22–24, 41], w pracach przedstawiono formalizację i analizę problematyki dyskretnych procesów produkcyjnych. Zadaniem Inteligentnego ALMM systemu jest dostarczenie rozwiązań (dokładnych lub przybliżonych) dla NP-trudnych problemów optymalizacji dyskretniej, z wykorzystaniem terminologii ALMM. Główną ideą rozwiązania generowanego przez system ALMM jest wygenerowanie jednej lub więcej trajektorii (w razie potrzeby także częściowych trajektorii). Generowanie trajektorii jest kontrolowane przez różne ogólne metody i/lub specyficzne algorytmy optymalizacji lub algorytmy do wyszukiwania dopuszczalnych rozwiązań. Jako rozwiązanie ALMM System podaje sekwencję decyzji (która określa trajektorię przechodzącą od stanu początkowego s_0 do stanu należącego do S_G) lub wskazuje, że nie znaleziono rozwiązania. ALMM System zapewnia funkcjonalność w zakresie modelowania problemów, optymalizacji problemów, symulacji procesów dla danej sekwencji decyzji oraz prezentacji wyników (w tym wizualizacji). Proponowaną strukturę modułową dla ALMM Systemu przedstawiono na Rysunku 2.2. Na wejście ALMM Systemu podawany jest model algebracno logiczny problemu i dane. Na tej podstawie tworzony jest IT model problemu. Model ten można łatwo „złożyć” z komponentów znajdujących się w bibliotece komponentów i modeli.



Rysunek 2.2: Modułowa struktura ALMM Systemu

ALM Modeler to moduł, który pozwala zdefiniować model problemu w technologii ALMM. W tym celu należy stworzyć AL model procesu, zdefiniować kryterium optymalizacji i zdefiniować dodatkową wiedzę o problemie (np. pomocnicze procedury pomocnicze lub reguły wnioskowania). AL Model można zbudować z wykorzystaniem predefiniowanych komponentów lub definiując go od podstaw.


Moduł SimOpt stanowi rdzeń ALMM Systemu. Jego zadaniem jest inteligentne skonstruowanie drzewa przejścia stanu (w całości lub tylko jego części) poprzez wygenerowanie jednej lub więcej trajektorii (części trajektorii). Baza danych Solver przechowuje wszystkie wygenerowane stany trajektorii, zachowując

strukturę drzewa. Moduł SimOpt wykorzystuje model problemu dostarczonego przez ALM Modeler. Generowanie trajektorii jest kontrolowane za pomocą algorytmów z Algorithm Module.

Algorithm Module zawiera zbiór wdrożonych metod i algorytmów oraz umożliwia zaprojektowanie nowych algorytmów. Moduł składa się z dwóch części: repozytorium algorytmów i modułu do tworzenia nowych algorytmów. W repozytorium algorytmów przechowane są różne metody i algorytmy. Natomiast moduł tworzenia algorytmów pozwala tworzyć nowe metody i algorytmy.

Result Interpreter to moduł, który identyfikuje ostateczne rozwiązanie danego problemu (najlepsze lub dopuszczalne) na podstawie danych (drzewa stanu) przechowywanych w bazie danych ALMM Systemu. Result Interpreter podaje użytkownikowi rozwiązanie (jedno lub wiele) lub zwraca informację o niezalezieniu rozwiązania, w przypadku, gdy rozwiązanie nie istnieje lub nie zostało znalezione przed spełnieniem warunku zakończenia.


Koncepcja Inteligentnego ALMM Systemu została podana w pracy [17]. Przedstawiono w niej koncepcję systemu, opartego na technologii ALMM, której celem jest optymalizacja problemów dyskretnych. Początkowa struktura ALMM Systemu została zasadniczo zmodyfikowana i rozszerzona o następujące nowe moduły: Inteligentny Interfejs Użytkownika (Intelligent User Interface (IUI)), moduł bazy wiedzy (Knowledge Base (KB)), moduł Solution Creator (SC) i Solution Creator Control (SCC). Strukturę Inteligentnego ALMM Systemu przedstawiono na Rysunku 2.3 [23, 24, 30].



Rysunek 2.3: Struktura inteligentnego ALMM Systemu [30]

Głównym modulem obliczeniowym ALMM Systemu jest moduł Solution Creator, który przeprowadza operacje mające na celu znalezienie rozwiązań dla problemów. W obecnej wersji ALMM Systemu moduł Solution Creator składa się z kilku równoległych podmodułów zwanych Solving Method Engines (SME) (patrz Rysunek 2.4). Funkcjonalnie każdego z SME opiera się na ściśle określonej metodzie rozwiązywania (lub klasie algorytmów). Wykorzystywane metody są zarówno dobrze znane jak i na nowo opracowywane

i zdefiniowane w technologii ALMM. Moduł Solution Creator Control uruchamia i konfiguruje odpowiedni SME, aby wykonać odpowiedni algorytm.



Rysunek 2.4: Struktura Solving Module [30]

Inteligentny interfejs użytkownika ma za zadanie zainicjować i przekazać informację o modelu problemu do modułu Solution Creator. Model musi zostać zdefiniowany w terminologii AL Modelu lub SRM (Software Representation Model). Model problemu można zdefiniować poprzez:

- użycie gotowego modelu znajdującego się w Library od Problem Models,
- zbudowanie modelu z istniejących komponentów AL Modeli,
- opracowanie nowego modelu podając wszystkie bazowe komponenty problemu.

Drugie zadanie IUI polega na inteligentnym wyborze metody (obsługiwanej przez system) i konfiguracji algorytmu rozwiązywania. W tym zadaniu IUI współpracuje z komponentami bazy wiedzy: właściwości problemu (Properties of Problem) (znajdujące się w bazie wiedzy problemów) i bazą wiedzy na temat metod rozwiązywania i algorytmów. Ostatnim zadaniem IUI jest zwrócenie rozwiązania lub informacji o niezalezieniu rozwiązania. To, co odróżnia ALMM system od innych systemów/solwerów jest fakt, że Inteligentny ALMM System posiada bazę wiedzy, która jest wykorzystywana do:

- przechowywania modeli problemów i ich komponentów, reprezentowanych w technologii ALMM,
- wspomagania tworzenia modeli nowych problemów, poprzez wykorzystanie zapisanych (przechowywanych) w bazie komponentów,

- przechowywania specyfikacji metod i algorytmów optymalizacji dyskretnej, przedstawionych w technologii ALMM,
- przechowywania definicji ogólnych własności problemów optymalizacji dyskretnej i informacji o własnościach, które są spełniane przez poszczególne problemy.

Baza wiedzy przechowuje wiedzę o problemach (Knowledge of Problems) i wiedzę na temat algorytmów i metod rozwiązywania (Knowledge on Solving Methods and Algorithms). Wiedza o problemach składa się z:

- biblioteki problemów (Library of Problem Models), która przechowuje AL i SR modele, które zawierają także komponenty do tworzenia nowych modeli,
- właściwości problemów (Properties of Problems), która zawiera ogólne definicje procesów i problemów oraz relacje wiążące się z poszczególnymi problemami (komponentami) zawartymi w Library of Problems.

W początkowym etapie użytkownik wybiera model problemu korzystając z modeli (komponentów modeli) zgromadzonych w bazie lub też konstruuje własny model problemu, a następnie wybiera metodę rozwiązania problemu (algorytm). Zamieszczony poniżej Algorytm 1 przedstawia możliwy scenariusz dostępu do SR AL modeli problemów przechowywanych w KB lub definiowanych komponentowo na bazie dostępnych AL modeli. W algorytmie odpowiednio Π - problem, P - proces, Q - kryterium, LofPM - Library of Problem Models, LofPMBase - biblioteka problemów, MDDP - Dynamic multistage decision proces.

Algorytm 1 Fragment algorytmu tworzenia AL Modelu

Require: problem $\Pi = (P, Q)$ or $\Pi = P$, Model**Ensure:** solution to the given problem Π

```

1: ...
2: if  $\Pi == P$  then
3:   connect LofPMBase();
4:   if Model  $\in$  LofPM then
5:     if Model is 'AL model' then
6:       load ALModel();
7:       view(Model);
8:     else if Model is 'SR model' then
9:       load SRModel(ComponentsSRModel);
10:      Solve(Model);
11:    else
12:      break
13:    end if
14:  else
15:    if ComponentsSRModel  $\in$  LofPM then
16:      MDDP = new SelectComponents();
17:      Model = new SRModel(MDDP);
18:      Solve(Model);
19:    else
20:      MDDP = new SelectComponents(SpecificProperties);
21:      Model = new SRModel(MDDP);
22:      addModel(LofPM);
23:      Solve(Model);
24:    end if
25:  end if
26: else
27:   // another optimization problem
28: end if
29: ...

```

Właściwości problemów


W Bazie wiedzy o problemach znajduje się repozytorium ich własności, które wykorzystywane jest w celu:

- zastosowania technologii komponentowej w tworzeniu AL modeli i SR modeli jak również specyfikacji metod i algorytmów, czyli rozwijania oprogramowania z wykorzystaniem tzw. reusable code,
- wspomagania użytkownika w doborze metod i algorytmów w zadaniach rozwiązywania wybranych klas problemów.

Właściwości zapisane w bazie wiedzy podzielone są na grupy związane z:


- typem wieloetapowego procesu, który stanowi bazę dla danego modelu (MDDP, CMDP),
- właściwościami poszczególnych elementów definiujących proces P ,
- właściwościami trajektorii procesu P ,
- właściwościami poszczególnych kryteriów Q .

Powyższe właściwości mogą być wykorzystane w celu inteligentnego doboru metody rozwiązania i algorytmu jak również do łatwiejszej i jednorodnej implementacji algorytmów. Klasyczną architekturę wybranych właściwości, które mogą opisywać problemy pewnej klasy przedstawiono na Rysunku 2.5.



Rysunek 2.5: Architektura własności problemu Π

Do właściwości opisujących kryterium Q zaliczyć można separowalność. Kryterium jest separowalne jeżeli możemy obliczyć jego wartość dla następnego stanu trajektorii znając jego wartość w poprzednim stanie i decyzję podjętą w tym czasie. Kryterium separowalności umożliwia stosowanie metody podziału i ograniczeń, programowania dynamicznego lub optymalizacji lokalnej. Polega to na możliwości jego rekurencyjnego obliczania, w sposób analogiczny jak obliczane są kolejne stany trajektorii (Rysunek 2.6). Trajektori



Rysunek 2.6: Generowanie trajektorii dla kryterium separowalności

procesu P nazywamy sekwencję stanów $\tilde{s} = (s_0, s_1, \dots, s_\omega)$, gdzie $s_{i+1} = f(u_i, s_i)$ dla $i = 0, 1, \dots, \omega-1$, oraz odpowiadającą jej sekwencję decyzji $\tilde{u} = (u_0, u_1, \dots, u_{\omega-1})$. Kryterium Q jest separowalne dla procesu P , jeżeli dla każdej sekwencji decyzyjnej $\tilde{u} \in U$ można w rekurencyjny sposób wyznaczyć:

$$Q_0 = \text{const w szczególności gdy } Q_0 = 0 \quad (2.1)$$

$$Q_{i+1} = f_Q(Q_i, u_i, s_i) \text{ dla } i = 0, 1, \dots, \omega - 1 \quad (2.2)$$

gdzie: Q_i dla $i > 0$ opisuje wartość kryterium Q wyznaczonego dla tego stanu w rozpatrywanej trajektorii $Q_i = Q(\tilde{u}')$, gdzie $\tilde{u}' = (u_0, u_1, \dots, u_{i-1})$ jest początkowym fragmentem sekwencji decyzji $\tilde{u}$, natomiast ω oznacza długość trajektorii $\tilde{s}$. Funkcja $f_Q : \mathbb{R} \times U \times S \rightarrow \mathbb{R}$ jest funkcją częściową, taką że:

$$\text{Dom } f_Q = \{(a, u, s) \in \mathbb{R} \times U \times S : s \in S^P, u \in U_p, a \in \mathbb{R}\}. \quad (2.3)$$

Separowalność jest właściwością algorytmu, który oblicza kryterium jakości dla sekwencji decyzji $\tilde{u}$, a tym samym dla wyznaczonej przez niego trajektorii $\tilde{s}$. Kryterium można oddzielić, jeśli możemy obliczyć jego wartość dla następnego stanu trajektorii znając jego wartość w poprzednim stanie i decyzję podjętą w tym czasie. Szczególnie przydatne są właściwości addytywnej rozdzielności kryterium. Przyjmując, że Q będzie kryterium rozdzielnym, a funkcja $\Delta Q(u, s)$ opisuje zmianę kryterium w stanie s (ustalonej trajektorii procesu P) w wyniku podjętej decyzji u , to separowalne kryterium Q jest addytywne dla procesu P , jeżeli dla każdej trajektorii $\tilde{s}$ danego procesu P , dla $i = 0, 1, \dots, d(\tilde{s}) - 1$ zachodzą zależności:

$$f_Q(Q_i, u_i, s_i) = Q_i + \Delta Q(u_i, s_i). \quad (2.4)$$

$$Q_{i+1} = Q_i + \Delta Q(u_i, s_i) \quad (2.5)$$

kryterium sterowalności Q zmienia się multiplikatywnie dla procesu P , jeżeli dla każdej trajektorii $\tilde{s}$ procesu P i dla $i = 0, 1, \dots, d(\tilde{s}) - 1$ zachodzi zależność:

$$f_Q(Q_i, u_i, s_i) = Q_i \cdot \nu(u_i, s_i) \quad (2.6)$$

gdzie $\nu(u, s)$ jest pewną funkcją składającą się z decyzji i stanu.

Podane powyżej właściwości kryterium wykorzystywane są w metodzie branch&bound, programowaniu dynamicznym, reinforcement learning, algorytmach A* jak również w klasie algorytmów konstrukcyjnych w oparciu o tzw. metodę trójstopniową i w szczególności w metodzie uczenia się opartą o terminologię ALMM. IUI może zaproponować użytkownikowi możliwe rozwiązania oparte na kryteriach i właściwościach procesu P . Po wybraniu odpowiedniej metody Inteligentny ALMM System wykorzystuje bardziej szczegółowe właściwości problemu i jego modelu w celu zbudowania poszczególnych komponentów algorytmu.

2.4 Przegląd wykorzystania technologii ALMM

Na tle szeroko stosowanych metod rozwiązywania problemów optymalizacyjnych, takich jak metaheurystyki (np. algorytmy genetyczne, Tabu Search, symulowane wyżarzanie), podejścia oparte na programowaniu z ograniczeniami (CP) czy metody dekompozycyjne, technologia ALMM stanowi alternatywną propozycję formalnego modelowania i rozwiązywania problemów kombinatorycznych. W odróżnieniu od podejść klasycznych, ALMM integruje opis struktury problemu z procesem konstrukcji algorytmu, co pozwala na dynamiczne dopasowanie metod rozwiązywania do specyfiki zadania. Rozwój tej technologii i jej zastosowania został szeroko opisany w pracach [17, 20, 21, 23–26, 30, 31, 41–43, 91].

W pracy [17] przedstawiono koncepcję i strukturę ALMM Solvera, którego celem jest generowanie rozwiązań dla dyskretnych problemów optymalizacyjnych, w szczególności dla problemów NP-trudnych. Opracowywanie nowych heurystycznych metod znajdowania rozwiązań dyskretnych problemów optymalizacyjnych przedstawiono w pracach [20, 21, 43]. Omówiono modelowanie i sterowanie dyskretnymi procesami produkcyjnymi (DPP) z zakłóceniami różnego typu m.in.: awariami maszyn, defektami jakościowymi, nieoczekiwanymi dodatkowymi zamówieniami. Przedstawiono również nowatorską formalną metodę modelowania DPP z zakłóceniami.

Modelowanie i rozwijanie systemu informatycznego Intelligent ALMM System zaprezentowano w pracy [41], dotyczącej rozwiązywania kombinatorycznych i dyskretnych problemów optymalizacyjnych, w tym niedeterministycznych problemów wielomianowych. Przedstawiono nową, rozszerzoną strukturę modułową ALMM Solver wraz z podstawowym układem Problem Model Library (PML).

W pracach [23, 24] przedstawiono koncepcję założeń implementacyjnych systemu Knowledge Base (KB) współpracującego z inteligentnym systemem informatycznym do rozwiązywania problemów dyskretnej optymalizacji. Zaproponowano wykorzystanie środowiska Protégé do ekstrakcji wiedzy o właściwościach i cechach problemów dyskretnych opisanych technologią ALMM. Implementację KB wspierającej inteligentny system do rozwiązywania problemów optymalizacyjnych przedstawiono w [30]. Wykorzystując zunifikowany opis wybranych problemów optymalizacyjnych zaprojektowano ontologiczną bazę wiedzy, która pozwala na selektywny wybór komponentów Inteligentnego ALMM Solvera niezbędnych do rozwiązywania i modelowania problemów. Takie nowatorskie podejście pozwala na dynamiczną budowę algorytmów rozwiązujących problemy optymalizacji dyskretnej. Wykorzystanie wiedzy o właściwościach rozważanych procesów oraz technologii ALMM uniwersalizuje proponowany system KB czyniąc go inteligentnym i wydajnym narzędziem do rozwiązywania zadań optymalizacji dyskretnej. Kluczową zaletą proponowanego podejścia ontologicznego jest możliwość jego elastycznej rozbudowy i rozszerzenia jego zastosowania na inne klasy problemów, które zostały już opisane w technologii ALMM.

Algebraiczno Logiczny Meta Model można wykorzystać m.in. w zagadnieniach optymalizacji dyskretnej, procesach produkcyjnych czy logistycznych. Problem podejmowania decyzji w dynamicznym problemie trasowania pojazdów (DVRP) przedstawiono w [25, 42]. W rozważanym dynamicznym problemie rozważano aspekt dotyczący m.in. dostępności klientów, czasy podróży, obsługi i dostępności pojazdów. Zaproponowano klasyfikację problemu DVRP ze względu na różne elementy powodujące dynamikę rozważanego problemu. W pracy [31] zaproponowano formalne podejście do rozwiązywania problemów harmonogramowania z nieoczekiwanymi zdarzeniami jako rozszerzenie ogólnych ram dla strategii Zero-Defect Manufactu-

ring (ZDM). ZDM ma na celu poprawę wydajności procesu i jakości produktu przy jednoczesnej eliminacji defektów i minimalizacji błędów procesu. Problem cross-docking został zaproponowany w [31], jest to przykład rzeczywistego problemu logistycznego należącego do klasy NP-trudnych problemów optymalizacyjnych. W szczególności rozważano optymalizację sekwencji przychodzących i wychodzących ciężarówek oraz przypisania doków ciężarówek w systemach cross-docking z wieloma bramami przychodzącymi i wychodzącymi. Do rozwiązania tego problemu zaproponowano optymalizację rojem cząstek połączoną z symulowanym wyżarzaniem.

Przedstawiony w niniejszym rozdziale ogólny paradygmat ALMM stanowi podstawę do budowy szczegółowych modeli algebracno-logicznych dedykowanych problemowi harmonogramowania zadań dla floty UAV, które zostaną zaprezentowane w Rozdziale 4. W dostępnej literaturze nie zidentyfikowano podejść wykorzystujących strategię kaskadowego modelowania w ramach paradygmatu ALMM dla tego typu problemów, uwzględniających jednocześnie złożone ograniczenia dynamiczne i operacyjne.

Luka ta stanowi motywację naukowo-badawczą dla niniejszej pracy, w której zaproponowano autorskie modele ALMM (Rozdział 4), odpowiadające im metody i algorytmy rozwiązywania (Rozdział 5), a także przeprowadzono ich weryfikację w drodze symulacji obliczeniowych oraz eksperymentów w środowisku zbliżonym do rzeczywistego (Rozdział 6).

Rozdział 3

Problem harmonogramowania zadań flot UAV w obszarze okołolotniskowym

W niniejszym rozdziale przedstawiono specyfikę rozważanego problemu zarządzania flotą bezzałogowych statków powietrznych realizujących zadania logistyczne w obszarze okołolotniskowym. Analizowany problem dotyczy synchronizacji i harmonogramowania dynamicznie napływających zadań transportowych w warunkach ograniczonej dostępności zasobów, przestrzeni operacyjnej oraz zmieniających się warunków realizacji misji.

Rozdział stanowi warstwę problemową i operacyjną przygotowującą formalizację algebraiczno-logicznego modelu decyzyjnego przedstawionego w kolejnym rozdziale. W tym celu scharakteryzowano podstawowe elementy procesu planowania, obejmujące strukturę zbioru zadań, zasoby UAV, przestrzeń operacyjną modelowaną w postaci grafu destynacji lotniczych, trajektorie realizacji zadań, ograniczenia czasowe wynikające z dostępności slotów oraz mechanizmy zakłóceń wpływających na przebieg procesu decyzyjnego.

Przedstawione w rozdziale elementy odpowiadają kolejnym klasom ograniczeń i mechanizmów uwzględnianych w formalnych modelach ALMM rozwijanych w rozdziale 4. Charakterystyka zasobów UAV stanowi podstawę modelu bazowego ALMM, ograniczenia czasowe slotów prowadzą do rozszerzenia ALMM-TS, ograniczenia przestrzenne i trajektorie realizacji zadań przygotowują model ALMM-CS, parametry czasowe zadań i okna realizacji stanowią podstawę modelu ALMM-TW, natomiast analiza zakłóceń operacyjnych tworzy fundament dynamicznego modelu ALMM-D.


Przedstawione założenia problemowe oraz dane operacyjne stanowią również podstawę do projektowania i walidacji heurystycznych algorytmów harmonogramowania oraz mechanizmów dynamicznej realokacji zadań opisanych w rozdziale 5.

3.1 Charakterystyka problemu harmonogramowania

Rozważany problem dotyczy harmonogramowania dynamicznie napływających zadań logistycznych realizowanych przez flotę bezzałogowych statków powietrznych w obszarze okołolotniskowym. Istotą problemu jest przydział zadań do dostępnych zasobów UAV oraz wyznaczenie tras ich realizacji przy uwzględnieniu

ograniczeń czasowych, przestrzennych i zasobowych. Dynamiczny charakter środowiska powoduje, że pojawianie się nowych zadań oraz zmiany warunków operacyjnych mogą wymagać aktualizacji harmonogramu w trakcie jego realizacji.

Proces realizacji zadań definiowany jest na grafie destynacji lotniczych, którego węzły odpowiadają punktom wykonywania operacji lotniczych, natomiast krawędzie reprezentują dopuszczalne połączenia pomiędzy nimi. Każde zadanie określa trasę lotu obejmującą jedną lub więcej destynacji. Na Rysunku 3.1 przedstawiono schemat funkcjonalny proponowanego systemu planowania zadań dla floty UAV pracującej w warunkach zmiennej dostępności przestrzeni operacyjnej.



Rysunek 3.1: Schemat głównych modułów proponowanego systemu planowania zadań dla UAV

System obejmuje trzy podstawowe bloki funkcjonalne: moduł planistyczno-decyzyjny, moduł kontroli procesu oraz flotę UAV realizującą zadania. Moduł planistyczno-decyzyjny odpowiada za generowanie harmonogramów i ocenę ich wykonalności, moduł kontroli monitoruje przebieg misji i aktualizuje stan systemu, natomiast flota UAV realizuje przydzielone zadania oraz dostarcza informacji zwrotnych o przebiegu operacji.

W rozpatrywanym problemie przyjęto następujące założenia operacyjne:

- Zadania realizowane są przez flotę od 3 do 10 UAV, przy czym jednostki mogą wykonywać zadania równolegle.
- Zdefiniowany jest punkt startowy (baza UAV) oraz graf możliwych destynacji lotniczych.
- Lokalizacja destynacji lotniczych jest znana i stała, natomiast dynamicznie zmienia się zbiór aktywnych zadań oraz dostępność zasobów UAV.
- Nowe zadania pojawiają się dynamicznie i posiadają określony czas realizacji oraz dopuszczalne terminy wykonania (okna czasowe).
- Każde zadanie definiuje trajektorię jednoetapową lub wieloetapową obejmującą jedną lub więcej destynacji lotniczych.
- Każda misja UAV rozpoczyna się i kończy w bazie, zgodnie z koncepcją zamkniętego cyklu operacyjnego.
- Znane są współrzędne węzłów oraz odległości pomiędzy nimi, co umożliwia wyznaczanie trajektorii lotu i czasu przelotu.

- W obszarze operacyjnym występują ograniczenia wynikające z dostępności przestrzeni powietrznej, w tym strefa CTR oraz możliwość wystąpienia czasowych konfliktów z ruchem lotniczym.
- Operacje realizowane są w określonym horyzoncie planowania obejmującym przedział czasowy od 08:00 do 16:00.
- UAV charakteryzują się ograniczeniami eksploatacyjnymi, takimi jak maksymalny czas lotu, prędkość przelotowa, zasięg operacyjny oraz dopuszczalny udźwig.
- Zadania mają charakter niepodzielny (*non-preemptive*), co oznacza, że po rozpoczęciu realizacji nie mogą zostać przerwane.
- Liczba zadań, dostępność zasobów oraz warunki realizacji mogą zmieniać się dynamicznie w czasie rzeczywistym.

Rozważany problem obejmuje kilka współzależnych klas ograniczeń: ograniczenia związane ze strukturą i dynamiką zbioru zadań, dostępnością zasobów UAV, dostępnością przestrzeni powietrznej, ograniczeniami czasowymi oraz zakłóceniami operacyjnymi wpływającymi na przebieg realizacji misji. Opisane założenia wyznaczają wymagania względem modelu decyzyjnego oraz algorytmów harmonogramowania. Model powinien umożliwiać ocenę wykonalności harmonogramów, uwzględnianie zmian dostępności zasobów i przestrzeni operacyjnej oraz rekonfigurację planu realizacji zadań po wystąpieniu zakłóceń. Wzrost liczby zadań, zasobów UAV oraz ograniczeń czasowo-przestrzennych prowadzi do gwałtownego wzrostu liczby możliwych wariantów decyzyjnych. Rozważany problem ma charakter kombinatoryczny i należy do klasy problemów NP-trudnych (*NP-hard*), co uzasadnia zastosowanie formalnego modelu decyzyjnego oraz heurystycznych procedur harmonogramowania i rekonfiguracji przedstawionych w dalszej części pracy.

3.2 Charakterystyka zasobów UAV

W rozważanym problemie zasobami realizującymi zadania są bezzałogowe statki powietrzne, które stanowią elementy zbioru zasobów dostępnych w procesie harmonogramowania. Każda jednostka UAV traktowana jest jako niezależny zasób operacyjny, którego aktualny stan oraz parametry eksploatacyjne determinują możliwość realizacji określonych zadań i wpływają na zbiór decyzji dopuszczalnych w kolejnych etapach procesu planowania.

Z punktu widzenia modelu harmonogramowania UAV charakteryzowany jest przez zbiór parametrów determinujących jego zdolność do wykonania zadania. Parametry te wpływają zarówno na ocenę wykonalności zadania, jak i na wybór zasobu w procesie przydziału oraz dynamicznej realokacji. Do podstawowych parametrów zasobu należą:

- zasięg operacyjny – maksymalna odległość realizacji misji wynosząca 15 km, ograniczająca możliwość realizacji wybranych trajektorii lotu,
- prędkość przelotowa – parametr wpływający na czas realizacji zadania oraz estymację czasu przelotu pomiędzy punktami:

- maksymalna: 19 m/s,
 - minimalna: 5.56 m/s,
 - średnia operacyjna: 11.11 m/s,
- czas operacyjny – maksymalny czas ciągłej realizacji misji wynoszący 30 minut, determinujący dopuszczalny czas wykonania zadania,
 - udźwig operacyjny – maksymalna masa transportowanego ładunku do 1 kg, wpływająca na możliwość realizacji określonych klas zadań.


W procesie harmonogramowania każdy UAV traktowany jest jako zasób o dynamicznie zmieniającej się dostępności. Możliwość realizacji zadania zależy od zgodności parametrów zadania z parametrami eksploatacyjnymi UAV, w szczególności od długości planowanej trajektorii, przewidywanego czasu realizacji, wymaganej masy transportowanego ładunku oraz aktualnej dostępności jednostki w horyzoncie planowania. W trakcie realizacji procesu UAV może przechodzić pomiędzy stanami dostępności, zajętości lub chwilowej niedostępności wynikającej z ograniczeń operacyjnych albo zakłóceń, a po ustaniu tych ograniczeń ponownie zostać włączony do zbioru zasobów dostępnych do planowania.

Z punktu widzenia formalizacji procesu decyzyjnego parametry oraz stany operacyjne UAV wyznaczają zbiór decyzji dopuszczalnych w kolejnych etapach harmonogramowania. Charakterystyka zasobów stanowi zatem podstawę definiowania ograniczeń modelu, oceny wykonalności harmonogramów oraz procedur dynamicznej realokacji zadań przedstawionych w dalszej części pracy.

3.3 Charakterystyka destynacji lotniczych

W rozważanym problemie przestrzeń realizacji zadań modelowana jest w postaci ważonego grafu destynacji lotniczych $G = (V, E, w)$, gdzie V oznacza zbiór węzłów odpowiadających punktom realizacji operacji lotniczych, E jest zbiorem dopuszczalnych połączeń pomiędzy węzłami, natomiast w jest funkcją wag przypisującą każdej krawędzi wartość odpowiadającą odległości pomiędzy punktami. Wagi krawędzi wyrażone są w kilometrach i stanowią podstawę do wyznaczania trajektorii lotu, estymacji czasu realizacji zadań oraz oceny wykonalności decyzji planistycznych w procesie harmonogramowania.

Na Rysunek 3.2 przedstawiono przykładowy graf destynacji lotniczych obejmujący punkt bazowy UAV Base oraz punkty docelowe oznaczone jako $A - G$. Każdy węzeł grafu reprezentuje potencjalne miejsce realizacji zadania transportowego, natomiast połączenia pomiędzy węzłami definiują możliwe trajektorie przemieszczania się UAV. Z punktu widzenia procesu decyzyjnego struktura grafu definiuje zbiór dopuszczalnych relacji przestrzennych pomiędzy punktami realizacji zadań i tym samym ogranicza zbiór możliwych decyzji planistycznych.



Rysunek 3.2: Graf destynacji lotniczych

Graf destynacji opisany jest za pomocą macierzy sąsiedztwa (Tabela 3.1), w której wartości wag odpowiadają odległościom pomiędzy poszczególnymi punktami węzłowymi. Macierz ta stanowi podstawę wyznaczania długości trajektorii lotu, estymacji czasu przelotu pomiędzy punktami oraz oceny wykonalności harmonogramu z uwzględnieniem ograniczeń operacyjnych zasobów UAV.


Tabela 3.1: Macierz sąsiedztwa rozważanego problemu

	UAV Base	A	B	C	D	E	F	G
UAV BASE	0,00	5,44	3,57	2,99	1,35	2,31	6,89	6,82
A	5,44	0,00	3,70	3,62	5,97	3,14	11,30	12,15
B	3,57	3,70	0,00	4,29	3,23	2,59	10,46	10,12
C	2,99	3,62	4,29	0,00	4,17	1,71	7,69	8,92
D	1,35	5,97	3,23	4,17	0,00	3,06	7,67	6,90
E	2,31	3,14	2,59	1,71	3,06	0,00	8,53	9,03
F	6,89	11,30	10,46	7,69	7,67	8,53	0,00	3,85
G	6,82	12,15	10,12	8,92	6,90	9,03	3,85	0,00

Z punktu widzenia planowania misji wartości wag przypisane krawędziom grafu wpływają bezpośrednio na czas realizacji zadania, czas zajętości zasobu UAV oraz możliwość uznania danej trajektorii za wykonalną. Wzrost długości odcinków pomiędzy punktami węzłowymi prowadzi do zwiększenia czasu realizacji

zadania, ograniczenia dostępności zasobu oraz może powodować odrzucenie niektórych wariantów planu na etapie oceny decyzji dopuszczalnych.

Ze względu na konieczność wielokrotnego generowania instancji problemowych o różnych konfiguracjach przestrzennych opracowano pomocnicze narzędzie UAV Graph Generator, wspierające proces definiowania grafów destynacji lotniczych. Narzędzie umożliwia wyznaczanie punktów węzłowych, generowanie połączeń pomiędzy nimi oraz automatyczne tworzenie macierzy sąsiedztwa wykorzystywanych w procesie harmonogramowania misji UAV. Narzędzie wspiera również analizę wykonalności przestrzennej planowanych trajektorii oraz ocenę poprawności struktury grafu przed rozpoczęciem procesu planowania. Przykład wykorzystania narzędzia do generowania instancji grafu destynacji lotniczych wraz z odpowiadającą mu macierzą sąsiedztwa i macierzą relacji przedstawiono na Rysunku 3.3.



Rysunek 3.3: Narzędzie wspomagające definiowanie grafów destynacji lotniczych wykorzystywanych w badaniach eksperymentalnych

Istotnym elementem modelu przestrzeni operacyjnej jest możliwość występowania konfliktów przestrzennych i czasowych wynikających z równoczesnego wykorzystania tych samych obszarów lub korytarzy lotniczych przez wiele jednostek UAV. W takich przypadkach struktura grafu oraz dostępność jego elementów mogą wpływać na konieczność zmiany trajektorii, przesunięcia realizacji zadania lub odrzucenia określonych wariantów planu.

W warunkach dynamicznie zmieniającego się środowiska operacyjnego dostępność wybranych punktów lub połączeń pomiędzy nimi może ulegać czasowym zmianom na skutek ograniczeń przestrzennych,

konfliktów ruchu lotniczego lub zakłóceń operacyjnych. Wpływa to bezpośrednio na proces wyznaczania trajektorii oraz może wymagać dynamicznej rekonfiguracji planu realizacji zadań.

Przedstawiony model przestrzeni operacyjnej stanowi podstawę formalnego opisu trajektorii realizacji zadań, estymacji czasu przelotu pomiędzy punktami, oceny wykonalności decyzji planistycznych oraz dynamicznej rekonfiguracji harmonogramu w procesie przydziału i realokacji zadań realizowanych przez flotę UAV.

3.4 Charakterystyka trajektorii realizacji zadań

Z punktu widzenia planowania misji zadania realizowane przez flotę UAV mogą przyjmować postać trajektorii jednoetapowych lub wieloetapowych. Trajektorja jednoetapowa obejmuje pojedynczy punkt docelowy oraz powrót do punktu bazowego, natomiast trajektorja wieloetapowa definiuje sekwencję kolejnych punktów realizacji zadania przed powrotem UAV do bazy. Liczba odwiedzanych węzłów, długość trajektorii oraz liczba segmentów lotu wpływają bezpośrednio na czas zajętości zasobu UAV, ocenę wykonalności zadania oraz możliwość jego realizacji w ramach przyjętego horyzontu planowania. Przykładowe klasy trajektorii przedstawiono w Tabeli 3.2.

Tabela 3.2: Trajektorie lotu dla rozważanych klas trajektorii

Klasa trajektorii	Lp. węzłów i trajektoria	Liczba etapów	Etapy zadania (S/F/L)
Jednoetapowa	1; UAV Base $\rightarrow$ A $\rightarrow$ UAV Base	$2 \times (S - F - L)$	UAV Base: S - F $\rightarrow$ A: L; A: S - F $\rightarrow$ UAV Base: L
Wieloetapowa	2; UAV Base $\rightarrow$ A $\rightarrow$ B $\rightarrow$ UAV Base	$3 \times (S - F - L)$	UAV Base: S - F $\rightarrow$ A: L; A: S - F $\rightarrow$ B: L; B: S - F $\rightarrow$ UAV Base: L
Wieloetapowa	3; UAV Base $\rightarrow$ A $\rightarrow$ B $\rightarrow$ C $\rightarrow$ UAV Base	$4 \times (S - F - L)$	UAV Base: S - F $\rightarrow$ A: L; A: S - F $\rightarrow$ B: L; B: S - F $\rightarrow$ C: L; C: S - F $\rightarrow$ UAV Base: L

Legenda: S – start (*take off*), F – przelot (*flight*), L – lądowanie (*landing*). Zapis „ $k \times (S-F-L)$ ” oznacza liczbę pełnych cykli faz lotu pomiędzy kolejnymi punktami trajektorii.

Czas realizacji trajektorii wyznaczany jest na podstawie sumy czasów poszczególnych segmentów lotu, obejmujących fazę startu, przeloty pomiędzy kolejnymi punktami trajektorii oraz lądowanie. W przypadku trajektorii wieloetapowych zależy on od liczby odwiedzanych punktów, długości segmentów oraz parametrów ruchu UAV. Do estymacji czasu realizacji trajektorii przyjęto parametry ruchu UAV zestawione w Tabeli 3.4. Parametry te wykorzystywane są w procesie wyznaczania czasu przelotu dla poszczególnych segmentów trajektorii, oceny wykonalności zadania oraz estymacji czasu zajętości zasobu w procesie harmonogramowania.

Tabela 3.4: Parametry ruchu UAV wykorzystywane do estymacji czasu realizacji trajektorii

Parametr ruchu	Wartość	Zastosowanie
Prędkość wznoszenia	2.78 m/s	Faza startu
Prędkość lądowania	2.78 m/s	Faza końcowa
Minimalna prędkość przelotowa	5.56 m/s	Warunek brzegowy / lot zachowawczy
Średnia prędkość przelotowa	11.11 m/s	Estymacja czasu realizacji zadania
Maksymalna prędkość przelotowa	19.00 m/s	Górne ograniczenie operacyjne
Standardowa wysokość lotu	50 m AGL	Realizacja segmentów przelotowych

W modelu harmonogramowania trajektoria determinuje czas zajętości zasobu UAV oraz stanowi podstawę oceny wykonalności przydziału zadania. O dopuszczalności trajektorii decydują jej długość, liczba segmentów lotu, wymagany czas realizacji oraz dostępność przestrzeni powietrznej.

Istotnym elementem oceny trajektorii jest również możliwość wystąpienia konfliktów przestrzennych i czasowych związanych z równoczesną realizacją misji przez wiele jednostek UAV. Nakładanie się trajektorii w tym samym przedziale czasowym, ograniczona dostępność przestrzeni powietrznej lub czasowe zamknięcie wybranych korytarzy lotniczych mogą prowadzić do konieczności odrzucenia trajektorii, zmiany kolejności realizacji zadania lub wyboru alternatywnego wariantu planu.

W warunkach dynamicznie zmieniającego się środowiska operacyjnego trajektoria zadania może podlegać rekonfiguracji na skutek wystąpienia zakłóceń, zmian dostępności zasobów lub ograniczeń przestrzennych. W takich przypadkach konieczne może być ponowne wyznaczenie trasy, zmiana kolejności realizacji segmentów zadania lub dynamiczna realokacja zadania do innej jednostki UAV. Mechanizmy te mają kluczowe znaczenie z punktu widzenia adaptacyjnego harmonogramowania oraz utrzymania poprawności procesu decyzyjnego w warunkach zakłóceń. Przedstawiona charakterystyka trajektorii stanowi podstawę formalizacji procesu realizacji zadań w kolejnych modelach algebraiczno-logicznych. Parametry trajektorii wykorzystywane są do wyznaczania czasu realizacji zadań, estymacji zajętości zasobów UAV, oceny wykonalności decyzji planistycznych oraz dynamicznej rekonfiguracji harmonogramu.

3.5 Charakterystyka slotów

W obszarach kontrolowanej przestrzeni powietrznej dostępność korytarzy lotniczych oraz stref operacyjnych UAV może być ograniczona do określonych przedziałów czasowych wynikających z organizacji ruchu lotniczego. Przedziały te modelowane są w pracy za pomocą slotów czasowych. W rozważanym problemie sloty nie są przypisywane na stałe do poszczególnych jednostek UAV, lecz stanowią zasób wspólny, z którego może korzystać dowolny UAV pod warunkiem spełnienia ograniczeń czasowych oraz operacyjnych. Z punktu widzenia procesu harmonogramowania slot definiuje dopuszczalny przedział czasowy realizacji zadania, a jego długość wpływa bezpośrednio na możliwość uznania trajektorii za wykonalną.

W projektowanym modelu slot jest przedziałem czasu zdefiniowanym przez podanie czasu początkowego B^r i końcowego F^r :

$$slot_r \stackrel{def}{=} [B^r, F^r] \quad (3.1)$$

gdzie B^r i F^r określają odpowiednio początek i koniec r -tego slotu. Długość slotu wyrażona jest jako:


$$|slot_r| = |F^r - B^r| \quad (3.2)$$

i stanowi podstawowy parametr wykorzystywany do oceny możliwości realizacji zadania w danym przedziale czasowym.

Z punktu widzenia procesu decyzyjnego trajektoria może zostać przypisana do slotu wyłącznie wtedy, gdy przewidywany czas realizacji zadania nie przekracza czasu dostępności slotu. Warunek ten można zapisać jako:

$$\tau_{traj} \leq |slot_r| \quad (3.3)$$

Oznacza to, że długość slotu stanowi bezpośrednie ograniczenie dopuszczalności decyzji planistycznej oraz wpływa na zbiór decyzji dopuszczalnych w procesie harmonogramowania. Na Rysunku 3.4 przedstawiono schemat zasobów obejmujących dostępność slotów.



Rysunek 3.4: Schemat zasobów wspólnych w rozważanym problemie

Zbiór wszystkich slotów dostępnych w chwili początkowej procesu t_0 definiowany jest jako:

$$Slots(t_0) = \bigcup_{r=1}^{ILs} slot_r \quad (3.4)$$

gdzie:

$$ILs = |Slots(t_0)| \quad (3.5)$$

oznacza liczbę dostępnych slotów w chwili początkowej.

Ponieważ zbiór slotów zmienia się w miarę upływu czasu, wprowadzamy pojęcie dynamicznego slotu $slot_r(t)$, którego postać zależy od aktualnej chwili procesu:

$$slot_r(t) = [B^r, F^r] \quad \text{dla} \quad t < B^r \quad (3.6)$$

$$slot_r(t) = [t, F^r] \quad \text{dla} \quad B^r \leq t < F^r \quad (3.7)$$

$$slot_r(t) = \emptyset \quad \text{dla} \quad t \geq F^r \quad (3.8)$$

Zbiór wszystkich dostępnych slotów w chwili t opisany jest zależnością:


$$Slots(t) = \bigcup_{r=1}^{ILs} slot_r(t) \quad (3.9)$$

Dopełnienie zbioru dostępnych slotów w analizowanym horyzoncie planowania definiuje zbiór antyslotów (n_slot_r) reprezentujących okresy niedostępności przestrzeni operacyjnej. Są to przedziały czasowe,

w których realizacja misji UAV nie jest dopuszczalna ze względu na ograniczenia operacyjne przestrzeni powietrznej. Zbiór tych przedziałów opisuje równanie:

$$N_Slots = \bigcup_{r=1}^{ILs} n_slot_r \quad (3.10)$$


Schemat antysłota przedstawiono na Rysunku 3.5.




Rysunek 3.5: Schemat przydziału czasowego antysłota

Z punktu widzenia modelu harmonogramowania sloty oraz antysloty wyznaczają strukturę czasowej dostępności przestrzeni operacyjnej. Ograniczenia te wpływają bezpośrednio na możliwość przypisania trajektorii do zasobu UAV, ocenę wykonalności decyzji oraz konieczność dynamicznej rekonfiguracji planu w przypadku zmian dostępności przestrzeni lotniczej.

W celu przeprowadzenia analizy rzeczywistej dostępności slotów wykorzystano dane operacyjne udostępnione przez PANSA dla lotniska EPRZ Jasionka. Dane obejmowały wybrane dni z różnych okresów roku, co umożliwiło analizę zmienności dostępności slotów w przedziale operacyjnym UAV (08:00–16:00). Dla przykładowego dnia referencyjnego 18.07.2023 zidentyfikowano 15 przedziałów wolnych oraz 15 przedziałów zajętych. Łączny czas dostępności przestrzeni operacyjnej wyniósł 04:59:59, natomiast łączny czas zajętości 03:10:59. Najdłuższy slot wolny miał długość 00:54:59, natomiast najkrótsze sloty wolne wynosiły 00:03:59. Średni czas trwania slotu wolnego wyniósł 00:19:59, co wskazuje na istotną fragmentację dostępnej przestrzeni operacyjnej pomimo relatywnie wysokiego łącznego czasu dostępności. Wizualizacje rozkładu slotów dla wybranych dni przedstawiono na Rysunkach 3.6–3.7.



Rysunek 3.6: Wizualizacja slotów wolnych i zajętych lipiec 2023



Rysunek 3.7: Wizualizacja slotów wolnych i zajętych listopad 2024

Tabela 3.5 przedstawia zbiorcze charakterystyki dostępności slotów dla wybranych dni, obejmujące liczbę przedziałów wolnych i zajętych, ich łączny czas, wartości minimalne i maksymalne oraz średni czas trwania slotów. Parametry te stanowią podstawę oceny stopnia fragmentacji dostępnej przestrzeni operacyjnej oraz wpływają bezpośrednio na wykonalność trajektorii w procesie harmonogramowania.

Tabela 3.5: Charakterystyka dostępności slotów w wybranych dniach


Dzień	Ilość slotów		Łączny czas slotów		Czas slotów wolnych		Czas slotów zajętych		Średni czas slotów	
	wolnych	zajętych	wolnych	zajętych	max	min	max	min	wolnych	zajętych
18.07.2023	15	15	04:59:59	03:10:59	00:54:59	00:03:59	00:21:00	00:05:59	00:19:59	00:12:43
19.07.2023	17	17	04:31:00	03:39:59	00:29:00	00:03:59	00:30:59	00:10:59	00:15:56	00:12:56
20.07.2023	10	11	05:10:00	03:00:59	01:06:00	00:08:59	00:46:00	00:10:59	00:31:00	00:16:27
24.07.2023	17	17	04:29:59	03:41:00	00:29:00	00:26:00	00:03:59	00:05:59	00:15:52	00:13:00
25.07.2023	16	16	04:44:59	03:26:00	00:46:59	00:21:00	00:02:59	00:05:59	00:17:48	00:12:52
26.07.2023	15	15	04:17:00	03:53:59	00:35:00	00:02:59	00:32:00	00:10:59	00:17:08	00:15:35
19.11.2024	15	15	04:48:00	03:22:59	00:58:59	00:02:00	00:26:00	00:05:59	00:19:12	00:13:31
20.11.2024	12	12	05:32:00	02:38:59	01:09:00	00:03:59	00:21:59	00:10:59	00:27:40	00:13:14
21.11.2024	10	10	06:06:00	02:04:59	01:45:00	00:06:00	00:25:59	00:10:59	00:36:36	00:12:29
22.11.2024	14	14	05:37:00	02:33:59	01:04:00	00:03:59	00:15:59	00:05:59	00:24:04	00:10:59

Czas slotów podawany jest w formacie HH:MM:SS (godziny:minuty:sekundy). Zestawienie obejmuje liczbę slotów wolnych i zajętych, ich łączny czas, wartości minimalne i maksymalne oraz średni czas trwania w analizowanych dniach. Liczba slotów wolnych i zajętych jest sobie równa w większości analizowanych przypadków, natomiast różnica występująca w dniu 20.07.2023 wynika z rzeczywistej struktury danych operacyjnych pozyskanych z PANSA.

Na podstawie przeprowadzonej analizy można zauważyć, że dostępność slotów czasowych charakteryzuje się istotną zmiennością zarówno pod względem liczby dostępnych przedziałów, jak i ich długości. W analizowanych dniach występowały zarówno krótkie sloty ograniczające możliwość realizacji zadań, jak również dłuższe przedziały umożliwiające elastyczne planowanie trajektorii wieloetapowych.

Z punktu widzenia procesu harmonogramowania kluczowe znaczenie ma nie tylko łączny czas dostępności przestrzeni, lecz również struktura czasowa slotów obejmująca ich długość, rozkład w czasie oraz występowanie antyslotów. Duża fragmentacja dostępnych slotów może prowadzić do ograniczenia liczby trajektorii możliwych do realizacji, nawet przy relatywnie wysokim łącznym czasie dostępności. Z kolei obecność długich, ciągłych slotów zwiększa możliwość realizacji zadań wieloetapowych oraz poprawia elastyczność procesu planowania.

Na Rysunkach 3.8–3.9 przedstawiono długości dostępnych slotów uporządkowane malejąco, co pozwala na ocenę potencjalnej elastyczności procesu planowania. Dłuższe sloty zwiększają możliwość realizacji zadań wieloetapowych, natomiast przewaga krótkich slotów sprzyja realizacji zadań krótszych lub wymaga dynamicznej rekonfiguracji harmonogramu.



Rysunek 3.8: Czasy dostępności slotów w dniu 18.07.2023



Rysunek 3.9: Czasy dostępności slotów w dniu 22.11.2024

Przeprowadzona analiza potwierdza, że sloty czasowe stanowią kluczowy element ograniczający proces harmonogramowania flot UAV, wpływając bezpośrednio na wykonalność trajektorii, dostępność zasobów, filtrację zbioru decyzji dopuszczalnych oraz konieczność dynamicznej realokacji zadań w warunkach zmiennej dostępności przestrzeni operacyjnej.

3.6 Charakterystyka danych dotyczących zadań lotniczych


W rozważanym problemie podstawową jednostkę pracy systemu stanowi zadanie lotnicze realizowane przez flotę UAV. Każde zadanie reprezentuje pojedynczą operację transportową wymagającą przypisania do odpowiedniego zasobu UAV, wyznaczenia trajektorii realizacji oraz uwzględnienia ograniczeń czasowych wynikających z dostępności slotów operacyjnych. Z punktu widzenia procesu harmonogramowania zadanie stanowi element zbioru zadań wejściowych, którego charakterystyka wpływa bezpośrednio na strukturę procesu decyzyjnego oraz wykonalność harmonogramu.

W modelu zadanie lotnicze opisane jest przez zestaw parametrów obejmujących przede wszystkim przewidywany czas realizacji, termin przydatności (*due time*), lokalizację destynacji docelowej oraz wynikającą z niej trajektorię realizacji. Parametry te determinują zarówno możliwość przypisania zadania do zasobu UAV, jak również wpływają na ocenę wykonalności decyzji planistycznych oraz konieczność uwzględnienia ograniczeń czasowo-przestrzennych w procesie harmonogramowania.

Istotnym elementem modelowania danych zadaniowych jest zróżnicowanie czasów realizacji poszczególnych zadań. W praktyce system może być obciążony zadaniami krótkimi, średnimi oraz długimi, których udział ilościowy może się zmieniać w zależności od charakteru scenariusza operacyjnego. Struktura rozkładu czasów realizacji zadań wpływa bezpośrednio na poziom obciążenia systemu, efektywność wykorzystania slotów czasowych oraz skuteczność stosowanych algorytmów harmonogramowania.


W celu modelowania zróżnicowanych scenariuszy obciążenia systemu wykorzystano rozkłady probabilistyczne umożliwiające generowanie zestawów zadań o różnych profilach czasowych. Zastosowano między innymi funkcje sigmoidalne, rozkłady Gaussa, wykładnicze, logarytmiczne oraz inne funkcje histogramowe pozwalające modelować scenariusze zdominowane przez zadania krótkie, zadania długie lub mieszane profile obciążenia systemu. Dzięki temu możliwe jest odwzorowanie zarówno scenariuszy o niskim obciążeniu operacyjnym, jak również warunków intensywnej eksploatacji systemu wymagających dynamicznego podejmowania decyzji planistycznych.

W celu generowania reprezentatywnych instancji problemowych wykorzystanych w badaniach eksperymentalnych opracowano pomocnicze narzędzie AeroTask Generator. Narzędzie umożliwia tworzenie zbiorów zadań o kontrolowanej strukturze czasów realizacji oraz analizę ich właściwości statystycznych. Przykładowy zbiór wygenerowanych zadań wraz z charakterystyką ich rozkładu czasowego oraz podstawowymi statystykami przedstawiono na Rysunku 3.10. Wizualizacja ta prezentuje sposób generowania danych wejściowych wykorzystywanych w procesie walidacji modeli harmonogramowania flot UAV.




Rysunek 3.10: Narzędzie generowania instancji zadaniowych wykorzystywanych w badaniach eksperymentalnych

W celu odwzorowania różnych poziomów obciążenia systemu wykorzystano kilka klas rozkładów czasów realizacji zadań, odpowiadających odmiennym profilom napływu zleceń logistycznych. Na Rysunkach 3.11 oraz 3.12 przedstawiono przykładowe profile rozkładów czasów realizacji zadań uzyskane odpowiednio dla funkcji sigmoidalnej oraz rozkładu Gaussa. Rozkłady te pozwalają modelować różne scenariusze obciążenia systemu, wpływając bezpośrednio na strukturę zbioru zadań wejściowych oraz trudność problemu harmonogramowania.



Rysunek 3.11: Przykładowe uzyskane wyniki dla funkcji sigmoidalnej



Rysunek 3.12: Przykładowe uzyskane wyniki dla funkcji Gaussa

Z punktu widzenia procesu harmonogramowania różne profile czasów realizacji zadań prowadzą do odmiennych struktur obciążenia systemu. Oznacza to, że identyczna konfiguracja zasobów UAV i slotów czasowych może prowadzić do istotnie różnej liczby decyzji dopuszczalnych oraz odmiennych poziomów wykorzystania zasobów w zależności od struktury czasowej zbioru zadań. Scenariusze zdominowane przez zadania krótkie zwiększają liczbę możliwych przydziałów w krótkich slotach, natomiast obecność większej liczby zadań długich może prowadzić do wzrostu konkurencji o zasoby oraz zwiększenia ryzyka odrzucenia części trajektorii ze względu na ograniczenia czasowe.

Wygenerowane zestawy danych zadaniowych stanowią podstawę walidacji modeli formalnych przedstawionych w rozdziale 4 oraz testowania algorytmów harmonogramowania opisanych w rozdziale 5. Dzięki możliwości generowania zróżnicowanych scenariuszy obciążenia systemu możliwa jest ocena skuteczno-

ści algorytmów w warunkach zmiennej struktury zadań, ograniczonej dostępności slotów oraz dynamicznie zmieniających się warunków operacyjnych.

3.7 Charakterystyka zakłóceń

W rozważanym problemie dynamicznego harmonogramowania flot UAV zakłócenia stanowią zdarzenia powodujące zmianę warunków realizacji procesu decyzyjnego w trakcie trwania misji. Ich wystąpienie prowadzi do modyfikacji bieżącego stanu systemu, zmiany zbioru decyzji dopuszczalnych oraz konieczności rekonfiguracji harmonogramu. Z punktu widzenia technologii algebraiczno-logicznego meta-modelowania zakłócenie jest zdarzeniem dynamicznym powodującym zmianę postaci procesu decyzyjnego poprzez modyfikację przestrzeni stanów oraz zbioru dostępnych decyzji.

Formalnie zakłócenie można interpretować jako przejście:

$$s(t) \rightarrow s'(t) \quad (3.11)$$

które powoduje zmianę zbioru decyzji dopuszczalnych:

$$U_d(s) \rightarrow U_d(s') \quad (3.12)$$

oraz może prowadzić do zmiany warunków realizacji funkcji przejścia procesu decyzyjnego.

W skrajnych przypadkach zakłócenie może powodować przejście procesu do stanów niedopuszczalnych S_N , co wymaga uruchomienia procedur rekonfiguracji harmonogramu i ponownego wyznaczenia trajektorii realizacji zadań. W rozważanym problemie wyróżniono trzy podstawowe klasy zakłóceń:


- zakłócenia przestrzenne – wynikające z dynamicznych zmian w dostępności trajektorii operacyjnych lub fragmentów przestrzeni lotniczej (np. czasowa niedostępność wybranych trajektorii realizacji zadań, strefy zabronione, warunki pogodowe, loty uprzywilejowane),
- zakłócenia zasobowe – związane z nagłą niedostępnością jednostek UAV (np. awarie, utrata łączności, krytyczne parametry lotu, konieczność wycofania z operacji),
- zakłócenia zadaniowe – wynikające z dynamicznych zmian w zbiorze zadań (np. anulowanie zadania, pojawienie się zadania priorytetowego, zmiana parametrów realizacji).

Zakłócenia te stanowią podstawowy mechanizm dynamicznej zmiany procesu decyzyjnego i są kluczowym elementem modelu ALMM-D przedstawionego w rozdziale 4.

Zakłócenia przestrzenne i trajektorie operacyjne

W rozważanym problemie trajektorie realizacji zadań modelowane są jako połączenia pomiędzy punktami węzłowymi grafu destynacji lotniczych. Każde połączenie reprezentuje możliwą drogę realizacji zadania przez UAV i stanowi element przestrzeni decyzyjnej systemu.

Zakłócenie przestrzenne polega na czasowej lub trwałej niedostępności wybranego fragmentu trajektorii operacyjnej, co prowadzi do konieczności modyfikacji aktualnego planu realizacji misji. W ujęciu modelowym oznacza to ograniczenie zbioru trajektorii dopuszczalnych oraz zmianę przestrzeni decyzji możliwych do realizacji. Przykładową trajektorię operacyjną w grafie destynacji lotniczych przedstawiono na Rysunku 3.13.



Rysunek 3.13: Przykładowa przestrzeń trajektorii operacyjnych podlegających ograniczeniom przestrzennym

Ważnym ograniczeniem realizacji lotów jest konieczność zachowania separacji przestrzennej pomiędzy jednostkami UAV. W modelu przyjęto, że średnica UAV opisana jest zależnością:

$$d_{UAV} = 2r_{UAV} \quad (3.13)$$


Minimalna rezerwa bezpieczeństwa wokół UAV określona jest jako:

$$d_r = 2(r_{UAV} + x) \quad (3.14)$$

gdzie x oznacza dodatkowy margines bezpieczeństwa. Operacyjna separacja przestrzenna przyjmowana w modelu opisana jest zależnością:

$$sep = d_r \cdot f_s \quad (3.15)$$

gdzie f_s jest przyjętym w modelu współczynnikiem bezpieczeństwa zależnym od typu UAV oraz charakteru realizowanej misji. Na Rysunku 3.14 przedstawiono schemat separowalności UAV.



Rysunek 3.14: Schemat separowalności UAV

Naruszenie warunków separacji lub czasowa niedostępność fragmentów trajektorii prowadzi do wystąpienia zakłóceń przestrzennych, które powodują ograniczenie zbioru decyzji dopuszczalnych oraz konieczność dynamicznego wyznaczenia alternatywnej trajektorii. Przyjęte zależności mają charakter modelowy i służą do wyznaczania minimalnej strefy bezpieczeństwa wymaganej do jednoczesnej realizacji operacji przez wiele jednostek UAV.

Zakłócenia operacyjne związane z zasobami i zadaniami

Zakłócenia zasobowe związane są bezpośrednio z dynamiczną zmianą dostępności jednostek UAV wchodzących w skład systemu operacyjnego. Zakłócenia te prowadzą do zmiany postaci wektora stanu $s \in S$ w trakcie trwania procesu decyzyjnego i mogą wpływać zarówno na bieżące przydziały zadań, jak i na kolejne decyzje dotyczące alokacji zasobów. Najczęstszymi przyczynami zakłóceń zasobowych są:

- awarie techniczne UAV,
- utrata łączności,
- przekroczenie krytycznych parametrów operacyjnych,
- konieczność wycofania jednostki z operacji.

Zakłócenia zadaniowe dotyczą natomiast dynamicznych zmian w zbiorze realizowanych zadań. W ujęciu formalnym mogą być interpretowane jako modyfikacja zbioru zadań:

$$J \rightarrow J' \quad (3.16)$$

Zakłócenia te obejmują:

- anulowanie zadania,
- pojawienie się nowych zadań priorytetowych,
- zmianę parametrów realizacji zadania.

W modelu algebraiczno-logicznym zakłócenia zasobowe i zadaniowe prowadzą bezpośrednio do aktualizacji przestrzeni decyzji dopuszczalnych, modyfikacji stanu procesu oraz zmiany trajektorii możliwych do realizacji.

W przypadku wykrycia zakłócenia system uruchamia procedurę dynamicznej rekonfiguracji harmonogramu, która obejmuje:

- identyfikację elementów dotkniętych zakłóceniem,
- aktualizację stanu systemu,
- ponowne wyznaczenie zbioru decyzji dopuszczalnych,
- realokację zadań lub wyznaczenie alternatywnych trajektorii.

Zakłócenia stanowią zatem kluczowy mechanizm dynamicznej rekonfiguracji procesu decyzyjnego i są podstawą formalnego modelu ALMM-D oraz algorytmów dynamicznej realokacji przedstawionych odpowiednio w rozdziale 4 i 5.

Rozdział 4

Modele ALMM dla harmonogramowania zadań operacyjnych dla floty UAV

W niniejszym rozdziale przedstawiono formalizację problemu harmonogramowania zadań operacyjnych dla floty bezzałogowych statków powietrznych (UAV) w oparciu o paradygmat algebraiczno-logicznego meta-modelu (ALMM). Zaproponowane podejście umożliwia opis procesu harmonogramowania jako dyskretnego procesu decyzyjnego, w którym kolejne decyzje podejmowane są w zależności od aktualnego stanu systemu oraz dostępności zasobów.

Modele konstruowane są w sposób kaskadowy, poprzez sukcesywne wprowadzanie kolejnych ograniczeń operacyjnych oraz rozszerzeń struktury procesu. Każdy kolejny model stanowi uściślenie modelu poprzedniego, prowadząc do zawężenia zbioru decyzji dopuszczalnych oraz zbioru osiągalnych trajektorii procesu. Takie podejście pozwala na stopniową analizę wpływu poszczególnych ograniczeń na strukturę procesu harmonogramowania. W rozdziale wyróżniono następujące warianty modelu:

- **ALMM** – model bazowy, definiujący strukturę procesu decyzyjnego bez dodatkowych ograniczeń operacyjnych,
- **ALMM-TS** – model uwzględniający ograniczenia dostępności czasowej UAV (ang. Time Slots),
- **ALMM-CS** – model rozszerzony o ograniczenia dostępności korytarzy powietrznych (ang. Corridor Sharing),
- **ALMM-TW** – model uwzględniający okna czasowe realizacji zadań (ang. Time Windows),
- **ALMM-D** – model dynamiczny, rozszerzony o zakłócenia wpływające na przebieg procesu harmonogramowania.

W każdym z modeli szczegółowo definiowane są struktura stanu, zbiór decyzji możliwych i dopuszczalnych, funkcja przejścia oraz zbiory stanów niedopuszczalnych i docelowych. Rozszerzenia modeli obejmują zarówno ograniczenia egzogeniczne, wynikające z dostępności zasobów i środowiska operacyjnego, jak i elementy endogeniczne, związane z dynamiką procesu i jego ewolucją w czasie.

Zwieńczeniem rozdziału jest sformułowanie zadania optymalizacji, w którym proces harmonogramowania interpretowany jest jako przeszukiwanie przestrzeni trajektorii dopuszczalnych w celu wyznaczenia

rozwiązania optymalnego względem przyjętego kryterium jakości. Przyjęta postać kryterium umożliwia jego addytywną i separowalną reprezentację, co stanowi podstawę do zastosowania efektywnych metod optymalizacji dyskretnych procesów decyzyjnych.

Przedstawiona kaskada modeli stanowi spójne i systematyczne ujęcie problemu harmonogramowania UAV, umożliwiające zarówno analizę wpływu poszczególnych ograniczeń, jak i budowę algorytmów adaptacyjnych odpornych na zmienność warunków operacyjnych.

4.1 Model bazowy ALMM harmonogramowania zadań dla floty UAV

W niniejszym podrozdziale przedstawiono bazowy model procesu harmonogramowania zadań dla floty UAV w ujęciu algebraiczno-logicznego modelu ALMM. Model ten stanowi punkt wyjścia do dalszych rozszerzeń uwzględniających ograniczenia czasowe, przestrzenne oraz dynamiczne. Przyjmijmy zatem, że rozważany proces harmonogramowania zadań dla floty UAV opisany jest jako szóstka:

$$P = (U, S, s_0, f, S_N, S_G), \quad (4.1)$$

gdzie:

- S - przestrzeń stanów procesu,
- s_0 - stan początkowy,
- S_G - zbiór stanów docelowych,
- S_N - zbiór stanów niedopuszczalnych,
- U - zbiór decyzji,
- f - funkcja przejścia opisująca dynamikę procesu.

Podany jest skończony zbiór zadań, reprezentowany przez liczby naturalne $J = \{1, 2, \dots, n\}$ oraz zbiór UAV $K = \{1, 2, \dots, m\}$. Dana jest funkcja:

$$p : J \times K \rightarrow \mathbb{R}^+, \quad (4.2)$$

która określa czas przetwarzania zadania j przez UAV k . Zadania wykonywane są równolegle przez flotę UAV, przy czym wykluczenie pracy (preempcja) nie jest dopuszczalne. Zadaniem jest znalezienie przypisania zadań do UAV oraz kolejności ich wykonywania tak, aby wszystkie zadania zostały zrealizowane. W celu zapewnienia uporządkowanego zapisu wprowadza się zadanie 0 o czasie przetwarzania $p(0, k) = 0$, które oznacza brak zadania przypisanego do UAV. Zdefiniujmy:

$$J^* = J \cup \{0\}. \quad (4.3)$$

Stan właściwy x określony jest przez zbiór zadań ukończonych oraz stany poszczególnych UAV. Formalnie mamy:

$$X = X^0 \times X^1 \times \dots \times X^m, x = (x^0, x^1, \dots, x^m), \quad (4.4)$$

gdzie:

- $x^0 \subseteq J$ - zbiór zadań ukończonych,
- $x^k = (\beta^k, \tau^k)$, $k = 1, \dots, m$ - stan k -tego UAV,
- $\beta^k \in J^*$ - zadanie aktualnie realizowane przez UAV,
- $\tau^k \in \mathbb{R}_{\geq 0}$ - pozostały czas realizacji zadania.

Przyjmuje się:

$$\beta^k = 0 \iff \tau^k = 0, \quad (4.5)$$

$$\beta^k \neq 0 \Rightarrow \tau^k > 0, \quad (4.6)$$

$$\beta^k \notin x^0. \quad (4.7)$$

Zależności (4.5) – (4.7) określają spójność reprezentacji stanu UAV, zapewniając jednoznaczną interpretację pary (β^k, τ^k) , w której brak zadania odpowiada zerowemu czasowi realizacji, natomiast zadanie aktywne posiada dodatni czas przetwarzania i nie należy do zbioru zadań ukończonych. Stan uogólniony opisujemy jako:

$$s = (x, t), \quad t \in \mathbb{R}_{\geq 0}. \quad (4.8)$$

Przestrzeń stanów procesu S definiuje się jako zbiór wszystkich stanów uogólnionych:

$$S = X \times \mathbb{R}_{\geq 0}, \quad (4.9)$$

gdzie X jest przestrzenią stanów właściwych, natomiast t oznacza czas procesu.

Stan początkowy definiuje się jako:

$$s_0 = (x_0, t_0), \quad (4.10)$$

$$t_0 = 0, \quad x_0 = (\emptyset, (0, 0), \dots, (0, 0)). \quad (4.11)$$

Zbiór stanów docelowych definiuje się jako:

$$S_G = \{(x, t) \in S : x^0 = J\}. \quad (4.12)$$

Zbiór stanów niedopuszczalnych w modelu bazowym przyjmuje się, że jest pusty, gdyż występuje tu brak ograniczeń wpływających na proces P :

$$S_N = \emptyset. \quad (4.13)$$

Wprowadzony model operuje na przestrzeni stanów S , którą można podzielić na trzy rozłączne podzbiory:

- zbiór stanów dopuszczalnych S_F ,
- zbiór stanów docelowych S_G ,
- zbiór stanów niedopuszczalnych S_N .

Przyjmuje się, że:

$$S = S_F \cup S_G \cup S_N, \quad S_F \cap S_G = \emptyset, \quad S_F \cap S_N = \emptyset, \quad S_G \cap S_N = \emptyset. \quad (4.14)$$

Zbiór S_F obejmuje wszystkie stany dopuszczalne, które nie są stanami docelowymi, natomiast zbiór S_G zawiera stany spełniające warunek zakończenia procesu. Wprowadzenie jawnego rozróżnienia zbiorów S_F , S_G oraz S_N ma charakter konstrukcyjny i stanowi podstawę dla dalszych rozszerzeń modelu, w których pojawiają się ograniczenia prowadzące do powstania niepustego zbioru stanów niedopuszczalnych. Ponieważ w omawianym modelu bazowym zbiór stanów niedopuszczalnych $S_N = \emptyset$ oznacza to, że:

$$S = S_F \cup S_G. \quad (4.15)$$

W konsekwencji każda trajektoria procesu rozpoczynająca się w stanie początkowym s_0 i generowana przez dopuszczalne decyzje pozostaje w przestrzeni stanów dopuszczalnych, aż do osiągnięcia stanu docelowego.

Zbiór decyzji definiuje się jako:

$$U \subseteq (J^*)^m, \quad u = (u^1, \dots, u^m). \quad (4.16)$$

Dla stanu s :

$$J_M(s) = \{\beta^k : k = 1, \dots, m, \beta^k \neq 0\}. \quad (4.17)$$

Zależność ta definiuje zbiór zadań aktualnie realizowanych przez UAV w stanie s , który wykorzystywany jest do wykluczania ponownego przypisania tych samych zadań w ramach decyzji. Kolejno przyjmijmy, że zbiór decyzji możliwych zdefiniowany jest jako:

$$U_p(s) = U_p^1(s) \times \dots \times U_p^m(s), \quad (4.18)$$

gdzie:

$$U_p^k(s) \subseteq (J \setminus x^0 \setminus J_M(s)) \cup \{0\}. \quad (4.19)$$

W modelu wyróżnia się dwa poziomy opisu decyzji: zbiór decyzji możliwych oraz zbiór decyzji dopuszczalnych. Zbiór decyzji możliwych $U_p(s)$ obejmuje wszystkie decyzje zgodne ze strukturą procesu, w szczególności takie, które nie naruszają warunków logicznych modelu, jak brak powtórnego przypisania zadań już zakończonych czy jednoczesne przypisanie tego samego zadania do więcej niż jednego UAV. Z kolei zbiór decyzji dopuszczalnych $U_d(s)$ definiuje się jako podzbiór decyzji możliwych, który nie prowadzi do stanów niedopuszczalnych:

$$U_d(s) = \{u \in U_p(s) : f(u, s) \notin S_N\}. \quad (4.20)$$

Ponieważ w modelu bazowym przyjęto, że zbiór stanów niedopuszczalnych jest pusty, tj. $S_N = \emptyset$, oznacza to, że każda decyzja możliwa jest jednocześnie decyzją dopuszczalną, a więc mamy:

$$U_d(s) = U_p(s). \quad (4.21)$$

W konsekwencji mechanizm filtracji decyzji przez zbiór stanów niedopuszczalnych nie odgrywa roli w modelu bazowym, natomiast jego formalne wprowadzenie jest istotne z punktu widzenia dalszych rozszerzeń

modelu, w których ograniczenia operacyjne będą prowadzić do zawężenia zbioru decyzji dopuszczalnych. Dodatkowo przyjmuje się, że nie jest możliwe przydzielenie tego samego zadania do różnych statków UAV:

$$u^k = u^\ell \neq 0 \Rightarrow k = \ell. \quad (4.22)$$

Proces opisywany jest w chwilach dyskretnych $i = 0, 1, 2, \dots$, odpowiadających kolejnym zdarzeniom zmiany stanu, zatem zmienna t_i oznacza czas systemowy w i -tym stanie, natomiast Δt_i określa przyrost czasu do najbliższego zdarzenia, wyznaczony jako minimalny dodatni czas zakończenia jednego z realizowanych zadań.

Funkcja przejścia:

$$f(u_i, x_i, t_i) = (x_{i+1}, t_{i+1}), \quad (4.23)$$

$$t_{i+1} = t_i + \Delta t_i, \quad (4.24)$$

$$\Delta t_i = \min^+ \{p(u_i^1, 1), \dots, p(u_i^m, m), \tau_i^1, \dots, \tau_i^m\}. \quad (4.25)$$

Można stwierdzić, że zależności (4.23) – (4.25) definiują funkcję przejścia procesu w ujęciu zdarzeniowym, w którym czas przechodzi do najbliższego momentu zakończenia jednego z realizowanych zadań, determinowanego przez minimalny dodatni czas pozostały do jego ukończenia. Zbiory zadań zakończonych wyznaczamy jako:

$$J_{cmp}(u_i, x_i, t_i) = \{\beta_i^k : \tau_i^k = \Delta t_i\}. \quad (4.26)$$

$$x_{i+1}^0 = x_i^0 \cup J_{cmp}(u_i, x_i, t_i). \quad (4.27)$$

Jest to sposób identyfikacji zadań zakończonych w wyniku przejścia oraz aktualizacji zbioru zadań ukończonych poprzez ich dołączenie do składowej x^0 stanu procesu. Aktualizacja stanu UAV:

$$x_{i+1}^k = \begin{cases} (\beta_i^k, \tau_i^k - \Delta t_i), & \text{jeżeli } \tau_i^k > 0, \\ (u_i^k, p(u_i^k, k)), & \text{jeżeli } \tau_i^k = 0. \end{cases} \quad (4.28)$$

Zależność (4.28) opisuje aktualizację stanu pojedynczego UAV, rozróżniając przypadek kontynuacji realizacji zadania od sytuacji przydzielenia nowego zadania w stanie decyzyjnym. Dodatkowo wprowadza się pojęcie trajektorii procesu, którą oznaczamy przez $\tilde{s}$ i definiujemy jako ciąg stanów:

$$\tilde{s} = (s_0, s_1, \dots, s_\omega), \quad (4.29)$$

gdzie $\omega \in \mathbb{N}$ oznacza długość trajektorii, tj. liczbę kroków procesu odpowiadających kolejnym przejściom stanu, przy czym wartość ω zależy od przyjętej trajektorii i momentu osiągnięcia stanu docelowego. Ponadto dla każdego $i = 0, 1, \dots, \omega - 1$ istnieje decyzja u_i , dla której:

$$s_{i+1} = f(u_i, s_i). \quad (4.30)$$

Odpowiadający jej ciąg decyzji oznaczamy przez $\tilde{u}$:

$$\tilde{u} = (u_0, u_1, \dots, u_{\omega-1}), \quad (4.31)$$

nazywamy trajektorią decyzji. Ponadto zauważmy, że tak zdefiniowane trajektorie procesu mogą być interpretowane jako podprocesy, tj. fragmenty większych trajektorii odpowiadających bardziej złożonym procesom decyzyjnym, co umożliwia hierarchiczne oraz modułarne podejście do modelowania i analizy procesu P .

Przedstawiony model bazowy opiera się na reprezentacji stanu jako kombinacji zbioru zadań ukończonych oraz stanów poszczególnych UAV, a decyzje sprowadzają się do przypisania zadań do dostępnych zasobów. Przyjęta konstrukcja umożliwia jednoznaczne odwzorowanie dynamiki procesu w ujęciu zdarzeniowym, w którym to zmiany stanu zachodzą w chwilach zakończenia realizacji zadań. Jednocześnie model bazowy nie uwzględnia dodatkowych ograniczeń operacyjnych, takich jak dostępność czasowa UAV, ograniczenia przestrzenne czy zakłócenia w przebiegu realizacji zadań. W szczególności przyjęto, że UAV są dostępne w całym horyzoncie planowania, a realizacja zadań nie podlega ograniczeniom wynikającym z harmonogramu pracy systemu. Tak sformułowany model uproszczony stanowi punkt wyjścia do dalszych rozszerzeń, w których odwzorowane zostaną rzeczywiste uwarunkowania operacyjne systemu UAV.

4.2 Model ALMM-TS uwzględniający ograniczenia dostępności czasowej UAV

W niniejszym podrozdziale model bazowy zostaje rozszerzony o ograniczenia dostępności czasowej zasobów floty UAV. Przyjmuje się zatem, że realizacja zadań przez UAV jest możliwa jedynie w wyznaczonych przedziałach czasu, zwanych dalej slotami dostępności, które to określają okresy operacyjnej gotowości UAV do realizacji zadań. Przechodząc do formalnego opisu modelu, wprowadzamy następujące oznaczenia:

- zbiór zadań

$$J = \{1, 2, \dots, n\}, \quad (4.32)$$

- zbiór UAV

$$K = \{1, 2, \dots, m\}, \quad (4.33)$$

- oraz funkcja

$$p : J \times K \rightarrow \mathbb{R}^+, \quad (4.34)$$

określająca czasy realizacji zadań przez poszczególne UAV. Dla każdego UAV przyjmuje się wspólną strukturę dostępności czasowej opisaną przez przedziały:

$$[B^1, F^1], [B^2, F^2], \dots, [B^{ILs}, F^{ILs}], \quad (4.35)$$

gdzie B^r i F^r oznaczają odpowiednio początek i koniec r -tego slotu dostępności, natomiast ILs oznacza liczbę dostępnych slotów. Wprowadza się zbiór rozszerzony:

$$J^* = J \cup \{0\}, \quad (4.36)$$

gdzie zadanie 0 oznacza brak zadania przypisanego do UAV, przy czym:

$$p(0, k) = 0, \quad k = 1, 2, \dots, m. \quad (4.37)$$

Podobnie jak w modelu bazowym, stan właściwy procesu P ma postać:

$$x = (x^0, x^1, x^2, \dots, x^m), \quad (4.38)$$

gdzie:

- $x^0 \subseteq J$ - zbiór zadań ukończonych,
- $x^k = (\beta^k, \tau^k)$, $k = 1, 2, \dots, m$ - stan k -tego UAV,
- $\beta^k \in J^*$ - numer zadania aktualnie realizowanego przez k -ty UAV,
- $\tau^k \in \mathbb{R}_{\geq 0}$ - pozostały czas do zakończenia zadania.

Przyjmuje się, że:

$$\beta^k = 0 \iff \tau^k = 0, \quad (4.39)$$

$$\beta^k \neq 0 \Rightarrow \tau^k > 0, \quad (4.40)$$

$$\beta^k \notin x^0. \quad (4.41)$$

Stan uogólniony ma postać:

$$s = (x, t), \quad t \in \mathbb{R}_{\geq 0}. \quad (4.42)$$

Przestrzeń stanów procesu definiuje się jako:

$$S = X \times \mathbb{R}_{\geq 0}. \quad (4.43)$$

Stan początkowy procesu określony jest jako:

$$s_0 = (x_0, t_0), \quad (4.44)$$

gdzie:

$$t_0 = B^1, \quad (4.45)$$

oraz:

$$x_0 = (\emptyset, (0, 0), (0, 0), \dots, (0, 0)). \quad (4.46)$$

Zbiór stanów docelowych określony jest przez zależność:

$$S_G = \{(x, t) \in S : x^0 = J \wedge t \leq F^{ILs}\}. \quad (4.47)$$

W celu zdefiniowania zbioru stanów niedopuszczalnych wprowadza się pomocniczo zbiór zadań aktualnie realizowanych przez UAV w stanie s :

$$J_M(s) = \{\beta^k : k = 1, \dots, m, \beta^k \neq 0\}. \quad (4.48)$$

Zbiór stanów niedopuszczalnych obejmuje dwa typy sytuacji:

- czas procesu nie należy do żadnego przedziału dostępności, a jednocześnie istnieje zadanie aktualnie realizowane,
- nie wszystkie zadania zostały ukończone, a czas przekroczył koniec ostatniego slotu.

Formalnie zapiszemy zatem, że:

$$S_N^{TS} = \left\{ (x, t) \in S : \left[J_M(s) \neq \emptyset \wedge \bigvee_{r=1}^{ILs-1} (F^r < t < B^{r+1}) \right] \vee [x^0 \neq J \wedge t > F^{ILs}] \right\}. \quad (4.49)$$

Zbiór decyzji ma postać:

$$U \subseteq (J^*)^m, \quad u = (u^1, u^2, \dots, u^m), \quad (4.50)$$

gdzie u^k oznacza zadanie przypisane do k -tego UAV. Stan $s = (x, t)$ nazywa się stanem decyzyjnym dla k -tego UAV, jeżeli:

$$\tau^k = 0. \quad (4.51)$$

Zbiór stanów decyzyjnych dla k -tego UAV oznaczany jest przez $S_d(k)$.

$$s \in S_d(k) \iff \tau^k = 0. \quad (4.52)$$

W celu uproszczenia zapisu wprowadzamy podział zbioru UAV w stanie $s = (x, t)$ na podzbiory odpowiadające ich aktualnemu statusowi operacyjnemu. Niech:

$$K_{dec}(s) = \{k \in K : \tau^k = 0\} \quad (4.53)$$

oznacza zbiór UAV znajdujących się w stanie decyzyjnym, tj. gotowych do przyjęcia nowego zadania, oraz:

$$K_{busy}(s) = \{k \in K : \tau^k > 0\} \quad (4.54)$$

oznacza zbiór UAV aktualnie realizujących zadania. Z definicji zachodzi:

$$K_{dec}(s) \cup K_{busy}(s) = K, \quad K_{dec}(s) \cap K_{busy}(s) = \emptyset. \quad (4.55)$$

Zauważmy ponadto, że:

$$k \in K_{dec}(s) \iff s \in S_d(k). \quad (4.56)$$

Ten dodatkowy zapis istotnie ułatwia późniejszą implementację programistyczną modelu. Dla stanu s zbiór decyzji możliwych opisuje zależność:

$$U_p(s) = U_p^1(s) \times U_p^2(s) \times \dots \times U_p^m(s). \quad (4.57)$$

W odróżnieniu od modelu bazowego, w modelu z ograniczeniami dostępności czasowej zbiór decyzji dopuszczalnych jest zawężany przez warunek:

$$U_d^{TS}(s) = \{u \in U_p(s) : f(u, s) \notin S_N^{TS}\}. \quad (4.58)$$

Jeżeli czas t nie należy do żadnego slotu dostępności oraz $t < F^{ILs}$, to dopuszcza się wyłącznie decyzje specjalną:

$$u^* = (0, 0, \dots, 0), \quad (4.59)$$

interpretowaną jako przejście do kolejnego slotu. Dla zwykłych decyzji $u \neq u^*$ przyjmuje się następujące własności:

- jeżeli $s \in S_d(k)$, to:

$$U_p^k(s) \subseteq (J \setminus x^0 \setminus J_M(s)) \cup \{0\}, \quad (4.60)$$

- jeżeli $s \notin S_d(k)$, to:

$$U_p^k(s) = \{\beta^k\}, \quad (4.61)$$

- warunek jednoznaczności przypisania zadań do UAV, który eliminuje możliwość równoczesnej realizacji tego samego zadania przez różne statki, co oznacza, że to samo zadanie nie może być jednocześnie przypisane do więcej niż jednego UAV, a więc każde zadanie może być w danym stanie realizowane co najwyżej przez jeden zasób:

$$u^k = u^\ell \neq 0 \Rightarrow k = \ell, \quad (4.62)$$

Dodatkowo dla każdej decyzji zwykłej wymaga się, aby zadanie uruchomione w chwili t mogło zostać ukończone przed końcem bieżącego slotu. Jeżeli $t \in [B^r, F^r]$, wówczas zachodzi warunek:

$$t + p(u^k, k) \leq F^r \quad (4.63)$$

dla każdego UAV decyzyjnego, dla którego $u^k \neq 0$. Na podstawie powyższych własności zbiór decyzji możliwych $U_p(s)$ można zapisać równoważnie jako:

$$U_p(s) = \left\{ u \in (J^*)^m : \begin{array}{l} \forall_{k=1, \dots, m} u^k \in U_p^k(s), \\ \forall_{k \neq \ell} (u^k = u^\ell \neq 0 \Rightarrow k = \ell) \end{array} \right\}. \quad (4.64)$$

Kolejno definiujemy funkcję przejścia:

$$f(u_i, x_i, t_i) = (x_{i+1}, t_{i+1}), \quad (4.65)$$

przy czym:

$$f = (f_x, f_t), \quad (4.66)$$

gdzie:

$$f_x(u_i, x_i, t_i) = x_{i+1}, \quad f_t(u_i, x_i, t_i) = t_{i+1}. \quad (4.67)$$

Jeżeli $u_i \neq u^*$, to:

$$t_{i+1} = t_i + \Delta t_i, \quad (4.68)$$

gdzie:

$$\Delta t_i = \min^+ \{p(u_i^1, 1), p(u_i^2, 2), \dots, p(u_i^m, m), \tau_i^1, \tau_i^2, \dots, \tau_i^m\}. \quad (4.69)$$

Wartość Δt_i wyznacza najbliższy moment zmiany stanu procesu, odpowiadający zakończeniu co najmniej jednego z aktualnie realizowanych lub właśnie uruchomionych zadań. Dla wyznaczenia funkcji f_x^0 definiuje się zbiór zadań zakończonych w wyniku przejścia:

$$J_{cmp}(u_i, x_i, t_i) = J_{cmp-x}(u_i, x_i, t_i) \cup J_{cmp-u}(u_i, x_i, t_i), \quad (4.70)$$

gdzie zbiór $J_{cmp-x}(u_i, x_i, t_i)$ obejmuje zadania rozpoczęte wcześniej, których realizacja kończy się w chwili t_{i+1} , natomiast zbiór $J_{cmp-u}(u_i, x_i, t_i)$ zawiera zadania uruchomione decyzją u_i , które również kończą się w tym kroku przejścia. Zapiszemy to odpowiednio jako:

$$J_{cmp-x}(u_i, x_i, t_i) = \left\{ \beta_i^k : 1 \leq k \leq m, \tau_i^k = \Delta t_i \right\}, \quad (4.71)$$

oraz

$$J_{cmp-u}(u_i, x_i, t_i) = \left\{ u_i^k : 1 \leq k \leq m, u_i^k \neq 0, p(u_i^k, k) = \Delta t_i \right\}. \quad (4.72)$$

Wówczas przyjmujemy, że:

$$x_{i+1}^k = f_x^k(u_i, x_i, t_i). \quad (4.73)$$

$$x_{i+1}^0 = x_i^0 \cup J_{cmp}(u_i, x_i, t_i). \quad (4.74)$$

Indeks górny w funkcjach f_x^k odpowiada składowej wektora stanu, przy czym f_x^0 opisuje aktualizację zbioru zadań ukończonych, natomiast f_x^k , $k = 1, \dots, m$, opisują zmiany stanów poszczególnych UAV. Dla $k = 1, 2, \dots, m$ funkcja f_x^k opisana jest następująco:

- jeżeli $s_i \notin S_d(k)$, to

$$\beta_{i+1}^k = \beta_i^k, \quad \tau_{i+1}^k = \tau_i^k - \Delta t_i, \quad (4.75)$$

- jeżeli $s_i \in S_d(k)$, to

$$\beta_{i+1}^k = u_i^k, \quad \tau_{i+1}^k = p(u_i^k, k). \quad (4.76)$$

Równoważnie nowy stan k -tego UAV zapiszemy jako:

$$f_x^k(u_i, x_i, t_i) = \begin{cases} (\beta_i^k, \tau_i^k - \Delta t_i) & \text{dla } s_i \notin S_d(k), \\ (u_i^k, p(u_i^k, k)) & \text{dla } s_i \in S_d(k). \end{cases} \quad (4.77)$$

$$x_{i+1}^k = f_x^k(u_i, x_i, t_i). \quad (4.78)$$

W przypadku decyzji specjalnej u^* , jeśli $t_i \in [F^r, B^{r+1})$ dla pewnego $r < ILs$, to

$$\Delta t_i = B^{r+1} - t_i, \quad t_{i+1} = B^{r+1}, \quad (4.79)$$

natomiast stan właściwy nie ulega zmianie:

$$x_{i+1} = x_i. \quad (4.80)$$

Jeżeli $t_i \geq F^{ILs}$, to decyzja u^* nie jest dopuszczalna, a dalsza trajektoria prowadzi do zbioru stanów niedopuszczalnych. Przedstawiony model stanowi rozszerzenie modelu bazowego o ograniczenia dostępności czasowej zasobów floty UAV. Wprowadzenie slotów czasowych powoduje, że dopuszczalne trajektorie procesu są ograniczone przez strukturę przedziałów dostępności, w których możliwa jest realizacja zadań. Uwzględnienie tych ograniczeń prowadzi do zawężenia zbioru dopuszczalnych decyzji oraz wymusza synchronizację momentów realizacji zadań z dostępnością zasobów, co odzwierciedla rzeczywiste warunki operacyjne systemów UAV. Należy jednak zauważyć, że model w takiej postaci nie uwzględnia jeszcze ograniczeń przestrzenno-czasowych związanych z organizacją przestrzeni powietrznej. Ograniczenia te zostaną wprowadzone w kolejnym podrozdziale.

4.3 Model ALMM-CS uwzględniający dostępność korytarzy powietrznych

W niniejszym podrozdziale model przedstawiony w podrozdziale 4.2 (ALMM-TS) zostaje rozszerzony o ograniczenia przestrzenno-czasowe związane z dostępnością korytarzy powietrznych. Korytarze powietrzne traktowane są jako zasób współdzielony, którego dostępność w czasie ogranicza możliwość realizacji zadań przez UAV. Rozważany proces harmonogramowania opisujemy ponownie jako:

$$P = (U, S, s_0, f, S_N, S_G), \quad (4.81)$$

przy czym struktura stanu, funkcja przejścia oraz podstawowy zbiór decyzji pozostają zgodne z modelem ALMM-TS, natomiast modyfikacji ulegają warunki dopuszczalności decyzji oraz definicja zbioru stanów niedopuszczalnych.

Dany jest zbiór korytarzy powietrznych:

$$C = \{1, 2, \dots, q\}. \quad (4.82)$$

Dodatkowo definiuje się funkcję przypisania:

$$\gamma : J \rightarrow C, \quad (4.83)$$

gdzie $\gamma(j)$ oznacza korytarz wymagany do realizacji zadania j . W celu formalnego doprecyzowania struktury dostępności korytarzy powietrznych wprowadza się zbiór indeksów przedziałów dostępności dla każdego korytarza $c \in C$:

$$R_c = \{1, 2, \dots, IL_c\}, \quad (4.84)$$

gdzie IL_c oznacza liczbę przedziałów dostępności korytarza c . Zbiór przedziałów dostępności korytarza c definiuje się jako:

$$A_c = \{[B_c^r, F_c^r] : r \in R_c\}. \quad (4.85)$$

Przyjmuje się, że każdy przedział spełnia warunek:

$$B_c^r < F_c^r, \quad r \in R_c, \quad (4.86)$$

oraz że przedziały są uporządkowane i rozłączne:

$$F_c^r < B_c^{r+1}, \quad r = 1, 2, \dots, IL_c - 1. \quad (4.87)$$

W celu uwzględnienia jednoczesnej dostępności UAV oraz korytarzy powietrznych definiuje się efektywną dostępność korytarza c :

$$E_c = \left(\bigcup_{r=1}^{IL_s} [B^r, F^r] \right) \cap \left(\bigcup_{\rho=1}^{IL_c} [B_c^\rho, F_c^\rho] \right). \quad (4.88)$$

W powyższym zapisie indeks r odnosi się do przedziałów dostępności UAV, natomiast indeks ρ oznacza przedziały dostępności korytarza c . Indeksy te są niezależne, ponieważ struktura dostępności zasobów powietrznych oraz UAV może się różnić. Warunkiem koniecznym wykonalności realizacji zadania $j \in J$, wymagającego korytarza $\gamma(j)$, jest niepustość zbioru:

$$E_{\gamma(j)} \neq \emptyset. \quad (4.89)$$

Ponieważ realizacja zadań jest nieprzerywalna, musi istnieć przedział efektywnej dostępności umożliwiający realizację zadania w całości. Formalnie:

$$\exists k \in K, \exists I \subseteq E_{\gamma(j)} : |I| \geq p(j, k). \quad (4.90)$$

gdzie I oznacza przedział czasu $I = [a, b] \subseteq \mathbb{R}$. Dla każdego korytarza $c \in C$ definiuje się zbiór zadań korzystających z tego korytarza:

$$J_c = \{j \in J : \gamma(j) = c\}. \quad (4.91)$$

Warunkiem koniecznym wykonalności względem dostępności korytarzy jest:

$$\sum_{j \in J_c} \min_{k \in K} p(j, k) \leq |E_c|. \quad (4.92)$$

Dodatkowo warunek konieczny pojemności czasowej floty UAV ma postać:

$$\sum_{j \in J} \min_{k \in K} p(j, k) \leq m \sum_{r=1}^{ILs} (F^r - B^r). \quad (4.93)$$

Powyższe warunki mają charakter konieczny, lecz nie są warunkami wystarczającymi istnienia rozwiązania dopuszczalnego. Ich niespełnienie oznacza niewykonalność problemu, natomiast ich spełnienie nie gwarantuje istnienia harmonogramu, ponieważ zależy ono również od kolejności realizacji zadań oraz szczegółowego przypisania ich do UAV i korytarzy. Struktura stanu pozostaje niezmienną względem modelu ALMM-TS i dana jest przez:

$$x = (x^0, x^1, \dots, x^m), \quad (4.94)$$

gdzie:

- $x^0 \subseteq J$ - zbiór zadań ukończonych,
- $x^k = (\beta^k, \tau^k)$, $k = 1, \dots, m$,
- $\beta^k \in J^*$,
- $\tau^k \in \mathbb{R}_{\geq 0}$.

Stan uogólniony:

$$s = (x, t), \quad t \in \mathbb{R}_{\geq 0}. \quad (4.95)$$

Zbiór decyzji możliwych zachowuje strukturę:

$$U_p(s) = U_p^1(s) \times \dots \times U_p^m(s), \quad (4.96)$$

gdzie składniki $U_p^k(s)$ określone są analogicznie jak w modelu ALMM-TS. Dodatkowo wprowadzamy ograniczenia wynikające z dostępności korytarzy powietrznych. Dla każdej decyzji $u \in U_p(s)$ oraz dla każdego UAV decyzyjnego $k \in K_{dec}(s)$, dla którego $u^k \neq 0$, musi istnieć korytarz $c = \gamma(u^k)$ oraz przedział r taki, że:

$$t \geq B_c^r, \quad (4.97)$$

$$t + p(u^k, k) \leq F_c^r. \quad (4.98)$$

Oznacza to, że realizacja zadania u^k jest dopuszczalna tylko wtedy, gdy cały proces jego wykonania mieści się w jednym z przedziałów dostępności przypisanego korytarza. Ponieważ korytarze powietrzne stanowią zasób współdzielony, warunek współdzielenia korytarzy, który dotyczy wyłączości ich wykorzystania. Dla dowolnych UAV $k, \ell \in K, k \neq \ell$, zachodzi:

$$u^k \neq 0, u^\ell \neq 0, k \neq \ell \Rightarrow \gamma(u^k) \neq \gamma(u^\ell). \quad (4.99)$$

Warunek ten oznacza, że w danym kroku decyzyjnym ten sam korytarz nie może zostać jednocześnie przypisany do więcej niż jednego UAV. Zbiór decyzji dopuszczalnych definiuje się jako:

$$U_d^{CS}(s) = \{u \in U_p(s) : f(u, s) \notin S_N^{CS}\}, \quad (4.100)$$

przy czym $U_p(s)$ zawiera wyłącznie decyzje spełniające warunki dostępności korytarzy oraz warunek ich współdzielenia. Zbiór decyzji dopuszczalnych $U_d^{CS}(s)$ obejmuje decyzje spełniające warunki dostępności czasowej UAV oraz dostępności korytarzy powietrznych, w szczególności wynikające z definicji efektywnej dostępności E_c oraz warunków realizacji zadań w przedziałach nieprzerwywalnych. Z uwagi na hierarchiczny charakter rozszerzeń modelu zachodzi zależność:

$$U_d^{CS}(s) \subseteq U_d^{TS}(s) \subseteq U_p(s), \quad (4.101)$$

co oznacza, że kolejne rozszerzenia modelu prowadzą do monotonicznego zawężania zbioru decyzji dopuszczalnych poprzez uwzględnianie dodatkowych ograniczeń operacyjnych. Zbiór stanów niedopuszczalnych rozszerza się względem modelu ALMM-TS:

$$S_N^{CS} = S_N^{TS} \cup S_N^{corr}, \quad (4.102)$$

gdzie:

$$S_N^{corr} = \left\{ (x, t) : \exists k, \beta^k \neq 0 \wedge t \notin E_{\gamma(\beta^k)} \right\}. \quad (4.103)$$

Oznacza to, że stan jest niedopuszczalny, jeżeli realizowane zadanie wymaga korytarza, który w danym czasie nie jest dostępny. Funkcja przejścia określona jest następująco:

$$f(u_i, x_i, t_i) = (x_{i+1}, t_{i+1}) \quad (4.104)$$

zachowując strukturę modelu ALMM-TS. Jej zastosowanie jest jednak ograniczone do decyzji należących do zbioru $U_d(s)$, spełniających dodatkowe warunki wynikające z dostępności korytarzy powietrznych. Zbiór stanów docelowych pozostaje niezmienny:

$$S_G = \{(x, t) \in S : x^0 = J \wedge t \leq F^{ILs}\}. \quad (4.105)$$

Przedstawiony model ALMM-CS stanowi rozszerzenie modelu ALMM-TS o ograniczenia przestrzenno-czasowe wynikające z dostępności korytarzy powietrznych, traktowanych jako współdzielony zasób systemu. Wprowadzenie funkcji przypisania $\gamma(j)$ oraz zbiorów przedziałów dostępności korytarzy prowadzi do konieczności jednoczesnego uwzględnienia dostępności czasowej UAV oraz dostępności przestrzeni operacyjnej. Kluczowym elementem rozszerzenia jest definicja efektywnej dostępności korytarzy

E_c , która opisuje przedziały czasowe, w których możliwa jest realizacja zadań przy jednoczesnej dostępności UAV oraz odpowiednich zasobów przestrzennych. W konsekwencji warunki dopuszczalności decyzji oraz definicja zbioru stanów niedopuszczalnych zostają uzupełnione o ograniczenia wynikające z konieczności realizacji zadań w całości w dostępnych przedziałach E_c , z uwzględnieniem ich nieprzerywalnego charakteru oraz współdzielenia korytarzy przez wiele UAV. Wprowadzenie tych ograniczeń prowadzi do dalszego zawężenia zbioru decyzji dopuszczalnych $U_d^{CS}(s)$ oraz zbioru dopuszczalnych trajektorii procesu, przy zachowaniu niezmiennionej struktury funkcji przejścia. Należy jednak podkreślić, że przedstawiony model nadal zakłada deterministyczny charakter dostępności zasobów oraz brak zmian w trakcie realizacji procesu. W rzeczywistych warunkach operacyjnych ograniczenia te mogą ulegać dynamicznym zmianom, co prowadzi do konieczności uwzględnienia zakłóceń w modelu procesu, będącego przedmiotem kolejnego podrozdziału.

4.4 Model ALMM-TW uwzględniający okna czasowe zadań

W niniejszym podrozdziale model przedstawiony w podrozdziale 4.3 (ALMM-CS) zostaje rozszerzony o ograniczenia czasowe zadań w postaci momentów dostępności oraz terminów realizacji. Oznacza to, że każde zadanie może być realizowane wyłącznie w określonym przedziale czasowym, niezależnie od dostępności UAV oraz korytarzy powietrznych. Rozważany proces harmonogramowania opisujemy ponownie jako:

$$P = (U, S, s_0, f, S_N, S_G), \quad (4.106)$$

przy czym struktura stanu oraz funkcja przejścia pozostają zgodne z modelem ALMM-CS, natomiast rozszerzeniu ulegają warunki dopuszczalności decyzji oraz zbiór stanów niedopuszczalnych. Ograniczenia czasowe zadań $j \in J$ definiuje się:

$$r(j) \in \mathbb{R}_{\geq 0}, \quad (4.107)$$

oznaczające najwcześniejszy moment rozpoczęcia realizacji zadania (release time), oraz

$$d(j) \in \mathbb{R}_{\geq 0}, \quad (4.108)$$

oznaczające najpóźniejszy dopuszczalny moment zakończenia zadania (deadline). Zakłada się, że:

$$r(j) < d(j), \quad j \in J. \quad (4.109)$$

Dla wygody wprowadza się okno czasowe zadania:

$$W_j = [r(j), d(j)]. \quad (4.110)$$

Warunki dopuszczalności decyzji opisują zbiór decyzji możliwych $U_p(s)$, który zachowuje strukturę modelu ALMM-CS. Dla decyzji $u \in U_p(s)$ oraz dla każdego UAV decyzyjnego $k \in K_{dec}(s)$, dla którego $u^k = j \neq 0$, muszą być spełnione dodatkowe warunki:

$$t \geq r(j), \quad (4.111)$$

$$t + p(u^k, k) \leq d(j). \quad (4.112)$$

Oznacza to, że zadanie może zostać rozpoczęte nie wcześniej niż w chwili $r(j)$ oraz musi zostać zakończone przed upływem terminu $d(j)$. Warunki te obowiązują łącznie z ograniczeniami wynikającymi z:

- dostępności czasowej UAV (ALMM-TS),
- dostępności korytarzy powietrznych (ALMM-CS),
- nieprzerwalności realizacji zadań.

Zbiór decyzji dopuszczalnych definiuje się jako:

$$U_d^{TW}(s) = \{u \in U_p(s) : f(u, s) \notin S_N^{TW}\}. \quad (4.113)$$

Warunki (4.111) – (4.112) stanowią integralną część definicji zbioru decyzji możliwych $U_p(s)$, a tym samym są uwzględniane przy konstrukcji zbioru decyzji dopuszczalnych $U_d^{TW}(s)$. Z uwagi na hierarchiczny charakter rozszerzeń modelu zachodzi zależność:

$$U_d^{TW}(s) \subseteq U_d^{CS}(s) \subseteq U_d^{TS}(s) \subseteq U_p(s). \quad (4.114)$$

Oznacza to, że uwzględnienie okien czasowych zadań prowadzi do dalszego zawężenia zbioru decyzji dopuszczalnych. Zbiór stanów niedopuszczalnych rozszerza się względem modelu ALMM-CS:

$$S_N^{TW} = S_N^{CS} \cup S_N^{time}, \quad (4.115)$$

gdzie:

$$S_N^{time} = \left\{ (x, t) : \exists j \in J, j \notin x^0 \wedge \max\{t, r(j)\} + \min_{k \in K} p(j, k) > d(j) \right\}. \quad (4.116)$$

Oznacza to, że stan jest niedopuszczalny, jeżeli istnieje zadanie niezrealizowane, dla którego przekroczono termin realizacji. Funkcja przejścia definiowana jest analogicznie jak modelu bazowym:

$$f(u_i, x_i, t_i) = (x_{i+1}, t_{i+1}) \quad (4.117)$$

zachowuje strukturę modelu ALMM-CS, przy czym jej zastosowanie ograniczone jest do decyzji należących do zbioru $U_d^{TW}(s)$. Zbiór stanów docelowych pozostaje niezmieniony:

$$S_G = \{(x, t) \in S : x^0 = J \wedge t \leq F^{ILs}\}. \quad (4.118)$$

Wprowadzenie okien czasowych zadań powoduje, że proces harmonogramowania musi uwzględniać trzy współzależne aspekty czasowe:

- dostępność zasobów (UAV),
- dostępność przestrzeni operacyjnej (korytarze),
- indywidualne ograniczenia czasowe zadań.

Ograniczenia te mają charakter komplementarny i prowadzą do dalszego zawężenia zbioru dopuszczalnych decyzji oraz trajektorii procesu. Model ALMM-TS-CS-TW stanowi zatem bardziej realistyczne odwzorowanie rzeczywistych warunków operacyjnych, w których zadania muszą być realizowane nie tylko w dostępnych zasobach, lecz również w określonych przedziałach czasowych wynikających z ich charakterystyki operacyjnej. Jednocześnie model ten nadal zakłada deterministyczny charakter środowiska. W kolejnym podrozdziale zostaną wprowadzone elementy dynamiczne, uwzględniające zakłócenia oraz konieczność adaptacyjnego sterowania procesem.

4.5 Model ALMM-D uwzględniający zakłócenia procesu harmonogramowania

W niniejszym podrozdziale model przedstawiony w podrozdziale 4.4 zostaje rozszerzony o zakłócenia pojawiające się w trakcie realizacji procesu harmonogramowania. W odróżnieniu od wcześniejszych modeli, w których przyjmowano deterministyczny charakter parametrów oraz dostępności zasobów, w modelu ALMM-D dopuszcza się zmianę wybranych elementów procesu w kolejnych krokach decyzyjnych. Rozważany proces opisujemy ponownie jako:

$$P = (U, S, s_0, f, S_N, S_G), \quad (4.119)$$

przy czym zakłócenia wpływają na parametry procesu, zbiór decyzji dopuszczalnych oraz funkcję przejścia.

Zbiór zakłóceń w tym modelu definiujemy następująco. Niech $\mathcal{D}$ oznacza zbiór możliwych zakłóceń procesu. W kroku i wystąpienie zakłócenia opisuje element:

$$\delta_i \in \mathcal{D}. \quad (4.120)$$

Zakłócenie δ_i może obejmować w szczególności:

- zakłócenia czasowe, wpływające na czas realizacji zadania,
- zakłócenia zasobowe, wpływające na dostępność UAV,
- zakłócenia przestrzenne, wpływające na dostępność korytarzy powietrznych,
- zakłócenia zadaniowe, polegające na pojawieniu się, usunięciu lub zmianie parametrów zadań.

Zakłócenia te stanowią czynniki egzogeniczne względem procesu decyzyjnego i mogą prowadzić do konieczności modyfikacji wcześniej podjętych decyzji. W odpowiedzi na ich wystąpienie model dopuszcza zastosowanie mechanizmów endogenicznych, w szczególności decyzji realokacyjnych, które umożliwiają korektę trajektorii procesu i jego kontynuację w przestrzeni stanów dopuszczalnych. W modelu bazowym czas realizacji zadania j przez UAV k opisany był funkcją $p(j, k)$. W modelu z zakłóceniami przyjmuje się zakłócenia czasowe, które powodują, że czas ten może ulec zmianie w zależności od chwili procesu oraz zakłócenia:

$$p_\delta(j, k, i) = p(j, k) + \Delta p(j, k, \delta_i), \quad (4.121)$$

gdzie $\Delta p(j, k, \delta_i)$ oznacza zmianę czasu realizacji zadania wynikającą z zakłócenia δ_i . W konsekwencji warunki dopuszczalności decyzji zależne od czasu przetwarzania należy zapisać z użyciem $p_\delta(j, k, i)$. Przykładowo warunek realizacji zadania w oknie czasowym przyjmuje postać:

$$t_i + p_\delta(j, k, i) \leq d(j). \quad (4.122)$$

Należy podkreślić, że ograniczenia wynikające z okien czasowych zadań, w szczególności warunki związane z momentem uwolnienia zadania $r(j)$ oraz terminem jego realizacji $d(j)$, pozostają obowiązujące w modelu ALMM-D. W konsekwencji każda decyzja dopuszczalna musi spełniać warunki:

$$t_i \geq r(j), \quad t_i + p_\delta(j, k, i) \leq d(j), \quad (4.123)$$

dla wszystkich zadań przypisywanych w decyzji u_i . Zakłócenia zasobowe opisują czasową niedostępność wybranych UAV. Niech:

$$K_{av}(s_i, \delta_i) \subseteq K \quad (4.124)$$

oznacza zbiór UAV dostępnych w stanie s_i po uwzględnieniu zakłócenia δ_i . Wówczas zbiór UAV decyzyjnych zostaje zawężony do:

$$K_{dec}^D(s_i, \delta_i) = K_{dec}(s_i) \cap K_{av}(s_i, \delta_i). \quad (4.125)$$

Oznacza to, że nowe zadania mogą być przydzielane wyłącznie do UAV, które są jednocześnie wolne oraz dostępne operacyjnie.

Zakłócenia przestrzenne dotyczą zmian dostępności korytarzy powietrznych. Niech $E_c^D(i)$ oznacza efektywną dostępność korytarza c po uwzględnieniu zakłócenia w kroku i :

$$E_c^D(i) = E_c \setminus Z_c(\delta_i), \quad (4.126)$$

gdzie $Z_c(\delta_i)$ oznacza część dostępności korytarza c , która została wyłączona w wyniku zakłócenia. Dla decyzji $u_i^k = j \neq 0$ wymagane jest zatem:

$$[t_i, t_i + p_\delta(j, k, i)] \subseteq E_{\gamma(j)}^D(i). \quad (4.127)$$

Zakłócenia zadaniowe mogą prowadzić do zmiany zbioru zadań. W kroku i zbiór zadań przyjmuje postać:

$$J_i = J_{i-1} \cup J_i^{new} \setminus J_i^{rem}, \quad (4.128)$$

gdzie J_i^{new} oznacza zbiór nowych zadań ujawnionych w kroku i , natomiast J_i^{rem} oznacza zbiór zadań usuniętych lub anulowanych, które nie zostały z zakończone z powodu zakłóceń procesu w stanie s_i . W konsekwencji zbiór zadań niezakończonych, które mogą być rozważane przy konstrukcji decyzji, zależy od aktualnego zbioru J_i :

$$J_i^{unf}(s_i) = J_i \setminus x_i^0. \quad (4.129)$$

Należy zauważyć, że zmiana zbioru zadań nie implikuje ich natychmiastowej realizowalności, która dodatkowo zależy od dostępności UAV oraz korytarzy powietrznych.

Zbiór decyzji dopuszczalnych w modelu ALMM-D definiuje się jako:

$$U_d^D(s_i, \delta_i) = \{u_i \in U_p(s_i) : f(u_i, s_i, \delta_i) \notin S_N^D\}. \quad (4.130)$$

Z uwagi na hierarchiczny charakter rozszerzeń zachodzi:

$$U_d^D(s_i, \delta_i) \subseteq U_d^{TW}(s_i) \subseteq U_d^{CS}(s_i) \subseteq U_d^{TS}(s_i) \subseteq U_p(s_i). \quad (4.131)$$

Oznacza to, że wystąpienie zakłóceń prowadzi do dalszego zawężenia zbioru decyzji dopuszczalnych, przy czym zawężenie to może zmieniać się w kolejnych krokach procesu. Dodatkowo przyjmuje się, że decyzje mogą przypisywać zadania wyłącznie UAV należącym do zbioru dostępnych zasobów decyzyjnych:

$$k \in K_{dec}^D(s_i, \delta_i) \Rightarrow u_i^k \in J^*, \quad (4.132)$$

natomiast dla UAV niedostępnych operacyjnie:

$$k \notin K_{av}(s_i, \delta_i) \Rightarrow u_i^k = 0. \quad (4.133)$$

W modelu ALMM-D wprowadza się dodatkowo mechanizm realokacji, umożliwiający modyfikację wcześniej podjętych decyzji poprzez zmianę przypisania zadań do UAV. W szczególności dopuszcza się przerwanie realizacji zadania oraz jego ponowne przydzielenie w kolejnych krokach decyzyjnych. Zbiór decyzji rozszerza się o decyzje realokacyjne:

$$U(s_i, \delta_i) = U^{std}(s_i) \cup U^{ra}(s_i, \delta_i), \quad (4.134)$$

gdzie $U^{std}(s_i)$ oznacza zbiór decyzji standardowych, natomiast $U^{ra}(s_i, \delta_i)$ zbiór decyzji realokacyjnych. Decyzja realokacyjna ma postać:

$$u_i^{ra} = (k, j, k'), \quad (4.135)$$

gdzie:

- $k \in K$ - UAV aktualnie realizujący zadanie,
- $j \in J_i$ - zadanie podlegające realokacji,
- $k' \in K \cup \{0\}$ - nowy UAV lub wartość 0 oznaczająca odroczenie realizacji.

W wyniku decyzji realokacyjnej następuje przerwanie realizacji zadania j przez UAV k oraz jego usunięcie z bieżącego przypisania:

$$\beta_i^k = j \Rightarrow \beta_{i+1}^k = 0, \quad \tau_{i+1}^k = 0, \quad (4.136)$$

przy czym zadanie nie jest traktowane jako ukończone:

$$j \notin x_i^0. \quad (4.137)$$

Zadanie j pozostaje w zbiorze zadań niezakończonych i może zostać ponownie przydzielone w kolejnych krokach decyzyjnych. Decyzje realokacyjne podlegają ograniczeniom dopuszczalności analogicznie jak decyzje standardowe:

$$U_d^D(s_i, \delta_i) = \{u_i \in U(s_i, \delta_i) : f(u_i, s_i, \delta_i) \notin S_N^D\}. \quad (4.138)$$

W szczególności decyzja realokacyjna jest dopuszczalna, jeżeli jej zastosowanie pozwala uniknąć przejścia procesu do zbioru stanów niedopuszczalnych. Formalnie, dla decyzji standardowej u_i^{std} oraz odpowiadającej jej decyzji realokacyjnej u_i^{ra} , zachodzi:

$$f(u_i^{std}, s_i, \delta_i) \in S_N^D \Rightarrow \exists u_i^{ra} \in U^{ra}(s_i, \delta_i) : f(u_i^{ra}, s_i, \delta_i) \notin S_N^D. \quad (4.139)$$

Oznacza to, że mechanizm realokacji pełni rolę korekty trajektorii procesu, umożliwiając jego kontynuację w przestrzeni stanów dopuszczalnych pomimo wystąpienia zakłóceń. Należy podkreślić, że decyzje realokacyjne nie zmieniają struktury funkcji przejścia, lecz rozszerzają zbiór dopuszczalnych działań sterujących, wpływając tym samym na zbiór osiągalnych trajektorii procesu.

Zbiór stanów niedopuszczalnych rozszerza się względem modelu z oknami czasowymi i w modelu ALMM- D przyjmuje postać:

$$S_N^D(s_i, \delta_i) = S_N^{TW} \cup S_N^{res}(s_i, \delta_i) \cup S_N^{corrD}(s_i, \delta_i) \cup S_N^{task}(s_i, \delta_i). \quad (4.140)$$

Składnik $S_N^{res}(s_i, \delta_i)$ opisuje naruszenia dostępności zasobów UAV wynikające z zakłóceń, $S_N^{corrD}(s_i, \delta_i)$ stanowi dynamiczne rozszerzenie zbioru S_N^{corr} z modelu ALMM-CS, uwzględniające zmiany dostępności korytarzy powietrznych, natomiast $S_N^{task}(s_i, \delta_i)$ uwzględnia zmiany w strukturze zbioru zadań.

Uwzględniając hierarchiczną strukturę wcześniejszych rozszerzeń modelu, zależność (4.140) można zapisać również w postaci rozwiniętej:

$$S_N^D(s_i, \delta_i) = S_N^{TS} \cup S_N^{corr} \cup S_N^{time} \cup S_N^{res}(s_i, \delta_i) \cup S_N^{corrD}(s_i, \delta_i) \cup S_N^{task}(s_i, \delta_i). \quad (4.141)$$

Zapis ten pokazuje, że model ALMM-D zachowuje wszystkie wcześniejsze warstwy ograniczeń, tj. ograniczenia dostępności czasowej UAV, dostępności korytarzy powietrznych oraz okien czasowych zadań, a następnie rozszerza je o zakłócenia zasobowe, przestrzenne i zadaniowe.

Stan naruszający dostępność UAV definiuje się jako:

$$S_N^{res}(s_i, \delta_i) = \left\{ (x_i, t_i) : \exists k \in K, \beta_i^k \neq 0 \wedge k \notin K_{av}(s_i, \delta_i) \right\}. \quad (4.142)$$

Zbiór $K_{av}(s_i, \delta_i)$ ma charakter operacyjny i jest niezależny od logicznego statusu UAV wynikającego ze stanu procesu. W szczególności UAV może należeć do zbioru $K_{dec}(s_i)$, lecz jednocześnie nie należeć do $K_{av}(s_i, \delta_i)$ w przypadku jego czasowej niedostępności. W konsekwencji zbiór UAV, którym można przydzielać nowe zadania, określony jest jako część wspólna:

$$K_{dec}^D(s_i, \delta_i) = K_{dec}(s_i) \cap K_{av}(s_i, \delta_i). \quad (4.143)$$

Stan naruszający dynamiczną dostępność korytarzy:

$$S_N^{corrD}(s_i, \delta_i) = \left\{ (x_i, t_i) : \exists k, \beta_i^k \neq 0 \wedge [t_i, t_i + \tau_i^k] \not\subseteq E_{\gamma(\beta_i^k)}^D(i) \right\}. \quad (4.144)$$

Stan niezgodny z aktualnym zbiorem zadań:

$$S_N^{task}(s_i, \delta_i) = \left\{ (x_i, t_i) : \exists k, \beta_i^k \notin J_i^* \right\}, \quad (4.145)$$

gdzie:

$$J_i^* = J_i \cup \{0\}. \quad (4.146)$$

W modelu ALMM-D funkcja przejścia przyjmuje postać:

$$f(u_i, x_i, t_i, \delta_i) = (x_{i+1}, t_{i+1}). \quad (4.147)$$

Oznacza to, że następny stan procesu zależy nie tylko od aktualnego stanu i decyzji, lecz również od zakłócenia ujawnionego w kroku i . Jeżeli $u_i \neq u^*$, to:

$$t_{i+1} = t_i + \Delta t_i^D, \quad (4.148)$$

gdzie:

$$\Delta t_i^D = \min^+ \{p_\delta(u_i^1, 1, i), \dots, p_\delta(u_i^m, m, i), \tau_i^1, \dots, \tau_i^m\}. \quad (4.149)$$

Wartość Δt_i^D wyznacza najbliższy moment zmiany stanu procesu po uwzględnieniu zakłócenia. Aktualizacja stanu realizowana poprzez aktualizację zbioru zadań ukończonych przebiega analogicznie jak w modelach wcześniejszych, przy czym zbiór zadań zakończonych wyznaczany jest względem zmodyfikowanego czasu realizacji:

$$J_{cmp}^D(u_i, x_i, t_i, \delta_i) = J_{cmp-x}^D(u_i, x_i, t_i, \delta_i) \cup J_{cmp-u}^D(u_i, x_i, t_i, \delta_i). \quad (4.150)$$

Dla zadań realizowanych wcześniej:

$$J_{cmp-x}^D(u_i, x_i, t_i, \delta_i) = \{\beta_i^k : 1 \leq k \leq m, \tau_i^k = \Delta t_i^D\}. \quad (4.151)$$

Dla zadań uruchomionych decyzją u_i :

$$J_{cmp-u}^D(u_i, x_i, t_i, \delta_i) = \{u_i^k : 1 \leq k \leq m, u_i^k \neq 0, p_\delta(u_i^k, k, i) = \Delta t_i^D\}. \quad (4.152)$$

Wówczas:

$$x_{i+1}^0 = x_i^0 \cup J_{cmp}^D(u_i, x_i, t_i, \delta_i). \quad (4.153)$$

Dla $k = 1, 2, \dots, m$ aktualizacja stanu UAV ma postać:

$$x_{i+1}^k = \begin{cases} (\beta_i^k, \tau_i^k - \Delta t_i^D) & \text{dla } s_i \notin S_d(k), \\ (u_i^k, p_\delta(u_i^k, k, i)) & \text{dla } s_i \in S_d(k). \end{cases} \quad (4.154)$$

Zbiór stanów docelowych zachowuje podstawową interpretację jako zbiór stanów, w których wszystkie aktualnie wymagane zadania zostały ukończone:

$$S_G^D = \{(x_i, t_i) \in S : x_i^0 = J_i\}. \quad (4.155)$$

W przypadku, gdy zadania posiadają terminy realizacji, trajektoria prowadząca do zbioru stanów docelowych musi jednocześnie spełniać ograniczenia zawarte w S_N^D . Tak skonstruowany model ALMM-D, rozszerza wcześniejsze modele o możliwość występowania zakłóceń w trakcie realizacji procesu harmonogramowania. Zakłócenia te mogą wpływać na czasy realizacji zadań, dostępność UAV, dostępność korytarzy powietrznych oraz strukturę zbioru zadań. W konsekwencji proces harmonogramowania przestaje mieć charakter statyczny, a jego przebieg wymaga bieżącej aktualizacji stanu oraz adaptacji decyzji. Wprowadzenie zakłóceń powoduje, że zbiór decyzji dopuszczalnych staje się zależny od aktualnego stanu oraz od zakłócenia ujawnionego w danym kroku procesu. Model ALMM-D stanowi zatem podstawę do budowy algorytmów reaktywnego harmonogramowania, w których decyzje podejmowane są na podstawie aktualnej informacji o stanie systemu oraz dostępności zasobów. Ponadto należy zauważyć, że w szczególnym przypadku, gdy zbiór zakłóceń jest trywialny, tj.

$$\mathcal{D} = \{0\}, \quad (4.156)$$

model ALMM-D redukuje się do deterministycznego modelu ALMM-TW. Oznacza to, że wszystkie parametry procesu, w tym czasy realizacji zadań, dostępność UAV oraz dostępność korytarzy powietrznych,

pozostają niezmiennie w czasie, a struktura modelu odpowiada wcześniej wprowadzonym rozszerzeniom ALMM-TS, ALMM-CS oraz ALMM-TW.

W przypadku wystąpienia zakłócenia w chwili t_d proces harmonogramowania podlega rekonfiguracji, której celem jest wyznaczenie nowej trajektorii dopuszczalnej przy zachowaniu ciągłości realizacji procesu. W odróżnieniu od modeli deterministycznych ALMM-TS, ALMM-CS oraz ALMM-TW, w których ewolucja procesu opisywana jest wyłącznie przez kolejne przyrosty czasu Δt_i , wynikające z dynamiki realizacji zadań oraz funkcji przejścia procesu, model ALMM-D wprowadza dodatkowo pojęcie czasu rekonfiguracji:

$$\Delta t_r = t_a - t_d, \quad (4.157)$$

gdzie:

- t_d oznacza chwilę wystąpienia zakłócenia,
- t_a oznacza chwilę aktywacji nowej trajektorii procesu.

Należy podkreślić, że czas rekonfiguracji Δt_r nie stanowi przyrostu czasu procesu w sensie funkcji przejścia modelu, lecz opisuje meta-poziom procesu sterowania związany z:

- detekcją zakłócenia,
- aktualizacją stanu systemu,
- wyznaczeniem nowej trajektorii procesu,
- synchronizacją decyzji sterujących.

W przedziale czasowym $[t_d, t_a]$ system znajduje się w stanie przejściowym, w którym część operacji może być kontynuowana zgodnie z dotychczasową trajektorią procesu, natomiast pozostałe zadania podlegają procedurze rekonfiguracji.

Zakłócenie $\delta_i \in \mathcal{D}$ powoduje dynamiczną aktualizację parametrów procesu oraz ograniczeń operacyjnych. W szczególności aktualizacji podlegają:

- dostępność UAV,
- dostępność korytarzy powietrznych,
- zbiór aktywnych zadań procesu.

W przypadku zakłóceń zasobowych dla każdego UAV $k \in K$ definiuje się dynamiczną dostępność:

$$A_k^D(i) = A_k \setminus Z_k(\delta_i), \quad (4.158)$$

gdzie $Z_k(\delta_i)$ oznacza antysłot zasobowy odpowiadający okresowi niedostępności UAV.

Dla awarii czasowej:

$$Z_k(\delta_i) = [t_d, t_{rec}], \quad (4.159)$$

natomiast dla trwałego wyłączenia UAV:

$$Z_k(\delta_i) = [t_d, \infty). \quad (4.160)$$

Analogicznie dla zakłóceń przestrzennych dynamiczna dostępność korytarzy powietrznych opisana jest zależnością:

$$E_c^D(i) = E_c \setminus Z_c(\delta_i), \quad (4.161)$$

gdzie $Z_c(\delta_i)$ oznacza fragment dostępności korytarza wyłączony z użytkowania wskutek zakłócenia.

Zakłócenia mogą również prowadzić do aktualizacji zbioru zadań:

$$J_i = J_{i-1} \cup J_i^{new} \setminus J_i^{rem}. \quad (4.162)$$

W konsekwencji zakłócenie powoduje zmianę zbioru stanów niedopuszczalnych procesu. Po rekonfiguracji zbiór ten opisujemy jako:

$$S_N^{D,a}(s_a, \delta_i) = S_N^{TS} \cup S_N^{corrD}(s_a, \delta_i) \cup S_N^{time} \cup S_N^{res}(s_a, \delta_i) \cup S_N^{task}(s_a, \delta_i), \quad (4.163)$$

gdzie poszczególne składniki odpowiadają odpowiednio:

- ograniczeniom dostępności czasowej UAV,
- dynamicznym ograniczeniom dostępności korytarzy powietrznych,
- ograniczeniom wynikającym z okien czasowych zadań,
- zakłóceniom zasobowym,
- zmianom struktury zbioru zadań.

Aktualizacja zbioru stanów niedopuszczalnych prowadzi do rekonfiguracji zbioru decyzji dopuszczalnych:

$$U_d^{D,a}(s_a, \delta_i) = \left\{ u_i \in U_p(s_a) : f(u_i, s_a, \delta_i) \notin S_N^{D,a}(s_a, \delta_i) \right\}. \quad (4.164)$$

Stan procesu inicjujący nową trajektorię oznaczamy jako:

$$s_a = (x_a, t_a), \quad (4.165)$$

gdzie:

$$x_a^0 = \{j \in J_i : j \text{ zostało zakończone do chwili } t_a\} \quad (4.166)$$

oznacza zbiór zadań ukończonych przed aktywacją nowej trajektorii procesu.

Zadania będące w trakcie realizacji nie są traktowane jako zakończone, lecz pozostają przypisane do odpowiednich UAV do czasu ich ukończenia, o ile możliwość ich dalszej realizacji nie została naruszona przez zakłócenie. Dla każdego UAV:

$$k \in K$$

realizującego zadanie określany jest pozostały czas zajętości:

$$\tau_a^k, \quad (4.167)$$

wyznaczający najwcześniejszy moment ponownej dostępności danego zasobu.

W wyniku zakłócenia identyfikowany jest zbiór zadań dotkniętych zakłóceniem:

$$J_z(\delta_i), \quad (4.168)$$

obejmujący zadania, których realizacja nie może być kontynuowana zgodnie z dotychczasową trajektorią procesu. Zadania te pozostają w zbiorze zadań niezakończonych i mogą podlegać procedurze realokacji.

Nowa trajektoria procesu:

$$\tilde{s}' = (s_a, s'_{a+1}, \dots) \quad (4.169)$$

wyznaczana jest od aktualnego stanu systemu s_a z uwzględnieniem:

- aktualnej dostępności UAV,
- dostępności korytarzy powietrznych,
- bieżącego stanu realizacji zadań,
- ograniczeń czasowych,
- nowych warunków operacyjnych wynikających z zakłócenia.

W konsekwencji mechanizm rekonfiguracji w modelu ALMM-D nie polega na ponownym wyznaczeniu trajektorii procesu od stanu początkowego, lecz na transformacji aktualnej trajektorii procesu w nową trajektorię dopuszczalną, stanowiącą kontynuację procesu od rzeczywistego stanu operacyjnego systemu.

Należy zauważyć, że przedstawione rozszerzenia modeli ALMM mają charakter hierarchiczny oraz modułarny. Oznacza to, że kolejne klasy ograniczeń operacyjnych nie definiują całkowicie niezależnych modeli procesu, lecz stanowią warstwy ograniczeń aktywowane zależnie od aktualnych warunków operacyjnych systemu UAV. W konsekwencji model ALMM może być interpretowany jako wspólny meta-model procesu harmonogramowania, natomiast modele TS, CS, TW oraz D odpowiadają kolejnym klasom aktywnych ograniczeń wpływających na zbiór decyzji dopuszczalnych oraz zbiór osiągalnych trajektorii procesu. Niech $\mathcal{M}(t) \subseteq \{TS, CS, TW\}$ oznacza zbiór aktywnych klas ograniczeń deterministycznych obowiązujących w chwili t . Wówczas aktywny zbiór stanów niedopuszczalnych można zapisać jako:

$$S_N^{\mathcal{M}}(t) = \bigcup_{m \in \mathcal{M}(t)} S_N^m. \quad (4.170)$$

W modelu ALMM-D zbiór ten zostaje rozszerzony o składniki dynamiczne wynikające z zakłóceń:

$$S_N^{D,\mathcal{M}}(s_i, \delta_i) = S_N^{\mathcal{M}}(t_i) \cup S_N^{res}(s_i, \delta_i) \cup S_N^{corrD}(s_i, \delta_i) \cup S_N^{task}(s_i, \delta_i). \quad (4.171)$$

Odpowiadający im zbiór decyzji dopuszczalnych przyjmuje postać:

$$U_d^{D,\mathcal{M}}(s_i, \delta_i) = \left\{ u_i \in U_p(s_i) : f(u_i, s_i, \delta_i) \notin S_N^{D,\mathcal{M}}(s_i, \delta_i) \right\}. \quad (4.172)$$

Oznacza to, że rekonfiguracja procesu w modelu ALMM-D może dotyczyć nie tylko zmiany trajektorii procesu, lecz również dynamicznej zmiany aktywnego zbioru ograniczeń operacyjnych. W szczególności wystąpienie zakłócenia może prowadzić do aktywacji dodatkowych ograniczeń związanych z:

- czasową niedostępnością UAV,
- zmianą dostępności korytarzy powietrznych,
- zaostreniem ograniczeń czasowych realizacji zadań,
- koniecznością uruchomienia procedur rekonfiguracji i realokacji.

W konsekwencji proces harmonogramowania zachowuje wspólną strukturę przestrzeni stanów oraz funkcji przejścia, natomiast zmianie ulega aktywny zbiór ograniczeń wpływających na dopuszczalność decyzji i trajektorii procesu. Interpretacja ta jest zgodna z algebraiczno-logicznym charakterem modeli ALMM i umożliwia modularne rozszerzanie modelu bez konieczności redefinicji podstawowej struktury procesu decyzyjnego.

W szczególności przejście od trajektorii nominalnej do trajektorii rekonfigurowanej po wystąpieniu zakłócenia może być interpretowane jako przejście procesu pomiędzy różnymi konfiguracjami aktywnych ograniczeń:

$$\mathcal{M}(t < t_d) \neq \mathcal{M}(t \geq t_d), \quad (4.173)$$

przy zachowaniu ciągłości reprezentacji stanu procesu. Oznacza to, że rekonfiguracja realizowana w modelu ALMM-D nie wymaga redefinicji modelu procesu, lecz polega na aktualizacji aktywnego zbioru ograniczeń operacyjnych oraz wyznaczeniu nowej trajektorii dopuszczalnej od aktualnego stanu systemu.

4.6 Zadanie optymalizacji w modelach ALMM

Modele algebraiczno-logiczne ALMM przedstawione w podrozdziałach 4.1–4.5 definiują proces harmonogramowania jako dyskretny proces decyzyjny, opisany poprzez przestrzeń stanów, zbiór decyzji oraz funkcję przejścia. W szczególności określają one zbiór wszystkich dopuszczalnych trajektorii procesu wynikających z przyjętych ograniczeń operacyjnych. Z punktu widzenia praktycznego zastosowania modeli ALMM kluczowym zagadnieniem jest wybór trajektorii optymalnej względem przyjętego kryterium jakości.

Niech $\tilde{s} = (s_0, s_1, \dots, s_\omega)$ oznacza trajektorię stanów procesu, a $\tilde{u} = (u_0, u_1, \dots, u_{\omega-1})$ odpowiadającą jej trajektorię decyzji. W modelu uwzględniającym zakłócenia zbiór trajektorii dopuszczalnych definiujemy jako:

$$\mathcal{T}_{ad}^D = \left\{ \tilde{s} : \begin{array}{l} s_0 - \text{stan początkowy,} \\ s_{i+1} = f(u_i, s_i, \delta_i), \\ \tilde{s} : u_i \in U_d^D(s_i, \delta_i), \\ s_i \notin S_N^D(s_i, \delta_i), \quad i = 0, \dots, \omega, \\ s_\omega \in S_G^D \end{array} \right\}. \quad (4.174)$$

Zbiór ten obejmuje wszystkie trajektorie zgodne z dynamiką modelu ALMM-D oraz spełniające ograniczenia wynikające z dostępności UAV, dostępności korytarzy powietrznych, okien czasowych oraz zakłóceń procesu. Dopełnieniem zbioru trajektorii dopuszczalnych są trajektorie niedopuszczalne, tj. takie, które w pewnym kroku prowadzą do stanu należącego do zbioru S_N^D lub wynikają z wyboru decyzji spoza zbioru

$U_d^D(s_i, \delta_i)$. Należy jednak podkreślić, że w modelach ALMM trajektorie niedopuszczalne nie są jawnie generowane, ponieważ zbiór decyzji dopuszczalnych konstruowany jest w taki sposób, aby eliminować decyzje prowadzące do stanów niedopuszczalnych. W konsekwencji proces przebiega wyłącznie w przestrzeni stanów dopuszczalnych. Natomiast w kontekście implementacyjnym możliwe jest wykorzystanie pamięci trajektorii niedopuszczalnych lub ich fragmentów w celu ograniczenia przestrzeni przeszukiwania. Takie podejście pozwala na eliminację powtarzających się sekwencji decyzji prowadzących do stanów niedopuszczalnych oraz stanowi podstawę dla mechanizmów przycinania przestrzeni stanów i uczenia się heurystyk.

Na zbiorze trajektorii dopuszczalnych definiujemy funkcję celu:

$$Q(\tilde{u}) = \Phi(\tilde{s}, \tilde{u}), \quad (4.175)$$

która przypisuje każdej trajektorii decyzji wartość liczbową interpretowaną jako miarę jakości harmonogramu.

Podstawowym kryterium jakości jest minimalizacja całkowitego czasu realizacji procesu. W modelu ALMM kryterium to ma postać addytywną:

$$Q(\tilde{u}) = \sum_{i=0}^{\omega-1} \Delta t_i, \quad (4.176)$$

gdzie Δt_i oznacza przyrost czasu pomiędzy kolejnymi stanami procesu. Równoważnie:

$$Q(\tilde{u}) = t_\omega, \quad (4.177)$$

gdzie t_ω oznacza moment osiągnięcia stanu końcowego.

W modelu ALMM-D dopuszcza się występowanie decyzji realokacyjnych. W celu ograniczenia ich nadmiernego wykorzystania funkcję celu można rozszerzyć o składnik penalizujący realokacje:

$$Q(\tilde{u}) = \sum_{i=0}^{\omega-1} (\Delta t_i + \lambda \cdot \Delta R_i), \quad (4.178)$$

gdzie

$$\Delta R_i = \begin{cases} 1 & \text{jeżeli w kroku } i \text{ wykonano realokację,} \\ 0 & \text{w przeciwnym przypadku.} \end{cases} \quad (4.179)$$

W przypadku $\lambda = 0$ kryterium redukuje się do klasycznego problemu minimalizacji czasu realizacji, natomiast dla $\lambda > 0$ model preferuje rozwiązania ograniczające liczbę realokacji. Rozważane kryterium jakości spełnia istotne własności charakterystyczne dla modeli ALMM. Powiemy, że kryterium Q jest separowalne, jeżeli jego wartość może być wyznaczana rekurencyjnie:

$$Q_{i+1} = Q_i + \Delta Q(u_i, s_i), \quad (4.180)$$

gdzie $\Delta Q(u_i, s_i)$ oznacza przyrost wartości funkcji celu w stanie s_i . W przypadku minimalizacji czasu realizacji zachodzi:

$$\Delta Q(u_i, s_i) = \Delta t_i, \quad (4.181)$$

co prowadzi do postaci addytywnej:

$$Q(\tilde{u}) = \sum_{i=0}^{\omega-1} \Delta t_i. \quad (4.182)$$

W zależności od przyjętego kryterium rozważane mogą być różne postacie funkcji celu.

Najczęściej stosowanym kryterium jest minimalizacja czasu zakończenia procesu:

$$Q_1(\tilde{u}) = t_\omega, \quad (4.183)$$

gdzie t_ω oznacza czas osiągnięcia stanu końcowego.

Alternatywnie można rozważyć minimalizację liczby zdarzeń:

$$Q_2(\tilde{u}) = \omega, \quad (4.184)$$

gdzie ω oznacza długość trajektorii procesu.

W ogólnym przypadku funkcja celu może mieć postać złożoną, uwzględniającą wiele aspektów:

$$Q(\tilde{u}) = \alpha t_\omega + \beta \omega + \gamma C(\tilde{u}), \quad (4.185)$$

gdzie $C(\tilde{u})$ może oznaczać np. koszt energetyczny, ryzyko operacyjne lub inne miary jakości harmonogramu, a α, β, γ są wagami.

Kryterium jest monotonicznie rosnące wzdłuż trajektorii procesu:

$$Q_{i+1} \geq Q_i, \quad (4.186)$$

co wynika z nieujemności przyrostów czasu $\Delta t_i \geq 0$. Własności te umożliwiają zastosowanie klasycznych metod optymalizacji dyskretnych procesów decyzyjnych, takich jak programowanie dynamiczne, przeszukiwanie przestrzeni stanów czy metody typu branch-and-bound.

Zadanie harmonogramowania w modelach ALMM formułuje się jako problem wyboru trajektorii optymalnej:

$$\tilde{u}^* = \arg \min_{\tilde{u} \in \mathcal{T}_{ad}^D} Q(\tilde{u}). \quad (4.187)$$

Odpowiadająca jej trajektoria stanów $\tilde{s}^*$ określa optymalny przebieg procesu realizacji zadań.

$$(\tilde{s}^*, \tilde{u}^*) = \arg \min_{(\tilde{s}, \tilde{u}) \in \mathcal{T}_{ad}^D} Q(\tilde{u}). \quad (4.188)$$

Proces decyzyjny w modelach ALMM można interpretować jako przeszukiwanie grafu stanów, w którym:

- wierzchołki odpowiadają stanom procesu,
- łuki odpowiadają decyzjom,
- eliminowane są trajektorie prowadzące do stanów niedopuszczalnych,
- rozwiązaniem jest ścieżka prowadząca od stanu początkowego do stanu docelowego o minimalnej wartości funkcji celu.

Wprowadzenie kolejnych rozszerzeń modelu (TS, CS, TW, D) prowadzi do stopniowego zawężania zbioru trajektorii dopuszczalnych, natomiast mechanizm realokacji umożliwia dynamiczną modyfikację trajektorii w odpowiedzi na zakłócenia procesu. Addytywna i separowalna postać funkcji celu sprawia, że model ALMM stanowi dogodną podstawę do budowy efektywnych algorytmów harmonogramowania w warunkach deterministycznych oraz dynamicznych.

Rozdział 5

Metodologia i algorytmy rozwiązywania problemu harmonogramowania zadań dla floty UAV

Efektywne harmonogramowanie zadań dla floty UAV wymaga opracowania metod decyzyjnych zdolnych do uwzględnienia licznych ograniczeń przestrzennych, czasowych oraz operacyjnych wynikających ze specyfiki środowiska wykonawczego. Do kluczowych czynników determinujących złożoność problemu należą w szczególności ograniczona przepustowość korytarzy powietrznych, dostępność przedziałów czasowych realizacji, heterogeniczność i zmienność zasobów UAV oraz możliwość występowania zakłóceń wpływających na przebieg misji. Problem ten należy do klasy problemów obliczeniowo trudnych, a jego warianty z ograniczeniami czasowo-przestrzennymi mają charakter NP-trudny.

W niniejszym rozdziale przedstawiono metodykę rozwiązywania problemu harmonogramowania zadań UAV opartą na modelach algebraiczno-logicznych zaproponowanych w Rozdziale 4. Zaprezentowane podejście obejmuje zestaw algorytmów konstrukcyjnych, heurystyk redukcji przestrzeni decyzji oraz procedur dynamicznej rekonfiguracji harmonogramu, tworzących łącznie spójny mechanizm generowania i adaptacji planu operacyjnego.

Struktura rozdziału odpowiada kolejnym etapom procesu harmonogramowania. W pierwszej części omówiono własności problemu oraz wynikające z nich założenia algorytmiczne. Następnie przedstawiono heurystykę redukcji przestrzeni decyzji oraz algorytmy planowania, przydziału zadań do slotów czasowych i generowania rekomendowanych trajektorii lotu. Końcowa część rozdziału poświęcona została mechanizmom dynamicznego harmonogramowania, obejmującym predykcję zakłóceń oraz procedury realokacji zadań w czasie rzeczywistym.

Przedstawiona metodologia stanowi operacyjną implementację modeli ALMM-TS, ALMM-CS, ALMM-TW oraz ALMM-D, umożliwiając przejście od formalnego opisu procesu decyzyjnego do procedur obliczeniowych służących konstrukcji oraz adaptacji harmonogramu misji UAV.

5.1 Własności problemu i wynikające z nich założenia algorytmiczne

Problem harmonogramowania zadań dla floty UAV obejmuje wyznaczenie takiego przebiegu procesu decyzyjnego, w którym zadania zostają przypisane do dostępnych jednostek UAV oraz zrealizowane w dopuszczalnych przedziałach czasowo-przestrzennych. Zgodnie z modelami przedstawionymi w Rozdziale 4, proces ten interpretowany jest jako dyskretny proces decyzyjny, w którym kolejne decyzje u_i powodują przejście ze stanu s_i do stanu s_{i+1} zgodnie z funkcją przejścia f .

Kluczową własnością rozważanego problemu jest kaskadowe zawężanie przestrzeni decyzji. W modelu bazowym rozważany jest zbiór decyzji możliwych $U_p(s_i)$, natomiast kolejne ograniczenia operacyjne prowadzą do wyznaczenia coraz węższych zbiorów decyzji dopuszczalnych. Zależność tę można zapisać następująco:

$$U_d^D(s_i, \delta_i) \subseteq U_d^{TW}(s_i) \subseteq U_d^{CS}(s_i) \subseteq U_d^{TS}(s_i) \subseteq U_p(s_i). \quad (5.1)$$

Zapis ten odzwierciedla przyjętą w Rozdziale 4 kaskadową strukturę modeli ALMM, w której każdy kolejny wariant wprowadza dodatkowe ograniczenia względem wariantu poprzedniego. W konsekwencji model dynamiczny ALMM-D stanowi najbardziej restrykcyjne ujęcie procesu, gdyż dodatkowo uwzględnia wpływ zakłóceń δ_i .

Oznacza to, że każda procedura algorytmiczna stosowana w dalszej części rozdziału musi respektować ograniczenia wynikające z dostępności UAV, dostępności korytarzy powietrznych, okien czasowych zadań oraz, w przypadku modelu dynamicznego, zakłóceń ujawniających się w trakcie realizacji procesu. W konsekwencji algorytmy nie powinny generować decyzji spoza właściwego zbioru decyzji dopuszczalnych, lecz operować na jego zawężeniach lub heurystycznych przybliżeniach.

Z punktu widzenia konstrukcji algorytmów istotne są następujące własności problemu:

- zadania są niepodzielne, a ich realizacja przez UAV nie może zostać przerwana w modelach deterministycznych ALMM-TS, ALMM-CS oraz ALMM-TW;
- każde zadanie może zostać przypisane co najwyżej do jednego UAV w danym kroku decyzyjnym;
- realizacja zadania musi mieścić się w dopuszczalnym przedziale dostępności czasowej UAV;
- zadanie wymagające określonego korytarza powietrznego może być realizowane wyłącznie wtedy, gdy cały czas jego wykonania mieści się w efektywnej dostępności tego korytarza;
- w przypadku występowania okien czasowych zadanie może zostać rozpoczęte nie wcześniej niż w chwili $r(j)$ oraz musi zakończyć się nie później niż w chwili $d(j)$;
- w modelu dynamicznym wystąpienie zakłócenia δ_i może zmienić dostępność UAV, dostępność korytarzy, czas realizacji zadań lub aktualny zbiór zadań.

Ze względu na złożoność obliczeniową problemu przyjęto podejście heurystyczne. Nie zakłada się pełnego przeszukiwania całej przestrzeni $U_d(s_i)$, lecz zastosowanie mechanizmów redukcji przestrzeni decyzji oraz konstrukcyjnego wyznaczania trajektorii dopuszczalnej. W szczególności w kolejnych etapach wykorzystywane są:

- heurystyka redukcji przestrzeni decyzji, której zadaniem jest wyznaczenie zawężonego zbioru kandydackiego $\hat{U}_d^{CS}(s_i)$;
- algorytm planowania zadań, który wybiera decyzje sterujące z przestrzeni kandydackiej i konstruuje trajektorię decyzji $\tilde{u}$;
- algorytm przydziału zadań do slotów czasowych, który osadza zaakceptowane decyzje w konkretnych przedziałach realizacji;
- algorytm generowania rekomendowanej trajektorii lotu, który przekształca harmonogram czasowo-zadaniowy w reprezentację przestrzenno-czasową;
- mechanizmy dynamicznej realokacji, które umożliwiają modyfikację trajektorii procesu w przypadku wystąpienia zakłóceń.

Podstawowym kryterium konstrukcji harmonogramu jest uzyskanie trajektorii dopuszczalnej o możliwie korzystnej wartości funkcji celu, w szczególności minimalizacja czasu zakończenia procesu t_ω , ograniczenie przestojów UAV oraz równomierne wykorzystanie dostępnych zasobów. Przyjęta metodyka ma charakter hierarchiczny: najpierw redukowana jest przestrzeń decyzji, następnie wyznaczane są decyzje harmonogramowe, dalej następuje ich osadzenie czasowe, a na końcu generowana jest operacyjna trajektoria lotu. W wariantcie dynamicznym ten sam schemat jest uzupełniany o predykcję zakłóceń oraz procedury realokacji zadań.

5.2 Heurystyka redukcji przestrzeni decyzji

W celu ograniczenia złożoności obliczeniowej procesu harmonogramowania wprowadza się heurystykę redukcji przestrzeni decyzji. Jej zadaniem nie jest wyznaczenie kompletnego harmonogramu, lecz zawężenie zbioru decyzji rozważanych następnie przez algorytm planowania zadań UAV. Heurystyka ta jest zgodna z kaskadową strukturą modeli ALMM przedstawioną w Rozdziale 4, ponieważ nie zmienia definicji zbiorów decyzji dopuszczalnych, lecz wyznacza ich obliczeniowo użyteczne podzbiory kandydackie.

Dla danego stanu procesu $s_i = (x_i, t_i)$ punktem wyjścia jest zbiór decyzji możliwych $U_p(s_i)$, który następnie podlega zawężeniu przez ograniczenia właściwe dla modeli ALMM-TS, ALMM-CS, ALMM-TW oraz ALMM-D. W przypadku modelu ALMM-CS rozważane są wyłącznie decyzje należące do zbioru $U_d^{CS}(s_i)$. Bezpośrednie przeszukiwanie całego zbioru $U_d^{CS}(s_i)$ może być kosztowne obliczeniowo, zwłaszcza dla dużej liczby zadań, UAV oraz przedziałów dostępności. Dlatego przed właściwym etapem konstrukcji harmonogramu tworzony jest zawężony zbiór decyzji kandydackich:

$$\hat{U}_d^{CS}(s_i) \subseteq U_d^{CS}(s_i). \quad (5.2)$$

Redukcja przestrzeni decyzji opiera się na trzech zasadach:

- preferowaniu zadań o większym szacowanym czasie realizacji;
- preferowaniu wcześniejszych przedziałów dostępności;

- eliminowaniu przypisań niespełniających ograniczeń dostępności UAV oraz korytarzy powietrznych.

Dla każdego zadania $j \in J \setminus x_i^0$ wyznacza się szacowany czas realizacji:

$$\hat{p}(j) = \min_{k \in K} p(j, k), \quad (5.3)$$


a następnie porządkuje się zadania malejąco według wartości $\hat{p}(j)$. Dla każdego UAV $k \in K_{dec}(s_i)$ oraz zadania j sprawdzany jest warunek zgodności z efektywną dostępnością korytarza wymaganego przez to zadanie:

$$[t_i, t_i + p(j, k)] \subseteq E_{\gamma(j)}. \quad (5.4)$$

Jeżeli warunek ten nie jest spełniony, przypisanie zadania j do UAV k jest eliminowane z dalszego rozważania. Jeżeli warunek jest spełniony, para kandydacka (j, k) może zostać wykorzystana do budowy decyzji należącej do zawężonego zbioru $\hat{U}_d^{CS}(s_i)$. W konsekwencji otrzymuje się zbiór:

$$\hat{U}_d^{CS}(s_i) = \left\{ u_i \in U_d^{CS}(s_i) : \begin{array}{l} \text{każde niezerowe przypisanie } u_i^k = j \text{ spełnia warunek dostępności} \\ \text{korytarza } E_{\gamma(j)} \text{ oraz należy do zbioru kandydatów} \\ \text{uporządkowanych według przyjętej funkcji oceny heurystycznej.} \end{array} \right\}. \quad (5.5)$$

Etapy redukcji przestrzeni decyzji przedstawiono na Rysunku 5.1.



Rysunek 5.1: Etapy heurystyki redukcji przestrzeni decyzji z uwzględnieniem korytarzy powietrznych.

Schemat przedstawiony na Rysunku 5.1 należy interpretować jako etap przygotowawczy poprzedzający właściwe konstruowanie harmonogramu. W pierwszym kroku analizowane są dane wejściowe, tj. zbiór zadań J , zbiór UAV K , przedziały dostępności UAV $\{[B^r, F^r]\}_{r=1}^{ILs}$, zbiór korytarzy C oraz funkcja przypisania korytarzy $\gamma : J \rightarrow C$. Następnie tworzone są podzbiory zadań kandydackich, które mogą być rozważane w kolejnych stanach decyzyjnych. W dalszym kroku następuje wstępna ocena przypisań zadanie-UAV oraz ich zgodności z przedziałami dostępności.

Przypisania uzyskane na tym etapie nie stanowią jeszcze końcowego harmonogramu, lecz służą do określenia, które decyzje powinny zostać zachowane w zawężonej przestrzeni przeszukiwania. Następnie wykonywana jest lokalna korekta kolejności kandydatów, polegająca na preferowaniu wcześniejszych dostępnych przedziałów, o ile nie narusza to ograniczeń modelu. Kończącym etapem jest weryfikacja zgodności kandydatów z ograniczeniami dostępności korytarzy powietrznych.

Jeżeli zbiór kandydacki nie pozwala na dalszą konstrukcję harmonogramu, parametry heurystyki mogą zostać zaktualizowane, np. przez zwiększenie liczby rozważanych kandydatów, dopuszczenie późniejszych przedziałów czasowych albo zmianę kolejności rozpatrywania zadań. Wynikiem działania heurystyki jest uporządkowany zbiór decyzji kandydackich $\hat{U}_d^{CS}(s_i)$, który zostaje przekazany do algorytmu planowania zadań UAV jako zawężona przestrzeń przeszukiwania.

Należy podkreślić, że heurystyka redukcji przestrzeni decyzji nie zastępuje formalnej definicji zbioru decyzji dopuszczalnych $U_d^{CS}(s_i)$, lecz stanowi jego praktyczne, obliczeniowo użyteczne zawężenie:

$$\hat{U}_d^{CS}(s_i) \subseteq U_d^{CS}(s_i). \quad (5.6)$$

W przypadku uwzględnienia okien czasowych lub zakłóceń analogiczne zawężenie może zostać zastosowane odpowiednio do zbiorów $U_d^{TW}(s_i)$ oraz $U_d^D(s_i, \delta_i)$.

5.3 Algorytm planowania zadań UAV z ograniczeniami korytarzy powietrznych

W niniejszym podrozdziale przedstawiono heurystyczny algorytm harmonogramowania zadań UAV zgodny z algebraiczno-logicznym modelem ALMM-CS opisanym w podrozdziale 4.3. Celem algorytmu jest konstrukcja dopuszczalnej trajektorii procesu harmonogramowania uwzględniającej ograniczenia wynikające z dostępności czasowej UAV oraz dostępności współdzielonych korytarzy powietrznych.

Zgodnie z modelem ALMM-CS każde zadanie $j \in J$ może zostać przypisane do UAV $k \in K$ wyłącznie wtedy, gdy spełnione są jednocześnie następujące warunki:

- UAV k znajduje się w stanie decyzyjnym, tj. $k \in K_{dec}(s_i)$,
- zadanie nie zostało wcześniej ukończzone ani nie jest aktualnie realizowane,
- cały czas realizacji zadania mieści się w dostępnym przedziale czasowym UAV,
- cały czas realizacji zadania mieści się w efektywnej dostępności wymaganego korytarza powietrznego,
- realizacja zadania nie narusza warunku współdzielenia korytarzy powietrznych.

Formalnie oznacza to, że każda decyzja konstrukcyjna algorytmu musi należeć do zbioru decyzji dopuszczalnych $u_i \in U_d^{CS}(s_i)$. W celu weryfikacji możliwości realizacji zadania j przez UAV k sprawdzany jest warunek $[t_i, t_i + p(j, k)] \subseteq E_{\gamma(j)}$, gdzie $E_{\gamma(j)}$ oznacza efektywną dostępność korytarza wymaganego przez zadanie j . Proponowany algorytm ma charakter konstrukcyjno-iteracyjny. W każdej iteracji budowana jest decyzja sterująca u_i , prowadząca do kolejnego stanu procesu zgodnie z funkcją przejścia $s_{i+1} = f(u_i, s_i)$. W algorytmie wykorzystuje się zawężony zbiór decyzji kandydackich wyznaczony w poprzednim podrozdziale, w którym jednym z kryteriów porządkowania zadań jest heurystyka typu LPT, oparta na malejącym uporządkowaniu zadań według szacowanego czasu realizacji. W szczególności możliwe jest wykorzystanie porządku $\hat{p}(j) = \min_{k \in K} p(j, k)$, co odpowiada przybliżonemu oszacowaniu trudności realizacji zadania. Heurystyka preferuje wcześniejsze przydzielanie zadań o największym

czasie realizacji, co zwiększa prawdopodobieństwo znalezienia rozwiązania dopuszczalnego w warunkach ograniczonej dostępności zasobów czasowo-przestrzennych. Projektowany algorytm harmonogramowania przedstawiono w Algorytmie 2.

Algorytm 2 Harmonogramowanie zadań UAV z uwzględnieniem ograniczeń korytarzy powietrznych

- 1: **Dane wejściowe:** zbiór zadań J , zbiór UAV K , zbiór korytarzy C , funkcja przypisania korytarzy $\gamma : J \rightarrow C$, czasy realizacji $p(j, k)$, przedziały dostępności UAV oraz korytarzy
 - 2: **Dane wyjściowe:** trajektoria decyzji $\tilde{u}$, trajektoria stanów $\tilde{s}$ oraz wstępny harmonogram decyzyjny
 - 3: Wyznacz efektywną dostępność korytarzy E_c dla każdego $c \in C$
 - 4: Zainicjalizuj stan początkowy procesu $s_0 = (x_0, t_0)$
 - 5: $\tilde{u} \leftarrow \emptyset, \tilde{s} \leftarrow (s_0)$
 - 6: Ustaw licznik iteracji $i \leftarrow 0$
 - 7: **while** $s_i \notin S_G$ **do**
 - 8: Wyznacz zbiór UAV decyzyjnych: $K_{dec}(s_i) = \{k \in K : \tau_i^k = 0\}$
 - 9: Wyznacz zbiór zadań niezakończonych: $J_i^{unf} = J \setminus x_i^0$
 - 10: Wyznacz zawężony zbiór decyzji kandydackich: $\hat{U}_d^{CS}(s_i) \subseteq U_d^{CS}(s_i)$ zgodnie z heurystyką redukcji przestrzeni decyzji
 - 11: **if** $\hat{U}_d^{CS}(s_i) = \emptyset$ **then**
 - 12: Zwróć informację o braku decyzji dopuszczalnej
 - 13: **Stop**
 - 14: **end if**
 - 15: Wybierz decyzję kandydacką: $u_i \in \hat{U}_d^{CS}(s_i)$ minimalizującą lokalne kryterium wyboru, np. najwcześniejsze zakończenie, najmniejszy przestój UAV lub największe wykorzystanie dostępnych slotów
 - 16: **if** $u_i \notin U_d^{CS}(s_i)$ **then**
 - 17: Zwróć informację o naruszeniu warunków dopuszczalności
 - 18: **Stop**
 - 19: **end if**
 - 20: Wyznacz kolejny stan: $s_{i+1} = f(u_i, s_i)$
 - 21: Dodaj decyzję u_i do trajektorii decyzji $\tilde{u}$
 - 22: Dodaj stan s_{i+1} do trajektorii stanów $\tilde{s}$
 - 23: $i \leftarrow i + 1$
 - 24: **end while**
 - 25: Oblicz wartość funkcji celu: $Q(\tilde{u}) = t_\omega$
 - 26: Zwróć wstępny harmonogram decyzyjny, trajektorię decyzji $\tilde{u}$ oraz trajektorię stanów $\tilde{s}$
-

Przedstawiony algorytm realizuje konstrukcję harmonogramu zgodnie z mechanizmem sekwencyjnego przeszukiwania zawężonej przestrzeni decyzji kandydackich $\hat{U}_d^{CS}(s_i)$, stanowiącej heurystyczne przybliżenie pełnego zbioru decyzji dopuszczalnych modelu ALMM-CS. W każdej iteracji wyznaczany jest zawężony zbiór decyzji kandydackich $\hat{U}_d^{CS}(s_i)$, a następnie wybierana jest jedna decyzja sterująca u_i , która spełnia warunki dopuszczalności modelu ALMM-CS i prowadzi do kolejnego stanu procesu. Algorytm konstruuje trajektorię procesu $\tilde{s} = (s_0, s_1, \dots, s_\omega)$, oraz odpowiadającą jej trajektorię decyzji $\tilde{u} = (u_0, u_1, \dots, u_{\omega-1})$, które spełniają warunki dopuszczalności modelu ALMM-CS. Zastosowanie heurystyki typu LPT pozwala ograniczyć ryzyko późniejszej niewykonalności harmonogramu poprzez wcześniejsze planowanie zadań najbardziej wymagających czasowo. Jednocześnie zachłanny charakter konstruk-

cji powoduje, że algorytm nie gwarantuje wyznaczenia rozwiązania optymalnego globalnie, lecz umożliwia efektywne generowanie rozwiązań wysokiej jakości w czasie akceptowalnym obliczeniowo dla problemów o dużej skali.

Przedstawiony algorytm stanowi podstawę do dalszych rozszerzeń uwzględniających dodatkowe ograniczenia operacyjne, w szczególności okna czasowe zadań oraz dynamiczne zakłócenia procesu, które zostaną uwzględnione w kolejnych podrozdziałach.

5.4 Algorytm przydziału zadań do slotów czasowych UAV

Algorytm przydziału zadań do slotów czasowych UAV stanowi etap wykonawczy względem algorytmu planowania przedstawionego w podrozdziale 5.3. W odróżnieniu od heurystyki redukcji przestrzeni decyzji, która wyznacza zawężony zbiór decyzji kandydackich $\hat{U}_d^{CS}(s_i)$, niniejszy algorytm operuje na trajektorii decyzji zaakceptowanych przez algorytm planowania, tj. $\tilde{u} = (u_0, u_1, \dots, u_{\omega-1})$.

W kontekście algebraiczno-logicznego modelu procesu decyzyjnego etap ten odpowiada uszczegółowieniu trajektorii decyzji poprzez wyznaczenie dokładnych momentów rozpoczęcia i zakończenia realizacji zadań wewnątrz agregowanych przedziałów dostępności UAV i korytarzy powietrznych. Oznacza to przejście od logicznego przypisania zadanie–UAV do pełnej reprezentacji czasowo-przestrzennej harmonogramu operacyjnego.

Rozdzielenie etapu planowania i osadzania slotowego pozwala oddzielić problem kombinatorycznego wyboru decyzji harmonogramowych od problemu dokładnego pozycjonowania czasowego zadań, co zmniejsza złożoność przestrzeni przeszukiwania oraz upraszcza konstrukcję harmonogramu szczegółowego.

Algorytm realizuje procedurę lokalnego dopasowania czasowego poprzez analizę wszystkich dostępnych przedziałów pracy UAV oraz wybór najwcześniejszego dopuszczalnego slotu realizacji dla każdego zadania. Przydział zadania do slotu jest akceptowany wyłącznie wtedy, gdy spełnione są jednocześnie następujące warunki:

- czas realizacji zadania mieści się w przedziale dostępności czasowej rozważanego UAV,
- realizacja zadania nie narusza dostępności wymaganego korytarza powietrznego,
- realizacja zadania nie powoduje konfliktu z innymi wcześniej osadzonymi zadaniami tego UAV,
- zachowana zostaje zgodność z lokalnymi ograniczeniami kolejności realizacji zadań.

W przypadku braku możliwości osadzenia zadania w aktualnie analizowanym slocie algorytm przeszukuje kolejne dostępne przedziały czasowe. Jeżeli nie istnieje żaden dopuszczalny slot realizacji, dana decyzja zostaje oznaczona jako niemożliwa do osadzenia czasowego i przekazywana do ponownej analizy w nadrzędnym mechanizmie planowania.

Przyjęte podejście ma charakter zachłanny i lokalny, dzięki czemu umożliwia efektywne czasowo osadzanie decyzji harmonogramowych przy zachowaniu zgodności z ograniczeniami modelu ALMM-CS. Algorytm ten stanowi kluczowy element konstrukcji trajektorii dopuszczalnej procesu harmonogramowania, ponieważ pozwala przejść od decyzji zadanie–UAV do pełnej reprezentacji czasowo-przestrzennej planu

operacyjnego. Formalny przebieg procedury przedstawiono w Algorytmie 3. Przez $t_{\text{free}}(k, \mathcal{H})$ oznacza się najwcześniejszą chwilę, od której UAV k jest dostępny po uwzględnieniu zadań już osadzonych w harmonogramie $\mathcal{H}$.

Algorytm 3 Algorytm przydziału zadań do slotów czasowych UAV

```

1: Wejście:
2: Trajektoria decyzji zaakceptowanych przez algorytm planowania  $\tilde{u} = (u_0, u_1, \dots, u_{\omega-1})$ 
3: Zbiór przedziałów dostępności UAV  $\{[B_k^r, F_k^r]\}$ 
4: Efektywne przedziały dostępności korytarzy  $\{E_c\}_{c \in C}$ 
5: Wyjście:
6: Dopuszczalny harmonogram slotowy  $\mathcal{H}$ 
7:  $\mathcal{H} \leftarrow \emptyset$ 
8: for każda decyzja  $u_i \in \tilde{u}$  do
9:   for każde przypisanie  $u_i^k = j$ , gdzie  $j \neq 0$  do
10:    Wyznacz uporządkowany zbiór dostępnych slotów UAV  $k$ 
11:    for każdy slot  $[B_k^r, F_k^r]$  do
12:      Wyznacz najwcześniejszy możliwy czas rozpoczęcia:  $t_{\text{start}} = \max\{B_k^r, t_{\text{free}}(k, \mathcal{H})\}$ 
13:      if  $[t_{\text{start}}, t_{\text{start}} + p(j, k)] \subseteq [B_k^r, F_k^r]$  then
14:        if  $[t_{\text{start}}, t_{\text{start}} + p(j, k)] \subseteq E_{\gamma(j)}$  then
15:          if brak konfliktu z zadaniami już osadzonymi w  $\mathcal{H}$  then
16:            Osadź zadanie  $j$  realizowane przez UAV  $k$  w slotcie  $r$ 
17:            Zapisz przedział realizacji:  $[t_{\text{start}}, t_{\text{start}} + p(j, k)]$ 
18:            Zaktualizuj harmonogram  $\mathcal{H}$ 
19:          break
20:        end if
21:      end if
22:    end if
23:  end for
24:  if zadanie  $j$  nie zostało osadzone then
25:    Oznacz decyzję  $u_i$  jako wymagającą ponownej analizy
26:  end if
27: end for
28: end for
29: return  $\mathcal{H}$ 

```

Przedstawiony algorytm realizuje deterministyczne osadzanie decyzji harmonogramowych w dostępnych przedziałach czasowych UAV, stanowiąc etap uszczegółowienia trajektorii decyzji wygenerowanej przez algorytm planowania. Uzyskany harmonogram slotowy stanowi bezpośrednie wejście do procedury generowania trajektorii lotu opisanej w kolejnym podrozdziale.

5.5 Algorytm generowania trajektorii lotu UAV

Po wyznaczeniu dopuszczalnego harmonogramu slotowego kolejnym etapem procesu planowania jest wygenerowanie fizycznych trajektorii lotu dla poszczególnych jednostek UAV. Zadaniem tego etapu jest transformacja harmonogramu czasowo-zadaniowego w pełną reprezentację przestrzenno-czasową realizacji misji, obejmującą sekwencję punktów trajektorii, segmentów korytarzy powietrznych oraz czasy przelotu pomiędzy kolejnymi punktami nawigacyjnymi.

W przeciwieństwie do wcześniejszych etapów planowania, które operują na abstrakcyjnych decyzjach harmonogramowych i przedziałach czasowych, niniejszy algorytm realizuje przestrzenną konkretyzację przydzielonych zadań poprzez konstrukcję trajektorii lotu zgodnych z geometrią przestrzeni operacyjnej. Generowane trajektorie muszą pozostawać zgodne zarówno z ograniczeniami przestrzennymi, jak i z przedziałami czasowymi wynikającymi z harmonogramu slotowego.

Przestrzeń operacyjna modelowana jest jako skierowany graf $G = (V, E)$, gdzie V oznacza zbiór punktów nawigacyjnych, natomiast E reprezentuje dopuszczalne segmenty przelotu odpowiadające fragmentom dostępnych korytarzy powietrznych. Dla każdego UAV generowana trajektoria stanowi uporządkowaną sekwencję segmentów lotu: $T_k = (v_1, v_2, \dots, v_m)$, gdzie $v_i \in V$ oznacza kolejne punkty trajektorii. Generowanie trajektorii odbywa się przy spełnieniu następujących warunków:

- trajektoria musi być zgodna z przypisanym harmonogramem slotowym,
- wszystkie segmenty trajektorii muszą należeć do dostępnych krawędzi grafu przestrzeni operacyjnej,
- czas realizacji trajektorii nie może przekroczyć długości przypisanego slotu czasowego,
- zachowana musi być separacja przestrzenna i czasowa pomiędzy UAV,
- trajektoria musi respektować ograniczenia dynamiczne platformy UAV (prędkość, zasięg, czas lotu).

Dla każdego zadania j przypisanego do UAV k oraz osadzonego w przedziale czasowym $[B_j, F_j] \subseteq \mathcal{H}$ wyznaczana jest ścieżka $P_{k,j} = \text{Path}(v_{start}^j, v_{goal}^j)$, łącząca punkt początkowy i końcowy zadania w grafie przestrzeni operacyjnej. Funkcja $\text{Path}(\cdot)$ oznacza procedurę wyznaczania dopuszczalnej ścieżki w grafie przestrzeni operacyjnej, np. z wykorzystaniem algorytmu najkrótszej ścieżki lub heurystycznej procedury wyboru trasy. Następnie wyznaczany jest szacowany czas realizacji trajektorii $t_{\text{traj}}(P_{k,j})$, który musi spełniać warunek $t_{\text{traj}}(P_{k,j}) \leq F_j - B_j$.

W przypadku wykrycia konfliktu przestrzennego, przeciążenia segmentu korytarza lub niespełnienia ograniczenia czasowego algorytm dokonuje lokalnej korekty trajektorii poprzez:

- wybór alternatywnej ścieżki w grafie przestrzeni operacyjnej,
- lokalne przesunięcie czasowe trajektorii w granicach przypisanego slotu,
- zgłoszenie konfliktu do nadrzędnego modułu harmonogramowania, jeżeli nie istnieje trajektoria dopuszczalna.

Formalny przebieg procedury przedstawiono w Algorytmie 4.

Algorytm 4 Algorytm generowania trajektorii lotu UAV

```


1: Wejście:
2: Harmonogram slotowy  $\mathcal{H}$ 
3: Graf przestrzeni powietrznej  $G = (V, E)$ 
4: Parametry dynamiczne UAV
5: Wyjście:
6: Zbiór trajektorii lotu  $\mathcal{T}$ 
7:  $\mathcal{T} \leftarrow \emptyset$ 
8: for każdy UAV  $k \in K$  do
9:   Pobierz uporządkowaną listę zadań przypisanych do UAV  $k$ 
10:  for każde zadanie  $j$  przypisane do UAV  $k$  do
11:    Pobierz slot realizacji  $[B_j, F_j]$ 
12:    Wyznacz punkt startowy i docelowy zadania:  $(v_{start}^j, v_{goal}^j)$ 
13:    Wyznacz ścieżkę:  $P_{k,j} = \text{Path}(v_{start}^j, v_{goal}^j)$ 
14:    Oblicz czas realizacji trajektorii  $t_{traj}(P_{k,j})$ 
15:    if  $t_{traj}(P_{k,j}) > F_j - B_j$  then
16:      Wyznacz alternatywną trajektorię lub zgłoś konflikt
17:    end if
18:    Zweryfikuj konflikty przestrzenno-czasowe z innymi trajektoriami
19:    if wykryto konflikt then
20:      Dokonaj lokalnej korekty trajektorii
21:    end if
22:    Dodaj trajektorię zadania do  $T_k$ 
23:  end for
24:  Dodaj  $T_k$  do zbioru  $\mathcal{T}$ 
25: end for
26: return  $\mathcal{T}$ 

```

Przedstawiony algorytm stanowi końcowy etap konstrukcji operacyjnego planu misji UAV w wariantcie deterministycznym. Wygenerowane trajektorie lotu stanowią przestrzenną konkretyzację harmonogramu slotowego i są następnie przekazywane do warstwy integracyjnej systemu, która odpowiada za końcową walidację ograniczeń operacyjnych oraz przygotowanie planu wykonawczego misji UAV.

5.6 Architektura zintegrowanego systemu harmonogramowania zadań floty UAV

Rysunek 5.2 przedstawia architekturę zintegrowanego systemu harmonogramowania zadań UAV implementującego zaproponowaną metodykę rozwiązywania problemu harmonogramowania w oparciu o modele algebraiczno-logiczne ALMM. Architektura integruje wszystkie etapy procesu decyzyjnego opisane w poprzednich podrozdziałach, tworząc spójny mechanizm konstrukcji kompletnego planu operacyjnego misji UAV.



Rysunek 5.2: Zintegrowana struktura działania algorytmów harmonogramowania zadań UAV w systemie ALMM.

Dane wejściowe systemu obejmują zbiór zadań J , zbiór UAV K , przedziały dostępności UAV, zbiór korytarzy powietrznych C , funkcję przypisania korytarzy $\gamma : J \rightarrow C$, parametry czasowe realizacji zadań oraz model przestrzeni operacyjnej. Dane te stanowią pełną specyfikację problemu harmonogramowania i inicjalizują proces planowania.

Centralnym elementem architektury jest moduł zarządzania iteracyjnym planowaniem, odpowiedzialny za koordynację procesu konstrukcji harmonogramu, wybór decyzji harmonogramowych oraz sterowanie przepływem danych pomiędzy kolejnymi etapami procesu planowania. Moduł ten operuje na wspólnej reprezentacji stanu procesu s_i , decyzji sterujących u_i oraz zbiorów ograniczeń dopuszczalności wynikających z modeli ALMM. Moduł zarządzania iteracyjnym planowaniem nie jest traktowany jako moduł wykonawczy, lecz jako nadrzędny komponent sterujący pracą pozostałych modułów.

W ramach architektury wyróżnia się następujące moduły wykonawcze:

- Moduł redukcji przestrzeni decyzji – wyznacza heurystycznie zawężony zbiór kandydackich decyzji $\hat{U}_d^{CS}(s_i)$, ograniczając przestrzeń przeszukiwania dla kolejnych etapów planowania;
- Moduł przydziału zadań do slotów czasowych – dokonuje osadzenia zaakceptowanych decyzji harmonogramowych w konkretnych przedziałach czasowych UAV, generując harmonogram slotowy $\mathcal{H}$;
- Moduł generowania trajektorii lotu – przekształca harmonogram slotowy w przestrzenno-czasowy plan trajektorii lotu UAV $\mathcal{T}$.

Po wykonaniu kolejnych etapów planowania oraz wygenerowaniu trajektorii lotu uzyskany plan operacyjny przekazywany jest do modułu walidacji ograniczeń, którego zadaniem jest weryfikacja spójności wygenerowanego harmonogramu z ograniczeniami formalnymi modeli ALMM. W szczególności sprawdzane są:

- zgodność harmonogramu z dostępnością UAV,
- zgodność z dostępnością wymaganych korytarzy powietrznych,

- spełnienie ograniczeń okien czasowych zadań,
- brak konfliktów przestrzenno-czasowych pomiędzy trajektoriami UAV.

Jeżeli walidacja zakończy się pozytywnie, wygenerowany harmonogram i trajektorie są przekazywane do modułu eksportu planu operacyjnego, odpowiedzialnego za przygotowanie końcowej reprezentacji planu misji dla warstwy wykonawczej systemu UAV.

W przypadku wykrycia naruszenia ograniczeń następuje aktywacja mechanizmu sprzężenia zwrotnego, prowadzącego do aktualizacji parametrów heurystyki, modyfikacji przestrzeni decyzji kandydackich lub ponownego uruchomienia wybranych etapów procesu planowania. Architektura realizuje tym samym iteracyjny mechanizm konstrukcji i poprawy harmonogramu aż do uzyskania rozwiązania dopuszczalnego.

Przedstawiona architektura ma charakter modułarny i hierarchiczny. Oznacza to, że poszczególne komponenty mogą być rozwijane niezależnie przy zachowaniu wspólnej reprezentacji stanu procesu oraz jednolitego mechanizmu walidacji ograniczeń. Takie podejście umożliwia bezpośrednie rozszerzenie architektury o mechanizmy dynamicznego harmonogramowania i rekonfiguracji planu operacyjnego, przedstawione w kolejnym podrozdziale dla modelu ALMM-D.

5.7 Algorytmy dynamicznego harmonogramowania z predykcją zakłóceń i realokacją

W niniejszym podrozdziale przedstawiono rozszerzenie deterministycznego mechanizmu harmonogramowania zadań UAV o obsługę zakłóceń dynamicznych. Proponowane algorytmy są zgodne z modelem ALMM-D opisanym w podrozdziale 4.5 i stanowią rozwinięcie procedur planowania, przydziału zadań do slotów oraz generowania trajektorii przedstawionych we wcześniejszych częściach rozdziału.

W modelu dynamicznym zakłada się, że w kroku decyzyjnym i może wystąpić zakłócenie. Niech $\mathcal{D}$ oznacza zbiór wszystkich możliwych zakłóceń wpływających na proces harmonogramowania. Wówczas zakłócenie występujące w kroku i spełnia zależność:

$$\delta_i \in \mathcal{D}. \quad (5.7)$$

Zakłócenie może zostać wykryte bezpośrednio w trakcie realizacji procesu lub przewidziane przez komponent predykcyjny:

$$\Phi_{ML}(s_i, t_i) \rightarrow \hat{\delta}_i, \quad (5.8)$$

gdzie $\hat{\delta}_i$ oznacza prognozowane zakłócenie mogące wpływać na dostępność UAV, dostępność korytarzy powietrznych, czas realizacji zadań albo aktualny zbiór zadań. W przypadku materializacji prognozowanego zakłócenia zachodzi przejście z predykcji $\hat{\delta}_i$ do zakłócenia potwierdzonego δ_i , które następnie uwzględniane jest w funkcji przejścia modelu dynamicznego oraz w procesie aktualizacji zbioru decyzji dopuszczalnych.

W konsekwencji zbiór decyzji dopuszczalnych w modelu dynamicznym zależy nie tylko od bieżącego stanu procesu, ale również od zakłócenia:

$$U_d^D(s_i, \delta_i). \quad (5.9)$$


W modelu dynamicznym funkcja przejścia stanu przyjmuje postać:

$$s_{i+1} = f^D(u_i, s_i, \delta_i), \quad (5.10)$$

gdzie decyzja u_i może być decyzją standardową u_i^{std} albo decyzją realokacyjną u_i^{ra} . W przypadku wystąpienia zakłócenia aktualizowane są odpowiednie składowe modelu:

$$K_{av}(s_i, \delta_i), \quad E_c^D(i), \quad J_i, \quad U_d^D(s_i, \delta_i). \quad (5.11)$$

Schemat architektury systemu dynamicznego przedstawiono na Rysunku 5.3.



Rysunek 5.3: Schemat architektury systemu decyzyjnego ALMM-D dla harmonogramowania zadań UAV z predykcją zakłóceń i realokacją dynamiczną.

Na Rysunku 5.3 wyróżniono moduł decyzyjny ALMM-D jako element centralny, który integruje informacje o zadaniach, UAV oraz slotach i korytarzach powietrznych z predykcją zakłóceń Φ_{ML} , modułem aktualizacji przydziału czasowo-zadaniowego oraz modułem realokacji dynamicznej. Architektura systemu obejmuje cztery współdziałające moduły:

- Moduł decyzyjny ALMM-D – odpowiada za wyznaczanie decyzji $u_i \in U_d^D(s_i, \delta_i)$, aktualizację trajektorii stanów procesu oraz weryfikację osiągalności zbioru stanów docelowych S_G^D .
- Moduł predykcyjny – generuje prognozę zakłócenia $\hat{\delta}_i = \Phi_{ML}(s_i, t_i)$, która może ograniczać dostępność zasobów UAV, korytarzy powietrznych, czasów realizacji zadań lub zbioru zadań.
- Moduł aktualizacji przydziału czasowo-zadaniowego – aktualizuje przypisania zadań do UAV oraz slotów czasowych po uwzględnieniu dynamicznej dostępności zasobów $K_{av}(s_i, \delta_i)$, zmodyfikowanej dostępności korytarzy $E_c^D(i)$ oraz aktualnego zbioru zadań J_i .
- Moduł dynamicznej realokacji – uruchamia decyzje realokacyjne $u_i^{ra} \in U^{ra}(s_i, \delta_i)$, gdy kontynuacja procesu za pomocą decyzji standardowych prowadziłaby do stanu niedopuszczalnego.

Moduł predykcji zakłóceń pracuje w pętli sprzężenia zwrotnego z modułem decyzyjnym ALMM-D, wykorzystując bieżący stan procesu oraz historię realizacji harmonogramu do generowania prognoz zakłóceń

wpływających na kolejne decyzje harmonogramowe. Takie sprzężenie umożliwia adaptacyjne korygowanie planu operacyjnego jeszcze przed materializacją przewidywanego zakłócenia.

W projektowanym systemie wyróżnia się trzy podstawowe klasy zakłóceń:

- zakłócenia przestrzenne, wpływające na dostępność korytarzy powietrznych, np. tymczasowa strefa zabroniona, przelot LPR, ćwiczenia wojskowe lub przelot statku załogowego;
- zakłócenia zasobowe, wpływające na dostępność UAV, np. awaria UAV, konieczność serwisowania lub wycofanie UAV z operacji;
- zakłócenia zadaniowe, wpływające na zbiór zadań J_i , np. anulowanie zadania, zmiana parametrów zadania lub pojawienie się nowego zadania o wyższym priorytecie.

Celem algorytmów dynamicznych jest utrzymanie trajektorii procesu w przestrzeni stanów dopuszczalnych poprzez bieżącą aktualizację zbioru decyzji dopuszczalnych oraz, w razie potrzeby, uruchomienie procedury realokacji. W przypadku braku możliwości kontynuacji dotychczasowego planu system poszukuje decyzji alternatywnej, która ogranicza opóźnienia, minimalizuje liczbę zmian w harmonogramie oraz maksymalizuje liczbę ukończonych zadań.

Obsługa zakłóceń przestrzennych

Zakłócenia przestrzenne wpływają bezpośrednio na dostępność korytarzy powietrznych. W modelu ALMM-D ich wystąpienie prowadzi do modyfikacji efektywnej dostępności korytarza:

$$E_c^D(i) = E_c \setminus Z_c(\delta_i), \quad (5.12)$$

gdzie $Z_c(\delta_i)$ oznacza część dostępności korytarza c , która została wyłączona w wyniku zakłócenia.


Jeżeli UAV realizuje zadanie wymagające korytarza $\gamma(j)$, to dalsza realizacja zadania jest dopuszczalna tylko wtedy, gdy:

$$[t_i, t_i + \tau_i^k] \subseteq E_{\gamma(j)}^D(i). \quad (5.13)$$

Jeżeli warunek ten nie jest spełniony, system może zastosować jedną z procedur reaktywnych:

- odroczenie realizacji zadania do kolejnego dopuszczalnego przedziału dostępności korytarza $\gamma(j)$;
- przejście UAV w tryb oczekiwania do czasu ponownej dostępności korytarza;
- uruchomienie decyzji realokacyjnej u_i^{ra} , jeżeli zadanie może zostać przejęte przez inny dostępny UAV;
- zakończenie realizacji zadania w trybie awaryjnym, jeżeli dalsze wykonywanie misji prowadziłoby do stanu niedopuszczalnego.


Poniższy przykład ma charakter ilustracyjny i przedstawia jedną z możliwych operacyjnych interpretacji zakłócenia przestrzennego δ_i . Formalnie w modelu ALMM-D zakłócenie to odpowiada zmianie efektywnej dostępności korytarza $E_c^D(i)$. Na Rysunku 5.4 przedstawiono przykładowy graf destynacji lotniczej,



Rysunek 5.4: Graf destynacji lotniczej jako przykład struktury przestrzennej misji UAV.

w którym węzły reprezentują punkty przestrzeni operacyjnej, natomiast krawędzie odpowiadają możliwym połączeniom lub fragmentom trajektorii lotu.

W rozważanym przykładzie UAV realizuje przelot z punktu startowego oznaczonego na Rysunku 5.5 symbolem H do punktu docelowego oznaczonego symbolem B . W trakcie realizacji misji pojawia się dynamiczna strefa ograniczonej dostępności przestrzeni powietrznej. W ujęciu modelowym oznacza to, że fragment dotychczas dostępnej przestrzeni zostaje wyłączony ze zbioru $E_c^D(i)$, a system musi zweryfikować, czy dalsza trajektoria pozostaje dopuszczalna. Przykładową reakcję UAV na tego typu zakłócenie pokazano na Rysunku 5.5.



Rysunek 5.5: Przykładowa strategia reakcji UAV na dynamicznie pojawiające się zakłócenie przestrzenne podczas realizacji przelotu między punktem startowym H a punktem docelowym B .

Strategia reakcji może obejmować obniżenie wysokości lotu, przejście w tryb oczekiwania, odroczenie zadania albo uruchomienie realokacji. Wybór konkretnej reakcji zależy od charakteru zakłócenia oraz od możliwości utrzymania procesu w przestrzeni stanów dopuszczalnych.

Obsługa zakłóceń zasobowych i zadaniowych

Zakłócenia zasobowe i zadaniowe wpływają odpowiednio na zbiór dostępnych UAV oraz aktualny zbiór zadań realizowanych w procesie harmonogramowania. W modelu ALMM-D dostępność UAV po uwzględ-

nieniu zakłócenia opisana jest przez zależność:

$$K_{av}(s_i, \delta_i) \subseteq K. \quad (5.14)$$

Zbiór UAV, którym można przydzielać nowe zadania, przyjmuje postać:

$$K_{dec}^D(s_i, \delta_i) = K_{dec}(s_i) \cap K_{av}(s_i, \delta_i). \quad (5.15)$$


Zakłócenia zadaniowe prowadzą do aktualizacji zbioru zadań:

$$J_i = J_{i-1} \cup J_i^{new} \setminus J_i^{rem}, \quad (5.16)$$

natomiast zbiór zadań niezakończonych aktualizowany jest zgodnie z zależnością:

$$J_i^{unf}(s_i) = J_i \setminus x_i^0. \quad (5.17)$$

Po wykryciu zakłócenia zasobowego lub zadaniowego następuje aktualizacja odpowiednich składowych modelu ALMM-D oraz ponowne wyznaczenie zbioru decyzji dopuszczalnych $U_d^D(s_i, \delta_i)$. Jeżeli po tej aktualizacji nie istnieje decyzja standardowa umożliwiająca kontynuację procesu w przestrzeni stanów dopuszczalnych, uruchamiany jest moduł dynamicznej realokacji. Schemat jego działania zaprezentowano na Rysunku 5.6.



Rysunek 5.6: Etapy modułu realokacji zadań UAV w modelu ALMM-D realizującego aktualizację trajektorii stanów i decyzji po wystąpieniu zakłócenia.

Rysunek 5.6 przedstawia główną ścieżkę działania procedury realokacyjnej w modelu ALMM-D. W pierwszym etapie identyfikowany jest wpływ zakłócenia δ_i na stan procesu poprzez wyznaczenie jego oddziaływania na efektywną dostępność korytarzy $E_c^D(i)$, zbiór dostępnych zasobów $K_{av}(s_i, \delta_i)$ oraz aktualny zbiór zadań J_i . Następnie weryfikowana jest możliwość kontynuacji procesu z wykorzystaniem decyzji standardowych należących do zbioru $U^{std}(s_i) \cap U_d^D(s_i, \delta_i)$. Dopiero w przypadku braku takich decyzji wykonywana jest ocena dopuszczalnych alternatyw realokacji.

Jeżeli procedura realokacyjna wygeneruje decyzję u_i^{ra} , która spełnia warunki dopuszczalności modelu, następuje przejście stanu zgodnie z funkcją:

$$s_{i+1} = f^D(u_i^{ra}, s_i, \delta_i). \quad (5.18)$$

W kolejnym kroku aktualizowana jest trajektoria stanów i decyzji procesu, tj. $\tilde{s}$ oraz $\tilde{u}$, przy zachowaniu spójności z historią wykonania harmonogramu. Kończącym etapem procedury jest weryfikacja osiągalności stanu docelowego S_G^D . W przypadku braku dopuszczalnej decyzji realokacyjnej system może przejść do trybu oczekiwania, odroczyć realizację zadania do kolejnej iteracji harmonogramowania albo oznaczyć zadanie jako niespełnione.

System uwzględnia różne strategie reagowania na zakłócenia:

- tryb priorytetowy – zadania o wyższym priorytecie otrzymują pierwszeństwo w procesie realokacji;
- tryb kompensacyjny – zadania mogą zostać przesunięte do późniejszych dopuszczalnych przedziałów realizacji;
- tryb oczekiwania – UAV pozostaje w stanie oczekiwania do czasu ponownej dostępności zasobu lub korytarza;
- tryb awaryjny – UAV kończy bieżącą operację lub przechodzi do bezpiecznego stanu operacyjnego;
- rollback – system powraca do ostatniego zapamiętanego stanu dopuszczalnego.

Algorytm 5 przedstawia nadrzędną procedurę obsługi zakłóceń w modelu ALMM-D.

Algorytm 5 Zintegrowany algorytm obsługi zakłóceń w modelu ALMM-D

```

1: Wejście: stan bieżący  $s_i$ , trajektoria decyzji  $\tilde{u}$ , prognoza  $\Phi_{ML}(s_i, t_i)$ 
2: Wyjście: zaktualizowana trajektoria procesu  $(\tilde{s}, \tilde{u})$  lub informacja o braku kontynuacji dopuszczalnej
3: while proces nie osiągnął stanu docelowego  $S_G^D$  do
4:   Wyznacz prognozowane zakłócenie:  $\hat{\delta}_i = \Phi_{ML}(s_i, t_i)$ 
5:   Wykryj lub potwierdź zakłócenie:  $\delta_i \in \mathcal{D}$ 
6:   if wystąpiło zakłócenie przestrzenne then
7:     Zaktualizuj efektywną dostępność korytarzy  $E_c^D(i)$ 
8:   end if
9:   if wystąpiło zakłócenie zasobowe then
10:    Zaktualizuj zbiór dostępnych UAV  $K_{av}(s_i, \delta_i)$ 
11:    Wyznacz  $K_{dec}^D(s_i, \delta_i)$ 
12:   end if
13:   if wystąpiło zakłócenie zadaniowe then
14:     Zaktualizuj zbiór zadań  $J_i$ 
15:     Wyznacz zbiór zadań niezakończonych  $J_i^{unf}(s_i)$ 
16:   end if
17:   Wyznacz zaktualizowany zbiór decyzji dopuszczalnych:  $U_d^D(s_i, \delta_i)$ 
18:   if istnieje decyzja standardowa  $u_i^{std} \in U^{std}(s_i) \cap U_d^D(s_i, \delta_i)$  then
19:     Wykonaj przejście:  $s_{i+1} = f^D(u_i^{std}, s_i, \delta_i)$ 
20:   else
21:     Uruchom procedurę realokacji dynamicznej
22:     Wyznacz decyzję realokacyjną:  $u_i^{ra} \in U^{ra}(s_i, \delta_i)$ 
23:     if  $u_i^{ra} \in U_d^D(s_i, \delta_i)$  then
24:       Wykonaj przejście:  $s_{i+1} = f^D(u_i^{ra}, s_i, \delta_i)$ 
25:     else
26:       Oznacz zadania jako odroczone lub niespełnione
27:       Zakończ procedurę dla bieżącej trajektorii
28:     end if
29:   end if
30:   Zaktualizuj trajektorię stanów i decyzji
31:    $i \leftarrow i + 1$ 
32: end while
33: return zaktualizowana trajektoria procesu

```

Moduł dynamicznej realokacji stanowi wyspecjalizowaną procedurę rekonfiguracji planu operacyjnego uruchamianą w sytuacji, gdy standardowe decyzje sterujące nie pozwalają na dalszą kontynuację procesu. Jego strukturę formalną przedstawiono w Algorytmie 6. Przez J_z oznacza się zbiór zadań, których realizacja została bezpośrednio naruszona przez zakłócenie δ_i , np. przez utratę dostępności UAV, zamknięcie wymaganego korytarza albo zmianę parametrów zadania.

Algorytm 6 Algorytm dynamicznej realokacji zadań UAV

```

1: Wejście: stan bieżący  $s_i$ , zakłócenie  $\delta_i$ , zbiór zadań dotkniętych zakłóceniem  $J_z$ 
2: Wyjście: decyzja realokacyjna  $u_i^{ra}$  albo informacja o braku realokacji dopuszczalnej
3:  $u_i^{ra} \leftarrow \emptyset$ 
4: for all  $j \in J_z$  do
5:   Wyznacz  $k_{old}$ , czyli UAV dotychczas realizujący lub mający realizować zadanie  $j$ 
6:   Wyznacz zbiór dostępnych UAV mogących przejąć zadanie:
      
$$K_j^D = \left\{ k \in K_{dec}^D(s_i, \delta_i) : [t_i, t_i + p_\delta(j, k, i)] \subseteq E_{\gamma(j)}^D(i) \right\}$$

7:   if  $K_j^D \neq \emptyset$  then
8:     Wybierz UAV minimalizujący koszt realokacji:  $k^* = \arg \min_{k \in K_j^D} (w_j \Delta t_j + \alpha c_{reloc}(j, k))$ 
9:     Dodaj element  $(k_{old}, j, k^*)$  do decyzji realokacyjnej  $u_i^{ra}$ 
10:  else
11:    Oznacz zadanie  $j$  jako odroczone do kolejnej iteracji
12:  end if
13: end for
14: if  $u_i^{ra} \neq \emptyset$  oraz  $u_i^{ra} \in U_d^D(s_i, \delta_i)$  then
15:   return  $u_i^{ra}$ 
16: else
17:   return brak realokacji dopuszczalnej
18: end if

```

Przez $p_\delta(j, k, i)$ oznacza się czas realizacji zadania j przez UAV k w kroku i , skorygowany o wpływ zakłócenia δ_i . W procesie wyboru decyzji realokacyjnej wykorzystywana jest lokalna funkcja kosztu:

$$\min_{k \in K_j^D} (w_j \Delta t_j + \alpha c_{reloc}(j, k)), \quad (5.19)$$

gdzie w_j oznacza wagę priorytetu zadania, Δt_j przewidywane opóźnienie zadania, $c_{reloc}(j, k)$ koszt realokacji zadania j do UAV k , natomiast α reguluje kompromis pomiędzy stabilnością harmonogramu a minimalizacją opóźnień.

W przypadku braku dostępnych zasobów umożliwiających kontynuację zadania system może zastosować tryb oczekiwania, odroczyć zadanie do kolejnej iteracji albo oznaczyć zadanie jako niespełnione. Mechanizm ten zapewnia zachowanie spójności procesu decyzyjnego oraz zapobiega przejściu trajektorii do zbioru stanów niedopuszczalnych.

Przykładowe przypadki testowe

W celu zilustrowania działania algorytmów dynamicznych rozważono trzy przykładowe scenariusze:

- **Scenariusz A – awaria UAV:** UAV₃ ulega awarii podczas realizacji zadania j_5 . System aktualizuje zbiór $K_{av}(s_i, \delta_i)$, identyfikuje zadania dotknięte zakłóceniem i uruchamia procedurę realokacji do innego dostępnego UAV.

- **Scenariusz B – nagłe ograniczenie dostępności korytarza:** w chwili t_i część dostępności korytarza $\gamma(j)$ zostaje wyłączona, co prowadzi do aktualizacji $E_{\gamma(j)}^D(i)$. Zadania zaplanowane w tym przedziale są odraczane albo realokowane, jeżeli istnieje decyzja dopuszczalna.
- **Scenariusz C – dynamiczny dopływ zadania o wysokim prioryecie:** w kroku i pojawia się nowe zadanie $j_{new} \in J_i^{new}$. System aktualizuje zbiór J_i , nadaje zadaniu odpowiedni priorytet w_j , a następnie ponownie wyznacza zbiór decyzji dopuszczalnych $U_d^D(s_i, \delta_i)$.

Realokacja oparta jest na lokalnym przeszukiwaniu przestrzeni stanów ograniczonym aktualnym zakłóceniem oraz predykcją Φ_{ML} . Każda rekonfiguracja harmonogramu wymaga ponownej oceny osiągalności zbioru stanów docelowych S_G^D , co zapewnia zachowanie formalnej zgodności procesu z ograniczeniami modelu ALMM-D. Rejestrowanie historii stanów, decyzji oraz zdarzeń zakłócających umożliwia dodatkowo analizę jakości działania algorytmu oraz adaptacyjne doskonalenie stosowanych heurystyk decyzyjnych.

Rozdział 6

Wyniki badań eksperymentalnych

Celem niniejszego rozdziału jest przeprowadzenie wieloetapowej walidacji eksperymentalnej opracowanej technologii inteligentnego harmonogramowania zadań operacyjnych dla floty UAV, bazującej na formalizmie algebraiczno-logicznego meta-modelowania oraz zaproponowanych algorytmach konstrukcji i adaptacji harmonogramu. Walidacja ma na celu ocenę poprawności formalnej modeli, skuteczności algorytmicznej opracowanych metod oraz odporności systemu na zmienność warunków operacyjnych i występowanie zakłóceń dynamicznych. Etap eksperymentalny pracy został zaprojektowany w sposób hierarchiczny i odpowiada strukturze rozwijanych modeli ALMM przedstawionych w Rozdziale 4. Przyjęte scenariusze badawcze umożliwiają stopniową ocenę wpływu kolejnych ograniczeń operacyjnych na jakość generowanych harmonogramów oraz analizę zdolności adaptacyjnych opracowanego systemu w środowisku dynamicznym. Walidacja obejmuje zarówno eksperymenty symulacyjne realizowane dla modeli statycznych i dynamicznych, jak również badania przeprowadzone w warunkach zbliżonych do rzeczywistych z wykorzystaniem fizycznej infrastruktury testowej.

W pierwszej części rozdziału przedstawiono środowisko badawcze oraz zakres walidacji eksperymentalnej, obejmujące konfigurację scenariuszy testowych, parametry środowiska symulacyjnego oraz przyjęte miary oceny jakości harmonogramów. Następnie zaprezentowano wyniki eksperymentów dla bazowych scenariuszy harmonogramowania, eksperymentów uwzględniających ograniczenia czasowo-przestrzenne wynikające z dostępności korytarzy powietrznych i slotów czasowych, a także walidację modelu dynamicznego ALMM-D w warunkach zakłóceń zasobowych i zadaniowych. Końcowa część rozdziału poświęcona została walidacji systemu w środowisku quasi-rzeczywistym oraz analizie porównawczej uzyskanych rezultatów względem wybranych metod raportowanych w literaturze. Przedstawione w niniejszym rozdziale wyniki stanowią empiryczne potwierdzenie skuteczności, skalowalności oraz adaptacyjności opracowanej technologii, a także podstawę do końcowej weryfikacji tezy badawczej sformułowanej w rozprawie.

6.1 Środowisko i zakres walidacji eksperymentalnej

W celu weryfikacji zaproponowanego modelu decyzyjnego ALMM oraz odpowiadających mu algorytmów harmonogramowania przedstawionych w Rozdziałach 4 i 5 opracowano środowisko badawcze umożliwiające prowadzenie eksperymentów w trybach Software-in-the-loop (SIL) oraz Hardware-in-the-loop (HIL).


Przygotowane stanowisko pozwalało na symulację pracy floty UAV, centralne monitorowanie przebiegu misji oraz rejestrację danych telemetrycznych w czasie rzeczywistym. Środowisko to stanowiło podstawę walidacji algorytmów planowania zadań, przydziału zadań do slotów czasowych, generowania trajektorii lotu oraz procedur dynamicznej realokacji.

W ramach badań eksperymentalnych analizowano zdolność zaproponowanego podejścia do:

- generowania dopuszczalnych trajektorii procesu decyzyjnego prowadzących do stanów docelowych S_G ,
- efektywnego przydziału zadań do UAV przy ograniczeniach czasowo-przestrzennych,
- obsługi ograniczeń wynikających z dostępności slotów czasowych i przepustowości korytarzy,
- rekonfiguracji harmonogramu w warunkach zakłóceń dynamicznych.

Przyjęta procedura walidacyjna została zorganizowana zgodnie z hierarchiczną strukturą modeli ALMM przedstawioną w Rozdziale 4. W kolejnych etapach badań analizowano odpowiednio właściwości modelu bazowego ALMM-TS, następnie wpływ ograniczeń czasowo-przestrzennych reprezentowanych przez modele ALMM-CS i ALMM-TW, a w dalszej kolejności zachowanie modelu dynamicznego ALMM-D uwzględniającego zakłócenia operacyjne oraz rekonfigurację harmonogramu. Takie podejście umożliwiło stopniową ocenę wpływu kolejnych klas ograniczeń na jakość generowanych harmonogramów oraz zdolność systemu do adaptacji w zmiennych warunkach operacyjnych.

Schemat zaprojektowanego stanowiska badawczego przedstawiono na Rysunku 6.1, natomiast przykładowe stanowiska wykorzystywane w badaniach SIL i HIL pokazano na Rysunku 6.2. Jednostki oznaczone jako UAV1–UAV6 reprezentują poszczególne statki floty UAV nadzorowane przez jednostkę centralną CC (ang. Central Control), odpowiedzialną za koordynację procesu sterowania, wymianę danych oraz monitorowanie przebiegu misji.




Rysunek 6.1: Schemat zaprojektowanego stanowiska badawczego



(a)



(b)



(c)

Rysunek 6.2: Dedykowane stanowiska badawcze do symulacji lotu UAV w trybach SIL oraz HIL

Zakres walidacji eksperymentalnej obejmował trzy komplementarne poziomy testów: walidację symulacyjną algorytmów harmonogramowania w środowisku Matlab/Simulink, walidację Software-in-the-loop z wykorzystaniem symulowanych modeli dynamiki UAV oraz walidację Hardware-in-the-loop z uwzględnieniem rzeczywistych komponentów komunikacyjnych i sterujących.

Badania symulacyjne przeprowadzono z wykorzystaniem środowisk X-Plane, Mission Planner oraz Matlab/Simulink. Środowisko X-Plane umożliwiało odwzorowanie dynamiki lotu oraz wpływu wybranych czynników środowiskowych, takich jak wiatr, natomiast Mission Planner pełnił funkcję stacji naziemnej umożliwiającej konfigurację oraz monitorowanie misji. W środowisku Matlab/Simulink zaimplementowano moduły sterowania, komunikacji oraz algorytmy harmonogramowania i przydziału zadań.

Na potrzeby eksperymentów zamodelowano dwa typy platform UAV: wielowirnikowiec oraz samolot (Rysunek 6.3). Uwzględnienie dwóch klas platform lotniczych pozwoliło ocenić niezależność opracowanej metodyki harmonogramowania od charakterystyki dynamicznej nośnika oraz potwierdzić możliwość jej zastosowania zarówno dla platform VTOL (Vertical Take-Off and Landing), jak i dla statków o stałopłatowej charakterystyce lotu.




(a) wielowirnikowiec



(b) samolot

Rysunek 6.3: Zamodelowane bezzałogowe statki powietrzne: (a) wielowirnikowiec, (b) samolot

Stanowisko badawcze obejmowało jednostkę centralną z zainstalowanym środowiskiem Matlab/ Simulink, zestaw komputerów pracujących w sieci LAN, dedykowany switch komunikacyjny oraz moduły komunikacyjne umożliwiające wymianę danych z UAV. Komunikacja pomiędzy jednostkami UAV a systemem sterowania realizowana była z wykorzystaniem protokołu MAVLink oraz transmisji UDP (patrz Rysunek 6.4). Rozwiązanie to umożliwiało rejestrację parametrów lotu, przesyłanie komend sterujących oraz monitorowanie stanu poszczególnych jednostek floty.



Rysunek 6.4: Schemat wymiany danych pomiędzy UAV a zaimplementowanym algorytmem w środowisku Matlab

W przyjętej architekturze UAV komunikowały się z komputerem PC za pośrednictwem mikrokomputera RPI 3B, który umożliwiał konwersję komunikatów MAVLink do uproszczonego protokołu wykorzystywanego przez opracowane algorytmy. Struktura ta pozwalała również na dołączenie nadrzędnej stacji kontroli lotów pełniącej funkcję modułu bezpieczeństwa. W przypadku wystąpienia sytuacji niebezpiecznej stacja nadzorująca mogła zatrzymać pojedynczy statek UAV, wycofać go do bazy lub przerwać działanie całej floty. W trakcie eksperymentów rejestrowano dane telemetryczne obejmujące m.in. identyfikator systemu, znacznik czasu, położenie geograficzne, wysokość bezwzględną i względną, składowe prędkości oraz kurs. Dane te wykorzystywano do oceny poprawności działania procedur sterowania i zgodności realizowanych trajektorii z harmonogramem. Rejestrowane dane telemetryczne oraz stany operacyjne UAV odwzorowywano następnie w przestrzeni stanów modelu ALMM, co umożliwiało mapowanie rzeczywistego przebiegu eksperymentu na formalny model procesu decyzyjnego oraz weryfikację zgodności trajektorii realizowanych z trajektoriami planowanymi przez algorytm harmonogramowania.

Przygotowane środowisko pozwoliło na przeprowadzenie eksperymentów obejmujących walidację bazowego harmonogramowania zadań, ocenę działania algorytmów przy ograniczonej dostępności korytarzy powietrznych, analizę trajektorii dopuszczalnych i niedopuszczalnych oraz testowanie reakcji systemu na zakłócenia zasobowe i zadaniowe. Wyniki tych badań przedstawiono w kolejnych podrozdziałach.

6.2 Wyniki bazowych eksperymentów symulacyjnych harmonogramowania zadań UAV

W celu walidacji opracowanego bazowego modelu algebraiczno-logicznego harmonogramowania zadań logistycznych UAV przeprowadzono serię eksperymentów symulacyjnych dla scenariuszy obejmujących dynamiczny napływ zadań lotniczych realizowanych przez flotę UAV. Celem eksperymentów była weryfikacja poprawności działania zaproponowanego modelu decyzyjnego w zakresie generowania trajektorii decyzyjnych, przydziału zadań do jednostek UAV oraz osiągania stanów docelowych procesu S_G . Na tym etapie nie uwzględniano jeszcze ograniczeń związanych z czasową dostępnością korytarzy powietrznych


ani zakłóceń zasobowych i zadaniowych. W ujęciu formalnym celem eksperymentów była walidacja procesu generowania trajektorii dopuszczalnych $\tilde{s} \in \mathcal{T}_{ad}$, prowadzących od stanu początkowego procesu s_0 do stanu docelowego należącego do zbioru S_G . Dla każdej analizowanej instancji problemu wyznaczano zbiór trajektorii dopuszczalnych procesu oraz odpowiadające im wartości funkcji celu związanej z całkowitym czasem realizacji zadań. Uzyskane wyniki pozwoliły na ocenę poprawności działania funkcji przejścia f , mechanizmu generowania decyzji dopuszczalnych oraz zdolności modelu do osiągania stanów docelowych przy zachowaniu przyjętych ograniczeń operacyjnych.

W analizowanym scenariuszu przyjęto flotę sześciu UAV oznaczonych jako UAV1–UAV6. Wszystkie jednostki rozpoczynały oraz kończyły realizację zadań w wydzielonej bazie operacyjnej UAV Base. Zadania logistyczne definiowane były jako sekwencje przelotów pomiędzy określonymi punktami węzłowymi rozmieszczonymi w analizowanym obszarze operacyjnym. Rozpatrywano zarówno zadania jednoetapowe, jak i wieloetapowe. Przykładowe klasy trajektorii zadań wykorzystanych w eksperymentach przedstawiono w Tabeli 6.1.

Tabela 6.1: Klasy trajektorii zadań


Typ misji	Klasa trajektorii lotów	Zadania do zrealizowania
J1	Wieloetapowa	UAV Base $\rightarrow$ D $\rightarrow$ F $\rightarrow$ UAV Base
J2	Wieloetapowa	UAV Base $\rightarrow$ C $\rightarrow$ A $\rightarrow$ E $\rightarrow$ F $\rightarrow$ UAV Base
J3	Wieloetapowa	UAV Base $\rightarrow$ F $\rightarrow$ A $\rightarrow$ B $\rightarrow$ UAV Base
J4	Wieloetapowa	UAV Base $\rightarrow$ E $\rightarrow$ A $\rightarrow$ UAV Base
J5	Jednoetapowa	UAV Base $\rightarrow$ D $\rightarrow$ UAV Base
J6	Wieloetapowa	UAV Base $\rightarrow$ E $\rightarrow$ C $\rightarrow$ B $\rightarrow$ F $\rightarrow$ UAV Base
J7	Wieloetapowa	UAV Base $\rightarrow$ B $\rightarrow$ F $\rightarrow$ UAV Base
J8	Jednoetapowa	UAV Base $\rightarrow$ C $\rightarrow$ UAV Base

Schemat rozmieszczenia punktów docelowych wykorzystanych w eksperymentach przedstawiono na Rysunku 6.5. Układ destynacji został opracowany dla analizowanego obszaru operacyjnego odpowiadającego przestrzeni lotniskowej Lotnisko Chopina w Warszawie (EPWA), przyjmowanej jako środowisko referencyjne dla realizowanych scenariuszy logistycznych UAV. W badaniach założono, że flota operacyjna składa się z sześciu bezzałogowych statków powietrznych, których start oraz lądowanie realizowane są z wydzielonej bazy operacyjnej UAV Base oznaczonej na rysunku symbolem L. Punkt ten stanowi centralny węzeł logistyczny systemu, z którego inicjowane są wszystkie misje transportowe oraz do którego UAV powracają po zakończeniu realizacji zadań. Pozostałe punkty oznaczone symbolami A-F reprezentują zdefiniowane w eksperymencie punkty węzłowe/destynacje operacyjne, odpowiadające lokalizacjom realizacji zadań transportowych i logistycznych. Punkty te modelują wirtualne miejsca dostaw, odbioru ładunków lub realizacji operacji specjalnych w przestrzeni lotniskowej i jej otoczeniu. Ich rozmieszczenie zostało dobrane w sposób umożliwiający analizę zachowania algorytmów harmonogramowania w warunkach zróżnicowanych odległości przelotowych oraz konkurencji o zasoby przestrzeni powietrznej.




Rysunek 6.5: Schemat rozmieszczenia destynacji lotniczych w analizowanym obszarze operacyjnym


Pierwszy etap walidacji obejmował ocenę poprawności generowania trajektorii realizacyjnych dla zadań przypisywanych poszczególnym jednostkom UAV. Analizie poddano zarówno przebieg realizacji kolejnych etapów zadania, jak i przestrzenny przebieg generowanych trajektorii lotu. Na Rysunku 6.6 przedstawiono przykładowe przebiegi realizacji zadań dla jednostek UAV1 oraz UAV2 wraz z odpowiadającymi im trajektoriami przestrzennymi.




(a) Etapy realizacji zadań przez UAV1



(b) Trajektoria przestrzenna UAV1




(c) Etapy realizacji zadań przez UAV2



(d) Trajektoria przestrzenna UAV2

Rysunek 6.6: Przykładowe przebiegi realizacji zadań i trajektorii lotu dla wybranych UAV

Dodatkowe przykłady wygenerowanych trajektorii 3D oraz ich rzutów pionowych przedstawiono na Rysunkach 6.7–6.8.



(a)



(b)

Rysunek 6.7: Przykładowa trajektoria 3D (a) oraz jej rzut pionowy (b) dla wybranego zadania



(a)



(b)

Rysunek 6.8: Przykład trajektorii przestrzennej (a) oraz rzut pionowy (b) dla zadania logistycznego


W kolejnym etapie przeprowadzono analizę jakości harmonogramowania dla różnych konfiguracji liczby zadań oraz liczebności floty UAV. Dla każdej instancji wyznaczano zbiory trajektorii dopuszczalnych prowadzących do osiągnięcia stanu docelowego procesu oraz identyfikowano harmonogram minimalizujący całkowity czas realizacji zadań.

Dla przypadku obejmującego flotę $|K| = 6$ UAV oraz zbiór $|J| = 20$ zadań logistycznych przeprowadzono analizę trajektorii dopuszczalnych procesu harmonogramowania należących do zbioru $\mathcal{T}_{ad}^D$. Trajektorie te uwzględniały stan początkowy oraz końcowy procesu, odpowiadające inicjalizacji i zakończeniu realizacji harmonogramu. W wyniku przeprowadzonych eksperymentów wyznaczono zbiór trajektorii dopuszczalnych $\tilde{s}^{(r)} \in \mathcal{T}_{ad}^D$, dla których czas realizacji procesu mieścił się w przedziale od 4057 [s] do 4571 [s]. Najkrótszy czas realizacji uzyskano dla trajektorii $\tilde{s}^{min}$, natomiast najdłuższy dla trajektorii $\tilde{s}^{max}$. Zestawienie czasów realizacji wygenerowanych trajektorii przedstawiono w Tabeli 6.2, natomiast odpowiadające im harmonogramy dla trajektorii $\tilde{s}^{min}$ oraz $\tilde{s}^{max}$ zaprezentowano na Rysunku 6.9. Każdy wiersz tabeli odpowiada jednej trajektorii dopuszczalnej $\tilde{s}^{(r)}$, należącej do zbioru trajektorii dopuszczalnych $\mathcal{T}_{ad}^D$.

Tabela 6.2: Czasy realizacji trajektorii dopuszczalnych $\tilde{s}^{(r)} \in \mathcal{T}_{ad}^D$ dla konfiguracji 20×6

Nr trajektorii r	Konfiguracja $ J \times K $	Czas realizacji $T(\tilde{s}^{(r)})$ [s]
1	20×6	4348
2	20×6	4218
3	20×6	4310
4	20×6	4409
5	20×6	4293
6	20×6	4130
7	20×6	4297
8	20×6	4421
9	20×6	4117
10	20×6	4451
11	20×6	4520
12	20×6	4378
13	20×6	4295
14	20×6	4057
15	20×6	4409
16	20×6	4355
17	20×6	4368
18	20×6	4571
19	20×6	4328
20	20×6	4280

Harmonogramy przedstawione na Rysunku 6.9 ilustrują przebieg realizacji trajektorii procesu $\tilde{s}^{min}$ oraz $\tilde{s}^{max}$, odpowiadających odpowiednio minimalnemu i maksymalnemu czasowi realizacji procesu harmonogramowania. Każda pozioma trajektoria odpowiada pojedynczemu UAV należącemu do zbioru $K = \{UAV_01, \dots, UAV_06\}$, natomiast kolejne punkty reprezentują stany procesu związane z realizacją zadań w kolejnych chwilach decyzyjnych. Oś pozioma odpowiada czasowi realizacji procesu, natomiast zmiany położenia punktów obrazują przejścia pomiędzy kolejnymi stanami procesu decyzyjnego. Występowanie odcinków poziomych oznacza ciągłą realizację operacji przez dany UAV, natomiast zmiany trajektorii wskazują momenty przejść pomiędzy kolejnymi etapami realizacji harmonogramu lub okresy oczekiwania wynikające z ograniczeń operacyjnych i synchronizacji procesu. Przedstawiona forma wizualizacji umożliwia analizę stopnia wykorzystania zasobów UAV, identyfikację okresów bezczynności oraz ocenę równoległości realizacji zadań w różnych trajektoriach harmonogramowania. Porównanie trajektorii $\tilde{s}^{min}$ i $\tilde{s}^{max}$ pozwala dodatkowo ocenić wpływ sekwencji decyzji na całkowity czas realizacji procesu oraz stopień obciążenia poszczególnych UAV.



Rysunek 6.9: Rozkład wykonania kolejnych lotów przez flotę 6 UAV (a) najkrótszy i (b) najdłuższy czas

W Tabeli 6.3 przedstawiono przebieg jednej trajektorii dopuszczalnej procesu harmonogramowania, tj. kolejne stany $\tilde{s} = (s_0, s_1, \dots, s_w)$, w których wskazano zadania przypisane do poszczególnych UAV. Wartość 0 oznacza brak aktywnego zadania przypisanego do danego UAV w danym stanie procesu, natomiast wartości od 1 do 20 odpowiadają identyfikatorom zadań ze zbioru J . Stan s_0 odpowiada stanowi początkowemu procesu, określanemu dalej jako stan *super-zero*.

Tabela 6.3: Przydział zadań do UAV w kolejnych stanach trajektorii procesu $\tilde{s}$

Stan s_i	UAV_01	UAV_02	UAV_03	UAV_04	UAV_05	UAV_06
s_0 (super-zero)	0	0	0	0	0	0
s_1	20	11	0	16	10	5
s_2	0	11	1	16	10	5

ciąg dalszy na następnej stronie

Tabela 6.3 (cd.)

Stan s_i	UAV_01	UAV_02	UAV_03	UAV_04	UAV_05	UAV_06
s_3	14	11	1	16	0	5
s_4	14	0	1	16	15	5
s_5	14	6	1	0	15	5
s_6	14	0	1	18	15	5
s_7	14	19	1	18	0	5
s_8	0	19	1	18	17	5
s_9	4	19	1	18	17	0
s_{10}	4	19	1	0	17	2
s_{11}	4	19	1	7	17	0
s_{12}	4	19	1	7	0	3
s_{13}	4	19	0	7	13	3
s_{14}	0	19	9	7	13	3
s_{15}	8	19	9	7	0	3
s_{16}	8	19	9	0	0	3
s_{17}	0	19	9	0	0	3
s_{18}	0	19	0	0	0	3
s_{19}	0	19	0	0	0	0
s_{20}	0	0	0	0	0	0

Dla bardziej złożonego scenariusza obejmującego 35 zadań właściwych oraz flotę 6 UAV wygenerowano dziewięć alternatywnych trajektorii dopuszczalnych procesu prowadzących do stanów docelowych. Dla tej konfiguracji otrzymano rozwiązanie o najkrótszym czasie 8727 [s] oraz odpowiednio najdłuższym 8965 [s] (patrz Tabela 6.4). W Tabeli 6.5 przedstawiono kolejno wykonywane zadania przez UAV dla uzyskanego najmniejszego czasu.

Tabela 6.4: Czasy realizacji harmonogramów dla konfiguracji 36×6

Nr trajektorii r	Konfiguracja $ J \times K $	Czas realizacji $T(\tilde{s}^{(r)})$ [s]
1	36x6	8778
2	36x6	8743
3	36x6	8765
4	36x6	8882
5	36x6	8750
6	36x6	8965
7	36x6	8727

ciąg dalszy na następnej stronie

Tabela 6.4 (cd.)

Nr trajektorii r	Konfiguracja $ J \times K $	Czas realizacji $T(\bar{s}^{(r)})$ [s]
8	36x6	8937
9	36x6	8750

Tabela 6.5: Przydzielone zadania dla floty UAV, decyzje $U_d(s_i)$


Stan s_i	UAV_01	UAV_02	UAV_03	UAV_04	UAV_05	UAV_06
s_0 (super zero)	0	0	0	0	0	0
s_1	6	10	33	0	25	16
s_2	6	10	0	34	25	16
s_3	6	0	17	34	25	16
s_4	6	3	17	34	25	0
s_5	0	3	17	34	25	30
s_6	28	3	17	34	0	30
s_7	28	3	17	0	18	30
s_8	28	0	17	21	18	30
s_9	28	2	0	21	18	30
s_{10}	28	2	7	21	18	0
s_{11}	0	2	7	21	18	32
s_{12}	15	2	7	0	18	32
s_{13}	15	2	7	29	0	32
s_{14}	0	2	7	29	14	32
s_{15}	5	2	7	29	14	0
s_{16}	0	2	7	29	14	13
s_{17}	35	2	7	29	0	13
s_{18}	35	2	0	29	4	13
s_{19}	35	0	23	29	4	13
s_{20}	35	22	23	0	4	13
s_{21}	0	22	23	8	4	13
s_{22}	9	22	23	8	0	13
s_{23}	9	22	0	8	24	13
s_{24}	0	22	1	8	24	13
s_{25}	26	22	1	0	24	13
s_{26}	26	22	1	20	24	0
s_{27}	26	22	1	20	0	31

ciąg dalszy na następnej stronie

Tabela 6.5 (cd.)


Stan s_i	UAV_01	UAV_02	UAV_03	UAV_04	UAV_05	UAV_06
s_{28}	26	22	1	0	19	31
s_{29}	26	0	1	12	19	31
s_{30}	26	11	1	12	0	31
s_{31}	26	11	0	12	0	31
s_{32}	26	0	0	12	0	31
s_{33}	26	0	0	12	0	0
s_{34}	0	0	0	12	0	0
s_{35}	0	0	0	0	0	0

Na Rysunku 6.10 przedstawiono harmonogram realizowanych zadań przez nadzorowaną flotę UAV dla uzyskanych stanów docelowych z powyższego przykładu.




Rysunek 6.10: Rozkład wykonania kolejnych lotów przez flotę 6 UAV (a) najkrótszy i (b) najdłuższy czas

Kolejne eksperymenty przeprowadzono dla większych flot oraz odmiennych liczebności zadań. Otrzymane harmonogramy dla konfiguracji 7 UAV / 23 zadania oraz 9 UAV / 29 zadań przedstawiono odpowiednio na Rysunkach 6.11 oraz 6.12.



Rysunek 6.11: Rozkład wykonania kolejnych lotów przez flotę 7 UAV (a) najkrótszy i (b) najdłuższy czas



Rysunek 6.12: Rozkład wykonania kolejnych lotów przez flotę 9 UAV (a) najkrótszy i (b) najdłuższy czas

W celu oceny zdolności modelu do eksploracji przestrzeni stanów przeprowadzono analizę liczby trajektorii dopuszczalnych oraz niedopuszczalnych dla różnych konfiguracji problemu. Wyniki zestawiono w Tabeli 6.6.

Tabela 6.6: Wyniki eksploracji przestrzeni stanów procesu dla wybranych konfiguracji problemu

Lp	Liczebność floty UAV	Liczba zadań w strumieniu	Trajektorie dopuszczalne $\mathcal{T}_{ad} \rightarrow S_G$	Trajektorie niedopuszczalne $\mathcal{T}_{nd} \rightarrow S_N$
1	4	22	6	3
2	4	29	30	0
3	4	32	15	3

ciąg dalszy na następnej stronie

Tabela 6.6 (cd.)

Lp	Liczebność floty UAV	Liczba zadań w strumieniu	Trajektorie dopuszczalne $\mathcal{T}_{ad} \rightarrow S_G$	Trajektorie niedopuszczalne $\mathcal{T}_{nd} \rightarrow S_N$
4	4	35	17	1
5	6	20	20	0
6	6	25	20	0
7	6	30	19	1
8	6	35	9	0
9	7	12	12	0
10	7	17	17	0
11	7	20	20	0
12	7	23	21	2
13	7	25	17	3
14	7	30	19	1
15	7	35	18	2
16	7	40	18	2
17	8	20	17	2
18	8	25	19	1
19	8	30	18	2
20	8	35	19	1
21	9	12	12	0
22	9	17	15	2
23	9	23	23	0
24	9	29	14	5

Uzyskane rezultaty potwierdzają, że zaproponowany model algebraiczno-logiczny skutecznie identyfikuje trajektorie prowadzące do osiągnięcia stanów docelowych procesu S_G , jednocześnie eliminując trajektorie niedopuszczalne prowadzące do stanów zabronionych S_N . Wykazano tym samym poprawność mechanizmu eksploracji przestrzeni decyzyjnej oraz zdolność modelu do odrzucania rozwiązań niespełniających przyjętych ograniczeń.

Przeprowadzone eksperymenty bazowe potwierdziły poprawność działania zaproponowanego modelu harmonogramowania zadań UAV w środowisku symulacyjnym. Otrzymane wyniki potwierdzają poprawność operacyjną bazowego odwzorowania procesu harmonogramowania w postaci modelu $P = (U, S, s_0, f, S_N, S_G)$, w szczególności w zakresie generowania sekwencji decyzji prowadzących do stanów docelowych S_G . Wykazano zdolność modelu do:

- poprawnego generowania trajektorii realizacyjnych dla zadań jedno- i wieloetapowych,
- dynamicznego przydziału zadań do jednostek UAV,

- identyfikacji trajektorii dopuszczalnych i niedopuszczalnych,
- wyznaczania harmonogramów minimalizujących całkowity czas realizacji misji.


Uzyskane wyniki stanowią podstawę do rozszerzenia modelu o dodatkowe ograniczenia związane z czasową dostępnością przestrzeni powietrznej, przedstawione w kolejnym podrozdziale.

6.3 Wyniki eksperymentów symulacyjnych z uwzględnieniem ograniczeń czasowych korytarzy

Celem eksperymentów przedstawionych w niniejszym podrozdziale była ocena skuteczności zaproponowanej metody harmonogramowania zadań UAV w warunkach ograniczonej czasowo dostępności korytarzy powietrznych. W odróżnieniu od eksperymentów bazowych omówionych w Podrozdziale 6.2, w których weryfikowano przede wszystkim poprawność generowania trajektorii stanów i przydziału zadań w podstawowym wariantcie modelu ALMM, w tej części uwzględniono dodatkowe ograniczenia wynikające z dostępności przedziałów czasowych korytarzy powietrznych. Eksperymenty te odnoszą się bezpośrednio do modeli ALMM-TS, ALMM-CS oraz ALMM-TW opisanych w Rozdziale 4, a także do algorytmów planowania, przydziału zadań do slotów czasowych oraz generowania trajektorii dopuszczalnych przedstawionych w Rozdziale 5. W badaniach rozważano różne konfiguracje liczby UAV, liczby zadań, liczby korytarzy powietrznych oraz długości ich przedziałów dostępności. Dane dotyczące zajętości korytarzy przyjęto w sposób zbliżony do danych operacyjnych udostępnianych przez PANSA, natomiast listy zadań wygenerowano losowo z wykorzystaniem narzędzia AeroTask Generator. Podczas generowania zadań uwzględniono ograniczenia dotyczące lokalizacji węzłów grafu destynacji, wymaganych czasów przelotu, warunków pogodowych oraz możliwych ograniczeń czasowych realizacji poszczególnych destynacji. Każde zadanie przypisane było do określonego korytarza powietrznego C_k , a jego realizacja była dopuszczalna wyłącznie wtedy, gdy cały przedział wykonania zadania mieścił się w efektywnym przedziale dostępności wymaganego korytarza. Oznacza to, że decyzja harmonogramowa była akceptowana tylko wtedy, gdy spełniała jednocześnie ograniczenia dostępności UAV, dostępności korytarza oraz ograniczenia czasowe realizacji zadania.

Istotnym elementem analizy była koincydencja dostępności korytarzy powietrznych, rozumiana jako występowanie takich przedziałów czasu, w których dostępnym jest jednocześnie kilka korytarzy. Wysoka koincydencja zwiększa elastyczność procesu harmonogramowania, ponieważ umożliwia równoległe wykonywanie większej liczby zadań przez flotę UAV. Niska koincydencja ogranicza natomiast liczbę możliwych decyzji dopuszczalnych i może prowadzić do powstawania stanów niedopuszczalnych S_N , jeżeli zadanie nie może zostać osadzone w żadnym dostępnym przedziale czasowym.

Rysunek 6.13 przedstawia schemat wizualizacji dostępności korytarzy powietrznych oraz ich koincydencji czasowej. Górny panel obrazuje indywidualne okna dostępności poszczególnych korytarzy, natomiast dolny panel wskazuje przedziały wspólnej dostępności, które mają kluczowe znaczenie dla efektywnego przydziału zadań do UAV.



Rysunek 6.13: Schemat koincydencji dostępności korytarzy powietrznych

Na podstawie tak zdefiniowanych ograniczeń przeprowadzono serię eksperymentów dla różnych konfiguracji problemu. W analizowanych wariantach liczba UAV wynosiła od 6 do 9, liczba zadań od 20 do 45, natomiast liczba korytarzy powietrznych była stała i wynosiła 6. Czas dostępności korytarzy mieścił się w przedziale od 2 do 5 godzin. W Tabeli 6.7 przedstawiono wybrane scenariusze wykorzystane w eksperymentach. Kolorem zielonym oznaczono scenariusze, które zostały następnie szczegółowo omówione. W analizie przyjęto, że trajektoria niedopuszczalna stanowi trajektorię procesu, która prowadzi do osiągnięcia co najmniej jednego stanu niedopuszczalnego $s_i \in S_N$. Oznaczając zbiór wszystkich trajektorii przez $\mathcal{T}$, można zapisać: $\mathcal{T}_{nd} = \mathcal{T} \setminus \mathcal{T}_{ad}$.

Tabela 6.7: Wybrane scenariusze eksperymentalne z ograniczeniami czasowej dostępności korytarzy powietrznych

Scenariusz	Liczebność floty UAV	Liczba zadań w strumieniu	Liczba korytarzy $ C $	Zakres $[B_c^r, F_c^r]$ [h]	$\mathcal{T}_{ad} \rightarrow S_G$	$\mathcal{T}_{nd} \rightarrow S_N$
1	6	20	6	3-5	20	0
2	6	25	6	3-5	25	0
3	6	30	6	2-5	30	0
4	6	35	6	3-5	23	12
5	6	40	6	3-5	29	11
6	6	45	6	3-5	31	14
7	6	20	6	2-5	20	0
8	6	25	6	2-5	23	2
9	6	30	6	2-5	25	5
10	6	35	6	2-5	33	2

ciąg dalszy na następnej stronie

Tabela 6.7 (cd.)

Scenariusz	Liczebność floty UAV	Liczba zadań w strumieniu	Liczba korytarzy $ C $	Zakres $[B_c^r, F_c^r]$ [h]	$\mathcal{T}_{ad} \rightarrow S_G$	$\mathcal{T}_{nd} \rightarrow S_N$
11	6	40	6	2-5	29	11
12	6	45	6	2-5	27	18
13	7	20	6	2-5	20	0
14	7	25	6	2-5	24	1
15	7	30	6	2-5	30	0
16	7	35	6	2-5	32	3
17	7	40	6	2-5	37	3
18	7	45	6	2-5	29	16
19	9	20	6	2-5	20	0
20	9	25	6	2-5	25	0
21	9	30	6	2-5	29	1
22	9	35	6	2-5	34	1
23	9	40	6	2-5	38	2
24	9	45	6	2-5	33	12

Przykład 1. Scenariusz 3

Konfiguracja analizowanego scenariusza obejmuje flotę składającą się z sześciu UAV oraz 30 zadań przypisanych do sześciu korytarzy powietrznych. W badanym przypadku system harmonogramowania osiągnął pełną realizację wszystkich zaplanowanych misji ($S_G = 30$), przy całkowitym braku stanów niedopuszczalnych ($S_N = 0$). Analiza Tabeli 6.8 wskazuje, że wszystkie zadania należały do destynacji jednoetapowych, co sprzyjało ich równomiernemu rozmieszczeniu pomiędzy poszczególne korytarze oraz uprościło proces harmonogramowania.

Tabela 6.8: Grupowanie zadań według trajektorii misji dla Scenariusza 3

Trajektoria misji	Zadania do realizacji
UAV Base $\rightarrow$ A $\rightarrow$ UAV Base	J4, J11, J15, J19, J28
UAV Base $\rightarrow$ B $\rightarrow$ UAV Base	J2, J3, J10, J17, J26
UAV Base $\rightarrow$ C $\rightarrow$ UAV Base	J5, J13, J22, J27, J29
UAV Base $\rightarrow$ D $\rightarrow$ UAV Base	J7, J8, J9, J21, J23
UAV Base $\rightarrow$ E $\rightarrow$ UAV Base	J6, J14, J16, J24, J25
UAV Base $\rightarrow$ F $\rightarrow$ UAV Base	J1, J12, J18, J20, J30

Zestawienie w Tabeli 6.9 potwierdza, że wszystkie korytarze dysponowały relatywnie długimi przedziałami dostępności, przekraczającymi w każdym przypadku trzy godziny, co znacząco ułatwiało planowanie


misji bez konieczności odrzucania zadań. Harmonogram dowodzi, że nawet w przypadku występowania krótszych wolnych slotów, system potrafił efektywnie dopasować do nich odpowiednie zadania, minimalizując ryzyko powstawania konfliktów czasowych. Dodatkowo, rozkład obciążenia floty UAV był zrównoważony - każda jednostka została wykorzystana w podobnym zakresie, bez przypadków nadmiernej eksploatacji lub niewykorzystania zasobów.

Tabela 6.9: Czas dostępności korytarzy dla Scenariusza 3

Nr korytarza	Czas dostępności korytarza		Harmonogram wykonywanych zadań przez UAV
	dostępny	niedostępny	
1	03:21:50	04:38:10	J4 UAV6; J11 UAV1; J15 UAV2; J19 UAV5; J28 UAV3
2	03:15:31	04:44:29	J2 UAV6; J3 UAV1; J10 UAV2; J17 UAV3; J26 UAV4
3	02:38:11	05:21:49	J5 UAV6; J13 UAV1; J22 UAV2; J27 UAV5; J29 UAV4
4	02:26:31	05:33:29	J7 UAV6; J8 UAV1; J9 UAV2; J21 UAV5; J23 UAV4
5	03:10:03	04:49:57	J6 UAV6; J14 UAV1; J16 UAV2; J24 UAV5; J25 UAV3
6	03:57:41	04:02:19	J1 UAV1; J12 UAV2; J18 UAV3; J20 UAV4; J30 UAV5

Przedstawione wyniki potwierdzają spełnienie ograniczeń czasowej dostępności korytarzy opisanych w modelu ALMM-CS. Wszystkie zadania zostały przypisane do przedziałów dostępności odpowiadających właściwym korytarzom lotniczym, co oznacza, że wygenerowana trajektoria procesu należy do zbioru trajektorii dopuszczalnych $\mathcal{T}_{ad}$. Wizualizację harmonogramu przedstawiono na Rysunku 6.14, który obejmuje trzy główne komponenty:

- Dostępność korytarzy w czasie – górny panel rysunku obrazuje sekwencję dostępnych (zielonych) i niedostępnych (czerwonych) przedziałów czasowych dla każdego z korytarzy.
- Przypisanie zadań do korytarzy – panel środkowy prezentuje szczegółowe rozmieszczenie zadań w dostępnych slotach czasowych, z uwzględnieniem identyfikatorów misji (np. J4, J11).
- Zadania wykonywane przez poszczególne UAV – dolny panel przedstawia rozkład operacji w czasie dla każdego UAV, pozwalając ocenić równomierność obciążenia floty.



Rysunek 6.14: Harmonogram operacji UAV dla scenariusza 3: 6 UAV, 30 zadań

Wyniki przedstawione na Rysunku 6.14 potwierdzają, że model ALMM-CS skutecznie wykorzystuje dostępne przedziały czasowe korytarzy lotniczych, zachowując zgodność z ograniczeniami ich dostępności oraz zapewniając pełną realizację zbioru zadań. Szczególnie istotna jest zdolność modelu do generowania trajektorii dopuszczalnych również w warunkach znacznej fragmentacji dostępnych przedziałów czasowych, w tym przy występowaniu krótkich okien operacyjnych. Uzyskany harmonogram wskazuje ponadto na efektywne ograniczanie czasu oczekiwania UAV na rozpoczęcie kolejnych misji dzięki mechanizmowi adaptacyjnego przypisania jednostek do dostępnych korytarzy w danym przedziale czasowym.

Przykład 2. Scenariusz 10

Konfiguracja obejmuje 6 UAV oraz 35 zadań przypisanych do sześciu korytarzy powietrznych. W badanym przypadku system osiągnął wysoki poziom realizacji zadań, wykonując 33 misje spośród zaplanowanych ($S_G = 33$) przy jedynie dwóch stanach niedopuszczalnych ($S_N = 2$), co oznacza, że J32 i J33 zadanie nie mogły zostać przypisane w dostępnych przedziałach czasowych. Analiza Tabeli 6.10 pokazuje, że zadania zostały przydzielone do trajektorii jednoetapowych, z równomiernym rozkładem między korytarze, co ograniczyło ryzyko nadmiernego obciążenia pojedynczych segmentów przestrzeni powietrznej.

Dane w Tabeli 6.11 wskazują, że większość korytarzy posiadała relatywnie długie okresy dostępności (w zakresie od 2 godzin i 14 minut do ponad 4 godzin i 36 minut), co umożliwiło elastyczne rozmieszczenie zadań. Wyjątkiem był korytarz 5, w którym dostępność wynosiła jedynie 2 godziny i 14 minut - to ograniczenie skutkowało koniecznością bardzo ścisłego dopasowania czasów rozpoczęcia misji. Harmono-

Tabela 6.10: Klasy trajektorii zadań dla Scenariusza 10


Trajektoria	Zadania do realizacji
UAV Base → A → UAV Base	J13, J16, J23, J26, J29
UAV Base → B → UAV Base	J2, J3, J6, J19, J30, J34
UAV Base → C → UAV Base	J1, J5, J8, J11, J24
UAV Base → D → UAV Base	J10, J17, J18, J20, J22, J35
UAV Base → E → UAV Base	J4, J7, J12, J14, J21, J28
UAV Base → F → UAV Base	J9, J15, J25, J27, J31

gram potwierdza, że algorytm dynamicznie przypisywał zadania w sposób minimalizujący konflikty, a przy tym równoważył obciążenie pomiędzy UAV, unikając sytuacji, w której dany UAV pozostawałby bezczynny przez znaczną część symulacji.

Tabela 6.11: Czas dostępności korytarzy dla Scenariusza 10

Nr korytarza	Czas dostępności korytarza		Harmonogram wykonywanych zadań przez UAV
	dostępny	niedostępny	
1	02:19:38	05:40:22	J13 UAV6; J16 UAV1; J23 UAV2; J26 UAV3; J29 UAV4
2	04:16:11	03:43:49	J2 UAV6; J3 UAV1; J6 UAV2; J19 UAV3; J30 UAV4; J34 UAV5
3	02:31:04	05:28:56	J1 UAV6; J5 UAV1; J8 UAV2; J11 UAV3; J24 UAV5
4	04:36:07	03:23:53	J10 UAV6; J17 UAV1; J18 UAV2; J20 UAV3; J22 UAV4; J35 UAV5
5	02:14:07	05:45:53	J4 UAV6; J7 UAV1; J12 UAV2; J14 UAV3; J21 UAV4; J28 UAV5
6	03:54:08	04:05:52	J9 UAV1; J15 UAV2; J25 UAV3; J27 UAV4; J31 UAV5

Na Rysunku 6.15 przedstawiono harmonogram czasu dostępności korytarzy oraz operacji UAV. Wyraźnie widoczna jest pełna synchronizacja zadań w krótkich oknach dostępności oraz skuteczne ich rozmieszczenie w dłuższych przedziałach czasowych. Kolorystyczne oznaczenia UAV pozwalają prześledzić, że ten sam statek może wykonywać operacje w różnych korytarzach, co dowodzi poprawnego działania mechanizmu dynamicznego przypisania jednostek.



Rysunek 6.15: Harmonogram operacji UAV dla scenariusza 10: 6 UAV, 35 zadań

Przykład 3. Scenariusz 15

W tym scenariuszu skonfigurowano flotę składającą się z 7 UAV, które realizowały 30 zadań w sześciu korytarzach powietrznych. Wszystkie zaplanowane misje zostały wykonane ($S_G = 30$), co potwierdza wysoką skuteczność działania systemu. Analiza Tabeli 6.13 ujawnia, że każde z zadań miało prostą trajektorię jednoetapową, co w połączeniu z rozsądnym rozkładem po korytarzach sprzyjało równomiernemu obciążeniu floty.

Tabela 6.13: Klasy trajektorii zadań dla Scenariusza 15

Trajektoria	Zadania do realizacji
UAV Base → A → UAV Base	J1, J10, J13, J23, J29
UAV Base → B → UAV Base	J5, J20, J21, J22, J27
UAV Base → C → UAV Base	J7, J9, J11, J14, J15
UAV Base → D → UAV Base	J2, J24, J25, J26, J28
UAV Base → E → UAV Base	J3, J6, J12, J16, J18
UAV Base → F → UAV Base	J4, J8, J17, J19, J30


Jak pokazuje Tabela 6.14, korytarze w tym scenariuszu dysponowały stosunkowo długimi oknami czasowymi (od 3 godzin 52 minut do niemal 4 godzin 52 minut), co ułatwiło harmonogramowanie. Algo-

rytm skutecznie unikał kolizji czasowych i przeciążeń w obrębie poszczególnych korytarzy, a dodatkowa liczba UAV względem scenariusza 3 zwiększyła możliwości równoległej realizacji zadań. Widoczne jest, że niektóre UAV były przypisywane do korytarzy w sposób wielokrotny, jednak bez powtarzania schematu przypisania, co wskazuje na elastyczność algorytmu w doborze jednostek.

Tabela 6.14: Czas dostępności korytarzy dla Scenariusza 15

Nr korytarza	Czas dostępności korytarza		Harmonogram wykonywanych zadań przez UAV
	dostępny	niedostępny	
1	04:44:42	03:15:18	J1 UAV6; J10 UAV7; J13 UAV1; J23 UAV2; J29 UAV3
2	04:48:44	03:11:16	J5 UAV6; J20 UAV7; J21 UAV1; J22 UAV2; J27 UAV3
3	04:51:25	03:08:35	J7 UAV6; J9 UAV7; J11 UAV1; J14 UAV4; J15 UAV2
4	03:52:35	04:07:25	J2 UAV6; J24 UAV7; J25 UAV1; J26 UAV2; J28 UAV4
5	04:50:04	03:09:56	J3 UAV6; J6 UAV7; J12 UAV1; J16 UAV4; J18 UAV3
6	03:59:17	04:00:43	J4 UAV1; J8 UAV2; J17 UAV3; J19 UAV4; J30 UAV5

Rysunek 6.16 przedstawia harmonogramy, w którym górny panel ukazuje dostępność poszczególnych korytarzy powietrznych w postaci slotów dostępnych i niedostępnych, natomiast kolejne prezentują szczegółowy rozkład realizowanych zadań w tych korytarzach, z przypisaniem do konkretnych UAV. Dolny harmonogram przedstawia harmonogram operacji poszczególnych UAV w ujęciu czasowym, co umożliwia analizę stopnia równomiernego obciążenia floty. Z analizy układu zadań wynika, że system skutecznie minimalizuje czasy oczekiwania pomiędzy kolejnymi misjami oraz unika tworzenia niepotrzebnych przerw w wykorzystaniu jednostek. Widoczna jest także zdolność algorytmu do elastycznego przypisywania UAV do różnych korytarzy w zależności od bieżącej dostępności slotów, co pozwala maksymalizować wykorzystanie zasobów. Szczególnie istotne jest, że przy dużej liczbie krótkich okien dostępności w korytarzach o wysokim stopniu fragmentacji, zadania zostały tak rozmieszczone, aby zapewnić ciągłość operacyjną większości UAV przez znaczną część trwania symulacji. Dzięki takiej organizacji harmonogramu możliwe jest utrzymanie wysokiej przepustowości operacyjnej systemu przy jednoczesnym ograniczeniu ryzyka kolizji czasowych w korytarzach powietrznych. Równomierne rozłożenie zadań między UAV oraz ich rozproszenie w czasie dowodzi skuteczności zaimplementowanej strategii przydziału i harmonogramowania zadań w warunkach dynamicznie zmieniającej się dostępności przestrzeni powietrznej.



Rysunek 6.16: Harmonogram operacji UAV dla scenariusza 15: 7 UAV, 30 zadań

Przykład 4. Scenariusz 21

W najbardziej wymagającym z analizowanych przykładów zastosowano flotę 9 UAV do realizacji 30 zadań w sześciu korytarzach powietrznych. System wykonał 29 misji, pozostawiając jedno zadanie (J25) nieprzydzielone z powodu braku dostępnych slotów spełniających wymagania czasowe $\mathcal{T}_{ad} = 29$, $\mathcal{T}_{nd} = 1$. Z analizy Tabeli 6.15 wynika, że wszystkie trajektorie były jednoetapowe, jednak liczba dostępnych UAV była znacznie większa niż w pozostałych scenariuszach, co spowodowało, że algorytm miał większą elastyczność w przypisywaniu jednostek, ale też musiał uwzględniać większą złożoność potencjalnych kombinacji.

Tabela 6.15: Klasy trajektorii zadań dla Scenariusza 21


Trajektoria misji	Zadania do realizacji
UAV Base → A → UAV Base	J10, J11, J13, J14, J26
UAV Base → B → UAV Base	J4, J5, J8, J18, J28
UAV Base → C → UAV Base	J1, J6, J19, J21, J29
UAV Base → D → UAV Base	J3, J12, J16, J17, J20
UAV Base → E → UAV Base	J7, J9, J23, J27, J30
UAV Base → F → UAV Base	J2, J15, J22, J24

Tabela 6.16 pokazuje, że w tym scenariuszu pojawiły się korytarze o znacznie krótszych czasach dostępności - szczególnie korytarz 6 z czasem zaledwie 1 godziny i 58 minut, co mogło stanowić główną przyczynę braku możliwości przypisania jednego zadań. Mimo to pozostałe korytarze miały dostępność przekraczającą 3 godziny, co pozwoliło na efektywne planowanie pozostałych misji. Harmonogram pokazuje również, że pomimo dużej liczby UAV, system unikał dublowania jednostek w tym samym czasie w jednym korytarzu, co minimalizuje ryzyko kolizji i przeciążeń.

Tabela 6.16: Czas dostępności korytarzy dla Scenariusza 21

Nr korytarza	Czas dostępności korytarza		Harmonogram wykonywanych zadań przez UAV
	dostępny	niedostępny	
1	03:41:59	04:18:01	J10 UAV5; J11 UAV1; J13 UAV6; J14 UAV7; J26 UAV8
2	04:50:31	03:09:29	J4 UAV5; J5 UAV6; J8 UAV7; J18 UAV8; J28 UAV9
3	04:28:33	03:31:27	J1 UAV5; J6 UAV1; J19 UAV6; J21 UAV7; J29 UAV2
4	03:16:40	04:43:20	J3 UAV5; J12 UAV1; J16 UAV6; J17 UAV2; J20 UAV7
5	03:44:24	04:15:36	J7 UAV5; J9 UAV1; J23 UAV6; J27 UAV7; J30 UAV8
6	01:58:53	06:01:07	J2 UAV1; J15 UAV2; J22 UAV3; J24 UAV4

Rysunek 6.17 prezentuje harmonogram pracy UAV i dostępności korytarzy, w którym wyraźnie widać fragmenty niewykorzystanych slotów w korytarzach o najkrótszych oknach czasowych. Zastosowany algorytm adaptacyjnego przypisywania zadań umożliwił jednak maksymalne wykorzystanie zasobów w pozostałych korytarzach, przy jednoczesnym utrzymaniu wysokiej równowagi obciążenia między UAV.



Rysunek 6.17: Harmonogram operacji UAV dla scenariusza 21: 9 UAV, 30 zadań

Przeprowadzone eksperymenty symulacyjne dla różnych konfiguracji problemu, obejmujących floty od 6 do 9 UAV, zbiory od 20 do 45 zadań oraz zróżnicowane profile czasowej dostępności korytarzy powietrznych, potwierdziły skuteczność zaproponowanego mechanizmu harmonogramowania w warunkach ograniczonej dostępności przestrzeni operacyjnej. Uzyskane harmonogramy charakteryzowały się wysokim stopniem wykorzystania dostępnych slotów czasowych, ograniczeniem przestojów pomiędzy kolejnymi misjami oraz równomiernym rozłożeniem obciążenia pomiędzy jednostki UAV.

Wyniki potwierdzają, że wprowadzenie ograniczeń czasowej dostępności korytarzy powietrznych istotnie zawęży przestrzeń decyzji dopuszczalnych, jednak opracowany algorytm umożliwia konstruowanie trajektorii prowadzących do stanów docelowych S_G . W scenariuszach o wysokiej koincydencji dostępności korytarzy uzyskano pełną realizację zadań, natomiast w przypadkach krótszych lub silnie pofragmentowanych okien operacyjnych pojawiały się pojedyncze stany niedopuszczalne S_N , wynikające z braku możliwości osadzenia zadania w dopuszczalnym przedziale czasowym.

Analiza wyników wskazuje, że skuteczność harmonogramowania zależy nie tylko od liczebności floty UAV, lecz także od struktury czasowej dostępności korytarzy oraz stopnia ich wzajemnej koincydencji. Zwiększenie liczby dostępnych jednostek poprawia elastyczność przydziału, ale nie eliminuje ograniczeń wynikających z niedostępności przestrzeni powietrznej. Oznacza to, że przepustowość systemu determinowana jest zarówno przez zasoby wykonawcze, jak i przez zewnętrzne ograniczenia infrastrukturalne.

Otrzymane rezultaty potwierdzają zgodność działania algorytmu z założeniami modeli ALMM-CS oraz ALMM-TW opisanych w Rozdziale 4, a także z algorytmami przydziału zadań do slotów i generowania trajektorii dopuszczalnych przedstawionymi w Rozdziale 5. Sekcja ta stanowi naturalne rozszerzenie eks-

perymentów bazowych i stanowi wprowadzenie do walidacji modelu ALMM-D w warunkach zakłóceń dynamicznych.

6.4 Walidacja modelu ALMM-D w warunkach dynamicznych zakłóceń zasobowych i zadaniowych

Celem eksperymentów przedstawionych w niniejszym podrozdziale była walidacja modelu ALMM-D oraz algorytmów dynamicznego harmonogramowania opisanych w Podrozdziale 5.7. Analizie poddano reakcję systemu na zakłócenia ujawniające się w trakcie realizacji harmonogramu, w szczególności zakłócenia zasobowe związane z czasową niedostępnością wybranych UAV oraz zakłócenia zadaniowe obejmujące anulowanie zadań lub pojawienie się nowych zadań w strumieniu wejściowym.

W każdym scenariuszu najpierw wyznaczano harmonogram bazowy odpowiadający nominalnej trajektorii stanów procesu, a następnie wprowadzano zakłócenie powodujące zmianę struktury stanu systemu. Ocenie podlegała zdolność modelu do lokalnej rekonfiguracji przyszłego segmentu trajektorii stanów, zachowania dopuszczalności przejść oraz osiągnięcia stanów docelowych S_G przy minimalnej liczbie stanów niedopuszczalnych S_N . W eksperymentach przyjęto czasową dostępność korytarzy powietrznych w zakresie od 2 do 5 godzin, zgodnie z założeniami wykorzystanymi w Podrozdziale 6.3.

W dalszej części pojęcie reoptymalizacji oznacza lokalną rekonfigurację przyszłego segmentu trajektorii stanów, obejmującą ponowną alokację zadań do dostępnych UAV oraz dostępnych slotów czasowych. Takie ujęcie odpowiada założeniom modelu ALMM-D, w którym zakłócenie modyfikuje zbiór decyzji dopuszczalnych $U_p(s)$, a system wyznacza nową trajektorię prowadzącą do S_G lub identyfikuje przejścia prowadzące do S_N . Wybrane scenariusze zakłóceń zasobowych wykorzystane w eksperymentach zestawiono w Tabeli 6.18. Scenariusze oznaczone kolorem zielonym zostały następnie szczegółowo omówione jako przykłady reprezentatywne.

Tabela 6.18: Wybrane scenariusze wykorzystywane w eksperymentach z uwzględnieniem zakłóceń zasobowych

Scenariusz	Liczebność floty UAV	Liczba zadań w strumieniu	Zakłócenie zasobowe	$\mathcal{T}_{ad} \rightarrow S_G$	$\mathcal{T}_{nd} \rightarrow S_N$
1	6	25	UAV1, UAV2	25	0
2	6	30	UAV2	30	0
3	6	30	UAV6	30	0
4	6	30	UAV4	29	1
5	6	30	UAV4	30	0
6	6	30	UAV1, UAV4	29	1
7	6	30	UAV3, UAV5	30	0
8	6	30	UAV4, UAV6	30	0

ciąg dalszy na następnej stronie

Tabela 6.18 (cd.)


Scenariusz	Liczebność floty UAV	Liczba zadań w strumieniu	Zakłócenie zasobowe	$\mathcal{T}_{ad} \rightarrow S_G$	$\mathcal{T}_{nd} \rightarrow S_N$
9	6	30	UAV2, UAV4, UAV5	28	2
10	6	30	UAV3, UAV5, UAV6	30	0
11	6	30	UAV2, UAV3, UAV5	29	1
12	6	35	UAV3	32	3
13	6	35	UAV3, UAV4	35	0
14	6	40	UAV5	34	6
15	7	30	UAV1, UAV2	30	0
16	7	30	UAV1, UAV3	30	0
17	7	35	UAV5, UAV6	35	0
18	7	35	UAV3, UAV4, UAV6	35	0
19	7	40	UAV1, UAV3	40	0
20	7	40	UAV3, UAV4	31	9
21	7	40	UAV4, UAV6, UAV7	40	0
22	8	45	UAV3, UAV4	38	7

Scenariusze zakłóceń zadaniowych, obejmujące anulowanie oraz dopływ nowych zadań, omówiono oddzielnie w końcowej części podrozdziału.

Przykład 1. Reakcja modelu ALMM-D na pojedynczą awarię UAV (Scenariusz 2)

W pierwszym eksperymencie przeanalizowano przypadek dynamicznego zakłócenia zasobowego polegającego na czasowej niedostępności pojedynczej jednostki UAV podczas realizacji harmonogramu. Rozpatrywana instancja obejmuje flotę 6 UAV realizujących 30 zadań w horyzoncie czasowym 08:00–16:00. Dostępność korytarzy powietrznych modelowano jako zbiory nieprzecinających się slotów czasowych, przy średnim współczynniku dostępności równym 57.28% (niedostępność: 42.72%).

Dla modelu ALMM-D wyznaczono harmonogram bazowy odpowiadający nominalnemu przebiegowi procesu przed wystąpieniem zakłócenia. Rozkład dostępności korytarzy oraz wynikowy harmonogram bazowy przedstawiono na Rysunku 6.18.



Rysunek 6.18: Harmonogram bazowy operacji floty UAV dla scenariusza 2

Tabela 6.19 przedstawia szczegółowe zestawienie przedziałów dostępności i niedostępności poszczególnych korytarzy wraz z przypisanymi zadaniami. Reprezentacja ta odpowiada bazowej trajektorii przejść w przestrzeni stanów, prowadzącej od stanu początkowego s_0 do harmonogramu nominalnego.

Tabela 6.19: Dostępność czasowa korytarzy oraz przypisane zadania dla Scenariusza 2


Korytarz	Czas korytarza (HH:MM:SS)		Harmonogram wykonywanych zadań przez UAV
	dostępny	niedostępny	
1	04:24:40	03:35:20	J3UAV6, J8UAV1, J12UAV2, J17UAV5, J26UAV3
2	04:31:10	03:28:50	J1UAV6, J2UAV1, J4UAV2, J10UAV3, J21UAV4
3	04:44:02	03:15:58	J5UAV6, J11UAV1, J14UAV4, J23UAV2, J27UAV5
4	04:41:23	03:18:03	J6UAV6, J9UAV1, J13UAV4, J24UAV5, J25UAV3
5	04:49:29	03:10:31	J15UAV6, J18UAV1, J20UAV4, J28UAV3, J29UAV2
6	04:18:57	03:41:03	J7UAV1, J16UAV2, J19UAV3, J22UAV4, J30UAV5

W przedziale czasu $t \in [09:00, 10:00]$ zasymulowano czasową niedostępność jednostki UAV2, modelowaną jako antysłot zasobowy: $Z_{UAV2} = [09:00, 10:00]$. Zdarzenie to powoduje zmianę struktury wektora stanu poprzez czasowe usunięcie zasobu z procesu decyzyjnego, generując stany niedopuszczalne S_N dla zadań zaplanowanych w oknie awarii. Zgodnie z procedurą ALMM-D zadania należące do zbioru $J_z(\delta_i)$ poddano resekwencjonowaniu i realokacji z zachowaniem ograniczeń dostępności korytarzy oraz warunków separacji czasowej. Wynik procesu reoptymalizacji przedstawiono na Rysunku 6.19.



Rysunek 6.19: Harmonogram po wystąpieniu awarii UAV2

Rysunek 6.20 przedstawia porównanie trajektorii bazowej oraz trajektorii po reoptymalizacji. Elementy oznaczone jako $J_x (pre)$ reprezentują pierwotne pozycje zadań w harmonogramie bazowym i umożliwiają identyfikację przesunięć wynikających z rekonfiguracji.



Rysunek 6.20: Porównanie harmonogramu przed i po wystąpieniu awarii UAV2

Tabela 6.20 prezentuje zmiany w przypisaniu zadań do poszczególnych UAV przed oraz po wystąpieniu zakłócenia.


Tabela 6.20: Zmiany w alokacji zadań do UAV przed i po rekonfiguracji - Scenariusz 2

UAV	Przypisane zadania	
	Przed awarią	Po awarii
UAV1	J7, J2, J8, J11, J18, J9	J7, J2, J8, J11, J18, J9
UAV2	J16, J4, J12, J23, J29	J16, J4, J12, J14, J20, J13
UAV3	J19, J10, J26, J28, J25	J19, J10, J17, J27, J24
UAV4	J22, J21, J14, J20, J13	J22, J21, J26, J28, J25
UAV5	J30, J17, J27, J24	J30, J23, J29
UAV6	J1, J3, J5, J15, J6	J1, J3, J5, J15, J6

Uzyskane wyniki potwierdzają, że model ALMM-D poprawnie identyfikuje zakłócenie zasobowe jako zmianę struktury stanu procesu i inicjuje lokalną rekonfigurację trajektorii decyzyjnej bez konieczności pełnego przeliczania harmonogramu od początku. Pomimo czasowej utraty jednej jednostki UAV system zachował pełną realizowalność zbioru zadań, osiągając końcowo stan $S_G = 30$ przy $S_N = 0$. Otrzymane rezultaty potwierdzają zdolność modelu do dynamicznej adaptacji i utrzymania ciągłości procesu planowania w warunkach występowania pojedynczych zakłóceń zasobowych.

Przykład 2. Reakcja modelu ALMM-D na wielokrotne zakłócenie zasobowe (Scenariusz 9)

W drugim eksperymencie przeanalizowano przypadek wielokrotnego zakłócenia zasobowego polegającego na jednoczesnej awarii trzech jednostek UAV podczas realizacji harmonogramu. Rozpatrywana instancja obejmuje flotę 6 UAV realizujących 30 zadań w horyzoncie czasowym 08:00–16:00. Średnia dostępność korytarzy powietrznych wyniosła 55.81%, przy niedostępności na poziomie 44.19%, co odpowiada umiarkowanie ograniczonej przestrzeni decyzyjnej procesu harmonogramowania. Na podstawie modelu ALMM-D wyznaczono harmonogram bazowy odpowiadający trajektorii nominalnej przed wystąpieniem zakłóceń. Rozkład dostępności slotów czasowych oraz wynikowy harmonogram przedstawiono na Rysunku 6.21.



Rysunek 6.21: Harmonogram bazowy operacji floty UAV dla Scenariusza 9


Tabela 6.22 przedstawia zestawienie dostępności czasowej poszczególnych korytarzy wraz z przypisanymi zadaniami. Reprezentacja ta odpowiada bazowej trajektorii przejść w przestrzeni stanów i stanowi punkt odniesienia dla dalszej analizy procesu rekonfiguracji.

Tabela 6.22: Dostępność czasowa korytarzy oraz przypisane zadania dla Scenariusza 9

Korytarz	Czas korytarza (HH:MM:SS)		Harmonogram wykonywanych zadań przez UAV
	dostępny	niedostępny	
1	04:20:20	03:39:40	J5UAV6, J8UAV1, J12UAV2, J21UAV3, J29UAV5
2	04:34:29	03:25:31	J2UAV6, J4UAV1, J10UAV2, J24UAV3, J27UAV4
3	04:48:20	03:11:40	J13UAV6, J14UAV1, J19UAV2, J23UAV3, J26UAV4
4	04:02:40	03:57:20	J6UAV6, J9UAV1, J11UAV2, J22UAV3, J25UAV5
5	04:55:42	03:04:18	J3UAV6, J15UAV1, J17UAV2, J18UAV3, J30UAV4
6	04:05:46	03:54:14	J1UAV1, J7UAV2, J16UAV3, J20UAV4, J28UAV5


W przedziale czasu $t \in [12:22:39, 13:37:14]$ zasymulowano równoczesne awarie trzech jednostek: UAV2, UAV4 oraz UAV5. Zdarzenia te powodują czasowe usunięcie części zasobów z procesu decyzyjnego, generując stany niedopuszczalne S_N dla zadań zaplanowanych w oknie zakłócenia. Bezpośrednio zakłócone zostały zadania J11, J17, J20 oraz J28. W wyniku procesu rekonfiguracji model ALMM-D przeprowadził lokalną reoptymalizację przyszłego segmentu trajektorii. Zadania J11 i J17 zostały skutecznie przesunięte i ponownie osadzone w dopuszczalnych slotach czasowych, natomiast zadania J20 i J28 nie

mogły zostać ponownie przydzielone ze względu na brak dostępnych przedziałów czasowych w korytarzu C_6 . Wynik procesu rekonfiguracji przedstawiono na Rysunku 6.22.



Rysunek 6.22: Harmonogram po wystąpieniu awarii trzech jednostek UAV

Rysunek 6.23 przedstawia porównanie trajektorii bazowej oraz trajektorii po reoptymalizacji. Elementy oznaczone jako $Jx (pre)$ reprezentują pierwotne pozycje zadań w harmonogramie bazowym i umożliwiają analizę zakresu zmian wprowadzonych przez mechanizm rekonfiguracji.



Rysunek 6.23: Porównanie harmonogramu przed i po wystąpieniu awarii – scenariusz 9

Tabela 6.23 przedstawia zmiany w przypisaniu zadań do poszczególnych UAV przed oraz po wystąpieniu zakłócenia.


Tabela 6.23: Zmiany w przypisaniu zadań do UAV przed i po awarii – scenariusz 9

UAV	Przypisane zadania	
	Przed awarią	Po awarii
UAV1	J1, J4, J8, J14, J15, J9	J1, J4, J8, J14, J15, J9
UAV2	J7, J10, J12, J19, J17, J11	J7, J10, J12, J19, J17, J11
UAV3	J16, J24, J21, J23, J18, J22	J16, J24, J21, J23, J18, J22
UAV4	J20, J27, J26, J30	J27, J26, J30
UAV5	J28, J29, J25	J29, J25
UAV6	J2, J5, J13, J3, J6	J2, J5, J13, J3, J6

Analiza wyników wskazuje, że spośród 30 zaplanowanych zadań 26 zachowało pierwotne pozycje w harmonogramie, 2 zadania zostały przesunięte w czasie, natomiast 2 zadania zostały odrzucone z powodu obiektywnego braku dostępnych slotów czasowych. Ostatecznie system wygenerował $\mathcal{T}_d = 28$ trajektorii prowadzących do stanów docelowych oraz $\mathcal{T}_{nd} = 2$ trajektorie prowadzące do stanów niedopuszczalnych. Uzyskane rezultaty potwierdzają, że model ALMM-D zachowuje zdolność do utrzymania poprawności procesu decyzyjnego nawet przy jednoczesnej utracie 50% aktywnej floty. Mechanizm rekonfiguracji umożliwia lokalną adaptację trajektorii, ograniczając zakres zmian wyłącznie do segmentu przyszłego oraz jednoznacznie identyfikując przypadki, w których osiągnięcie pełnego stanu docelowego jest niemożliwe z przyczyn obiektywnych wynikających z ograniczeń przestrzenno-czasowych.

Przykład 3. Reakcja modelu ALMM-D na równoczesną awarię trzech UAV (Scenariusz 11)

W trzecim eksperymencie przeanalizowano przypadek równoczesnego zakłócenia zasobowego obejmującego awarię trzech jednostek floty: UAV2, UAV3 oraz UAV5. Rozpatrywana instancja obejmuje flotę 6 UAV realizujących 30 zadań w horyzoncie czasowym 08:00–16:00. Średnia dostępność korytarzy powietrznych wyniosła 54.87%, przy niedostępności na poziomie 45.13%, co odpowiada umiarkowanej gęstości ograniczeń przestrzenno-czasowych. Na podstawie modelu ALMM-D wyznaczono harmonogram bazowy odpowiadający trajektorii nominalnej przed wystąpieniem zakłóceń. Harmonogram ten przedstawiono na Rysunku 6.24.



Rysunek 6.24: Harmonogram bazowy operacji floty 6 UAV dla scenariusza 11

Tabela 6.25 przedstawia zestawienie dostępności czasowej poszczególnych korytarzy wraz z przypisanymi zadaniami. Dane te opisują bazową trajektorię przejazdów w przestrzeni stanów i stanowią punkt odniesienia dla analizy procesu rekonfiguracji po wystąpieniu zakłócenia.


Tabela 6.25: Dostępność czasowa korytarzy oraz przypisane zadania dla scenariusza 11

Korytarz	Czas korytarza (HH:MM:SS)		Harmonogram wykonywanych zadań przez UAV
	dostępny	niedostępny	
1	04:21:32	03:38:28	J1UAV6, J10UAV1, J11UAV2, J24UAV5, J26UAV3
2	04:28:29	03:31:31	J6UAV6, J20UAV1, J23UAV2, J27UAV3, J30UAV4
3	04:50:01	03:09:59	J3UAV6, J4UAV1, J8UAV2, J13UAV5, J17UAV3
4	04:10:03	03:49:57	J2UAV6, J9UAV1, J12UAV2, J22UAV5, J28UAV3
5	04:32:46	03:27:14	J5UAV6, J7UAV1, J15UAV2, J19UAV5, J25UAV3
6	03:57:21	04:02:39	J14UAV1, J16UAV2, J18UAV3, J21UAV4, J29UAV5

W przedziale czasu $t \in [10:26:55, 13:40:12]$ zasymulowano równoczesne awarie trzech jednostek: UAV2, UAV3 oraz UAV5. Zdarzenia te spowodowały czasowe ograniczenie dostępnych zasobów oraz zmianę struktury stanu procesu. W konsekwencji dla części zadań przypisanych do uszkodzonych UAV pojawiły się stany niedopuszczalne S_N . Bezpośrednio zakłócone zostały m.in. zadania J23, J27 oraz J29.


Po wykryciu zakłócenia model ALMM-D uruchomił procedurę rekonfiguracji przyszłego segmentu trajektorii. Część zadań została przesunięta w czasie i ponownie przypisana do dostępnych UAV, natomiast

zadanie J30 nie mogło zostać zrealizowane ze względu na brak wolnego slotu spełniającego wymagania czasowo-przestrzenne. Wynikowy harmonogram po reoptymalizacji przedstawiono na Rysunku 6.25.



Rysunek 6.25: Harmonogram po wystąpieniu awarii trzech jednostek UAV

Porównanie harmonogramu bazowego oraz harmonogramu po rekonfiguracji przedstawiono na Rysunku 6.26. Elementy oznaczone jako Jx (pre) wskazują pierwotne pozycje zadań przed reoptymalizacją, natomiast obszary oznaczone jako AWARIA reprezentują przedziały czasowej niedostępności zasobów UAV.



Rysunek 6.26: Porównanie harmonogramu przed i po wystąpieniu awarii – scenariusz 11

Tabela 6.26 przedstawia zmiany w przypisaniu zadań do poszczególnych UAV przed oraz po wystąpieniu zakłócenia.

Tabela 6.26: Zmiany w przypisaniu zadań do UAV przed i po awarii – scenariusz 11

UAV	Przypisane zadania	
	Przed awarią	Po awarii
UAV1	J14, J20, J10, J4, J7, J9	J14, J20, J10, J4, J7, J9
UAV2	J16, J23, J11, J8, J15, J12	J16, J11, J8, J15, J12, J23
UAV3	J18, J27, J26, J17, J25, J28	J18, J27, J28
UAV4	J21, J30	J21, J26, J17, J19, J22
UAV5	J29, J24, J13, J19, J22	J24, J13, J29, J25
UAV6	J6, J1, J3, J5, J2	J6, J1, J3, J5, J2


Analiza wyników wskazuje, że spośród 30 zaplanowanych zadań 20 zachowało pierwotne przypisanie, 9 zostało przesuniętych w czasie lub przealokowanych do innych jednostek, natomiast jedno zadanie, J30, nie mogło zostać ponownie osadzone w harmonogramie. Ostatecznie uzyskano $\mathcal{T}_d = 29$ trajektorii prowadzących do stanów docelowych oraz $\mathcal{T}_{nd} = 1$ trajektorię niedopuszczalną.

Uzyskane rezultaty potwierdzają, że model ALMM-D zachowuje zdolność do stabilnej rekonfiguracji harmonogramu nawet przy jednoczesnej utracie połowy aktywnej floty. Mechanizm reoptymalizacji ogranicza zakres zmian do niezbędnego segmentu trajektorii, zachowuje spójność procesu decyzyjnego oraz jednoznacznie identyfikuje przypadki, w których pełna realizacja zbioru zadań jest niemożliwa ze względu na ograniczenia dostępności korytarzy powietrznych.

Przykład 4. Skalowalność modelu ALMM-D przy awarii trzech UAV (Scenariusz 18)

W czwartym eksperymencie przeanalizowano zachowanie modelu ALMM-D w warunkach złożonego zakłócenia zasobowego obejmującego jednoczesną awarię trzech jednostek floty: UAV3, UAV4 oraz UAV6. Rozpatrywana instancja obejmuje flotę 7 UAV realizujących 35 zadań w horyzoncie czasowym 08:00–16:00. Średnia dostępność korytarzy powietrznych wyniosła 55.21%, przy niedostępności na poziomie 44.79%, co odpowiada umiarkowanemu poziomowi ograniczeń przestrzenno-czasowych.

Na podstawie modelu ALMM-D wyznaczono harmonogram bazowy odpowiadający trajektorii nominalnej przed wystąpieniem zakłóceń. W konfiguracji bazowej wszystkie zadania $J_1, \dots, J_{35}$ zostały poprawnie przypisane do jednostek UAV. Harmonogram bazowy przedstawiono na Rysunku 6.27.



Rysunek 6.27: Harmonogram bazowy operacji floty 7 UAV dla scenariusza 18

Tabela 6.28 przedstawia zestawienie dostępności czasowej poszczególnych korytarzy wraz z przypisanymi zadaniami. Dane te opisują bazową trajektorię przejść w przestrzeni stanów i stanowią punkt odniesienia dla analizy procesu rekonfiguracji po wystąpieniu zakłócenia.


Tabela 6.28: Dostępność czasowa korytarzy oraz przypisane zadania dla scenariusza 18

Korytarz	Czas korytarza (HH:MM:SS)		Harmonogram wykonywanych zadań przez UAV
	dostępny	niedostępny	
1	04:12:11	03:47:49	J2UAV7, J3UAV1, J7UAV2, J9UAV3, J13UAV6, J14UAV4
2	04:36:30	03:23:30	J6UAV7, J17UAV1, J22UAV2, J26UAV3, J30UAV4, J35UAV5
3	04:37:33	03:22:27	J1UAV7, J12UAV1, J21UAV2, J27UAV3, J32UAV6, J34UAV5
4	04:03:31	03:56:29	J10UAV7, J11UAV1, J18UAV2, J25UAV3, J33UAV4
5	04:21:28	03:38:32	J8UAV7, J15UAV1, J16UAV2, J20UAV3, J23UAV4, J28UAV6
6	04:38:50	03:21:10	J4UAV1, J5UAV2, J19UAV3, J24UAV4, J29UAV5, J31UAV6

W przedziale czasu $t \in [10:15:50, 12:54:48]$ zasymulowano równoczesne awarie UAV6, UAV4 oraz UAV3. Zdarzenia te spowodowały czasowe ograniczenie dostępnych zasobów systemu oraz zmianę struktury stanu procesu. Bezpośrednio zakłócone zostały zadania J9, J20, J24 oraz J27, które w harmonogramie bazowym były przypisane do uszkodzonych jednostek.


Po wykryciu zakłócenia model ALMM-D uruchomił procedurę rekonfiguracji przyszłego segmentu trajektorii. Zadania kolidujące z awariami zostały ponownie osadzone w dostępnych slotach czasowych i przy-

pisane do sprawnych jednostek UAV. Wynikowy harmonogram po reoptymalizacji przedstawiono na Rysunku 6.28.



Rysunek 6.28: Harmonogram po wystąpieniu awarii trzech jednostek UAV

Porównanie harmonogramu bazowego oraz harmonogramu po rekonfiguracji przedstawiono na Rysunku 6.29. Elementy oznaczone jako Jx (pre) wskazują pierwotne pozycje zadań przed reoptymalizacją, natomiast obszary oznaczone jako AWARIA reprezentują przedziały czasowej niedostępności wybranych UAV.



Rysunek 6.29: Porównanie harmonogramu przed i po wystąpieniu awarii – Scenariusz 18

Tabela 6.29 przedstawia zmiany w przypisaniu zadań do poszczególnych UAV przed oraz po wystąpieniu zakłócenia.

Tabela 6.29: Zmiany w przypisaniu zadań do UAV przed i po awarii – Scenariusz 18

UAV	Przypisane zadania	
	Przed awarią	Po awarii
UAV1	J4, J17, J3, J12, J15, J11	J4, J17, J3, J12, J15, J11
UAV2	J5, J22, J7, J21, J16, J18	J5, J22, J7, J21, J16, J18
UAV3	J19, J26, J9, J27, J20, J25	J19, J26, J9, J23, J33
UAV4	J24, J30, J14, J23, J33	J30, J14, J34
UAV5	J29, J35, J34	J29, J35, J32, J28
UAV6	J31, J13, J32, J28	J31, J13, J27, J20, J25
UAV7	J6, J2, J1, J8, J10	J6, J2, J1, J8, J10, J24


Analiza wyników wskazuje, że spośród 35 zaplanowanych zadań 25 zachowało pierwotne przypisanie, natomiast 10 zostało przesuniętych w czasie lub przealokowanych do innych jednostek. W odróżnieniu od scenariuszy 9 i 11, w tym przypadku wszystkie zadania zostały ponownie osadzone w harmonogramie. Ostatecznie uzyskano $\mathcal{T}_d = 35$ trajektorii dopuszczalnych oraz $\mathcal{T}_{nd} = 0$ trajektorii niedopuszczalnych.

Uzyskane rezultaty potwierdzają skalowalność i odporność modelu ALMM-D w warunkach równoczesnej utraty kilku zasobów systemu. Pomimo awarii trzech UAV algorytm zachował ciągłość procesu decyzyjnego, ograniczył zakres zmian do niezbędnego segmentu przyszłego oraz wygenerował nową trajektorię dopuszczalną bez utraty zadań. Scenariusz 18 potwierdza, że zwiększenie liczebności floty zwiększa redundancję zasobową systemu, a tym samym poprawia zdolność modelu ALMM-D do generowania trajektorii dopuszczalnych w warunkach wielokrotnych zakłóceń zasobowych.

Przykład 5. Rekonfiguracja harmonogramu po anulowaniu zadań


W piątym eksperymencie przeanalizowano zakłócenie zadaniowe polegające na zmianie mocy zbioru zadań J . W odróżnieniu od wcześniejszych przykładów, w których zakłócenia dotyczyły czasowej niedostępności jednostek UAV, w tym przypadku zmianie ulegał strumień zadań wejściowych. Rozpatrywana flota składała się z 6 UAV operujących w horyzoncie czasowym 08:00–16:00 w sześciu korytarzach powietrznych. Średnia dostępność korytarzy wyniosła 55.15%, przy niedostępności na poziomie 44.85%. Najwyższą dostępność odnotowano dla korytarza C_6 , dla którego wyniosła ona 61.51%.

Początkowy zbiór zadań miał licznosc $|J| = 32$. Na podstawie modelu ALMM-D wyznaczono harmonogram bazowy, w którym wszystkie zadania zostały poprawnie przypisane do jednostek UAV, co oznacza osiągnięcie stanu docelowego $S_G = 32$. Harmonogram bazowy przedstawiono na Rysunku 6.30. Rysunek obejmuje dostępność korytarzy, harmonogram realizacji zadań w korytarzach oraz harmonogram zadań przypisanych do poszczególnych UAV.



Rysunek 6.30: Harmonogram bazowy operacji floty UAV przed anulowaniem zadań

W chwili $t = 08:35:59$ do systemu napłynęła informacja o anulowaniu dwóch zadań: $J_{\text{cancel}} = \{J_7, J_{12}\}$. Zdarzenie to spowodowało zmianę mocy zbioru zadań z $|J| = 32$ do $|J'| = 30$. W harmonogramie bazowym zadania J_7 oraz J_{12} były przypisane odpowiednio do UAV6 oraz UAV2 i realizowane w korytarzu C_2 . Anulowanie zadań zmienia strukturę przestrzeni decyzji dopuszczalnych $U_p(s)$, ponieważ usuwa część operacji z przyszłego segmentu trajektorii oraz zwalnia odpowiadające im sloty czasowe. Po aktualizacji stanu model ALMM-D uruchamia procedurę realokacji dynamicznej, której celem jest kompaktacja harmonogramu oraz ponowne uporządkowanie aktywnych zadań względem zaktualizowanego zbioru J' . Po reoptymalizacji uzyskano trajektorię spełniającą ograniczenia slotów czasowych i separacji. Bilans zmian względem harmonogramu bazowego był następujący: $\text{removed} = 2, \text{moved} = 21, \text{same} = 9, \text{added} = 0$. Oznacza to, że dwa zadania zostały usunięte, 21 zadań zmieniło położenie w harmonogramie, 9 zadań zachowało pierwotne przypisanie, a do systemu nie dodano nowych zadań. Porównanie harmonogramu bazowego oraz harmonogramu po anulowaniu zadań przedstawiono na Rysunku 6.31. Elementy oznaczone jako $Jx(\text{pre})$ wskazują pierwotne pozycje zadań przed reoptymalizacją, natomiast czerwone ramki $Jx(\text{cancelled})$ oznaczają zadania wyłączone ze zbioru J , tj. J_7 oraz J_{12} .



Rysunek 6.31: Porównanie harmonogramu przed i po anulowaniu zadań

Tabela 6.31 przedstawia zmiany w przypisaniu zadań do poszczególnych UAV przed oraz po zmianie mocy zbioru zadań.

Tabela 6.31: Zmiany w przypisaniu zadań do UAV przed i po anulowaniu zadań

UAV	Przypisane zadania	
	Harmonogram bazowy	Po zmianie mocy zbioru
UAV1	J3, J9, J23, J16, J24, J13	J3, J9, J19, J11, J21, J10
UAV2	J8, J12, J26, J20, J30, J25	J8, J18, J31, J32, J25
UAV3	J17, J15, J29, J22, J14	J17, J26, J20, J30, J28
UAV4	J27, J18, J31, J32, J28	J27, J29, J22, J14
UAV5	J5, J4, J2, J6, J1	J5, J4, J2, J6, J1
UAV6	J7, J19, J11, J21, J10	J15, J23, J16, J24, J13

Analizowany przykład potwierdza, że model ALMM-D umożliwia obsługę zakłóceń zadaniowych wynikających ze zmiany mocy zbioru J . Po anulowaniu zadań J_7 oraz J_{12} system wygenerował nową trajektorię dopuszczalną dla zaktualizowanego zbioru J' , zachowując ograniczenia slotów czasowych i separacji. Ostatecznie uzyskano $\mathcal{T}_d = 30$ oraz $\mathcal{T}_{nd} = 0$.


Wyniki wskazują, że procedura realokacji dynamicznej nie ogranicza się wyłącznie do reakcji na awarie zasobów, lecz pozwala również na stabilną rekonfigurację harmonogramu w przypadku zmian po stronie

strumienia zadań. Jest to istotne z punktu widzenia praktycznego zastosowania modelu, ponieważ w rzeczywistych warunkach operacyjnych anulowanie zadań może wynikać m.in. ze zmiany priorytetów misji, utraty aktualności celu lub zmiany warunków przestrzeni powietrznej.

Przykład 6. Rekonfiguracja harmonogramu po dopływie nowych zadań

W szóstym eksperymencie przeanalizowano zakłócenie zadaniowe polegające na zwiększeniu mocy zbioru zadań J wskutek pojawienia się nowych zadań w trakcie realizacji harmonogramu. Analogicznie jak w poprzednim przykładzie, analizowano sytuację dynamicznej zmiany strumienia wejściowego, jednak tym razem poprzez rozszerzenie zbioru zadań zamiast jego redukcji.


Rozpatrywana flota składała się z 6 UAV operujących w horyzoncie czasowym 08:00–16:00 w sześciu korytarzach powietrznych. Średnia dostępność korytarzy wyniosła 56.30%, przy czym dla wybranych korytarzy odnotowano odpowiednio: $C_6 = 58.87\%$ oraz $C_5 = 49.53\%$. Początkowy zbiór zadań miał licznosc $|J| = 30$, a wyznaczony harmonogram bazowy osiągnął pełny stan docelowy $S_G = 30$, co oznacza brak zadań nieprzydzielonych. Harmonogram bazowy przedstawiono na Rysunku 6.32.



Rysunek 6.32: Harmonogram bazowy operacji floty UAV przed dopływem nowych zadań

W chwili $t = 10:30:00$ do systemu napłynęły dwa nowe zadania: $J_{\text{new}} = \{J_{31}, J_{32}\}$, przy czym oba zadania przypisano do realizacji w korytarzu C_6 . Zdarzenie to zwiększyło moc zbioru zadań do $|J'| = 32$. Dopływ nowych zadań spowodował zmianę przestrzeni decyzji dopuszczalnych $U_p(s)$ oraz aktualizację ograniczeń czasowo-przestrzennych wynikających z zajętości slotów w korytarzach. W odpowiedzi model ALMM-D uruchomił procedurę realokacji dynamicznej, zachowując niezmienną część przeszłą trajektorii i przeplanując wyłącznie przyszły segment harmonogramu. W wyniku resekwencjonowania uzyskano

nową trajektorię spełniającą wszystkie ograniczenia slotów i separacji. Bilans zmian względem harmonogramu bazowego wyniósł: moved = 20, added = 2, removed = 0, same = 10. Oznacza to, że oba nowe zadania zostały poprawnie osadzone w harmonogramie, 20 istniejących zadań zmieniło pozycję czasową lub przydział, a 10 zadań zachowało swoje pierwotne przypisanie. Porównanie harmonogramu bazowego oraz harmonogramu po dopływie nowych zadań przedstawiono na Rysunku 6.33. Elementy oznaczone jako Jx (pre) wskazują pozycje zadań w trajektorii bazowej, natomiast oznaczenia Jx (new) identyfikują nowo dodane zadania J_{31} oraz J_{32} .



Rysunek 6.33: Porównanie harmonogramu przed i po dopływie nowych zadań

Tabela 6.33 przedstawia szczegółowe zmiany w przypisaniu zadań do poszczególnych UAV przed i po rekonfiguracji harmonogramu. Zadania dopływowe oznaczono pogrubieniem.

Tabela 6.33: Zmiany w przypisaniu zadań do UAV po dopływie nowych zadań

UAV	Przypisane zadania	
	Harmonogram bazowy	Po zmianie mocy zbioru
UAV1	J10, J11, J5, J8, J6, J12	J10, J11, J4, J3, J1, J2
UAV2	J18, J22, J13, J15, J7, J17	J18, J22, J5, J8, J6, J12
UAV3	J19, J25, J14, J29, J27	J19, J25, J13, J15, J7, J17
UAV4	J20, J30, J26, J28	J20, J30, J14, J16, J24, J23
UAV5	J21, J16, J24, J23	J21, J26, J28, J27
UAV6	J9, J4, J3, J1, J2	J9, J32 , J29, J31

Analizowany eksperyment potwierdza, że model ALMM-D umożliwia skuteczną rekonfigurację harmonogramu również w przypadku dynamicznego zwiększenia liczby zadań. Po rozszerzeniu zbioru zadań do $|J'| = 32$ system wygenerował nową trajektorię dopuszczalną bez naruszenia ograniczeń slotów czasowych i separacji, osiągając pełny stan docelowy $S_G = 32$.

Wyniki wskazują, że procedura realokacji dynamicznej pozwala nie tylko reagować na redukcję zbioru zadań, lecz również efektywnie integrować nowe zadania pojawiające się w trakcie realizacji misji. Jest to szczególnie istotne w środowiskach operacyjnych o wysokiej dynamice, w których nowe zlecenia mogą być generowane adaptacyjnie w odpowiedzi na bieżące potrzeby systemu logistycznego.

Przeprowadzone eksperymenty symulacyjne potwierdziły skuteczność modelu ALMM-D oraz zaproponowanego mechanizmu dynamicznej reoptymalizacji w warunkach występowania zakłóceń zasobowych i zadaniowych. We wszystkich analizowanych scenariuszach system zachowywał zdolność do rekonfiguracji harmonogramu poprzez lokalną modyfikację przyszłego segmentu trajektorii, przy jednoczesnym zachowaniu niezmienności części już zrealizowanej.

W przypadku zakłóceń zasobowych związanych z czasową niedostępnością jednostek UAV wykazano, że model umożliwia automatyczne wykrycie stanów niedopuszczalnych S_N , identyfikację zadań kolidujących z oknem awarii oraz ich ponowną alokację do dostępnych zasobów. Nawet w scenariuszach obejmujących równoczesną awarię trzech jednostek UAV system utrzymywał wysoką efektywność operacyjną, osiągając pełną lub niemal pełną realizację zbioru zadań. Przypadki wystąpienia stanów niedopuszczalnych były związane wyłącznie z obiektywnym brakiem dostępnych slotów czasowych w odpowiednich korytarzach, a nie z ograniczeniami algorytmu harmonogramowania.

W przypadku zakłóceń zadaniowych obejmujących zmianę mocy zbioru J poprzez anulowanie lub dopływ nowych zadań potwierdzono, że model ALMM-D umożliwia dynamiczną rekonfigurację harmonogramu przy zachowaniu spójności trajektorii oraz wszystkich ograniczeń czasowo-przestrzennych. Zarówno redukcja, jak i rozszerzenie zbioru zadań prowadziły do wygenerowania nowych trajektorii dopuszczalnych bez utraty stabilności procesu planowania.

Uzyskane wyniki wskazują, że zaproponowana metoda:

- zapewnia jednolity mechanizm obsługi różnych klas zakłóceń dynamicznych,
- ogranicza zakres rekonfiguracji do niezbędnego fragmentu przyszłej trajektorii,
- zachowuje pełną interpretowalność procesu decyzyjnego poprzez jednoznaczne odwzorowanie zmian stanów i decyzji sterujących,
- umożliwia skalowalne działanie dla rosnącej liczby UAV, zadań oraz poziomu złożoności zakłóceń.

Przedstawione właściwości zostały potwierdzone we wszystkich analizowanych klasach zakłóceń, obejmujących zarówno ograniczenia zasobowe, jak i zmiany strumienia zadań. Na podstawie przeprowadzonych eksperymentów można stwierdzić, że model ALMM-D spełnia założenia postawione w Rozdziale 5.7 i stanowi efektywne narzędzie do dynamicznego harmonogramowania misji logistycznych floty UAV w środowisku o niepewnej i zmiennej dostępności zasobów oraz zadań. Otrzymane rezultaty potwierdzają wysoką odporność opracowanej technologii na zakłócenia operacyjne oraz jej przydatność do zastosowań w rzeczywistych systemach autonomicznego planowania i zarządzania flotą UAV.

6.5 Walidacja eksperymentalna opracowanego systemu w warunkach zbliżonych do rzeczywistych

Celem badań przedstawionych w niniejszym podrozdziale była eksperymentalna walidacja opracowanego systemu inteligentnego harmonogramowania zadań logistycznych floty UAV poprzez jego implementację i testowanie w warunkach zbliżonych do rzeczywistych. W odróżnieniu od wcześniejszych eksperymentów symulacyjnych, skoncentrowanych na analizie właściwości algorytmicznych modelu, niniejsza część pracy obejmuje weryfikację możliwości przeniesienia wyników uzyskanych w środowisku symulacyjnym do rzeczywistego środowiska wykonawczego, z uwzględnieniem fizycznej floty UAV, infrastruktury komunikacyjnej oraz terenowej realizacji trajektorii lotów.

Eksperymenty przeprowadzono z wykorzystaniem dedykowanej floty UAV oraz aparatury umożliwiającej komunikację z wykorzystaniem protokołów MAVLink/UDP. Weryfikacji podlegała zgodność pomiędzy harmonogramem wygenerowanym przez opracowany system, trajektoriami przypisanymi do poszczególnych UAV oraz rzeczywistym przebiegiem realizacji zadań w środowisku SIL/HIL i podczas lotów terenowych. Na Rysunku 6.34 przedstawiono modele UAV wykorzystane w badaniach.



Rysunek 6.34: Wykorzystywane rzeczywiste modele UAV

Za kryterium poprawności walidacji przyjęto zgodność pomiędzy harmonogramem planowanym a rzeczywistą realizacją misji w zakresie:

- zachowania kolejności realizacji zadań przez poszczególne UAV,
- poprawności odwzorowania trajektorii przestrzennych,
- zachowania ograniczeń separacji czasowej pomiędzy operacjami,
- zgodności czasów realizacji z dopuszczalną tolerancją operacyjną wynikającą z charakterystyki wykonawczej platform UAV.

Pierwszy etap walidacji obejmował realizację scenariuszy referencyjnych bez występowania zakłóceń operacyjnych, dla których wygenerowane przez opracowany system harmonogramy i trajektorie zostały zaimplementowane w środowisku rzeczywistym. Loty wykonano z użyciem dedykowanej floty UAV na lotnisku polowym w Sędziszowie Małopolskim. W celu zapewnienia odpowiednich warunków bezpieczeństwa wszystkie eksperymenty przeprowadzono zgodnie z obowiązującymi regulacjami Urzędu Lotnictwa Cywilnego, przy udziale licencjonowanych operatorów systemów bezzałogowych statków powietrznych.

Na Rysunku 6.35 przedstawiono obszar realizacji lotów testowych wraz z rozmieszczeniem floty UAV (L1–L6) oraz zdefiniowanych punktów węzłowych grafu destynacji (A–K). Przyjęty graf destynacji modelowany jest jako graf nieskierowany i ważony, w którym każdy punkt węzłowy posiada połączenie z bazą UAV oraz wybranymi punktami sąsiednimi.



Rysunek 6.35: Oznaczenie i usytuowanie UAV oraz punktów węzłowych na obszarze wykonywania lotów testowych

Dla zdefiniowanego grafu destynacji wygenerowano zestaw zadań testowych uwzględniających ograniczenia lokalizacji punktów węzłowych, czasy przelotu pomiędzy destynacjami oraz ograniczenia czasowe realizacji zadań. Fragment wygenerowanego zbioru zadań przedstawiono w Tabeli 6.35, gdzie oznaczenie *UAV Base* odpowiada punktowi startu i lądowania UAV.

Tabela 6.35: Przykładowy zbiór zadań testowych wykorzystywanych podczas walidacji terenowej

Nr zadania	Klasa trajektorii lotów	Zadanie do zrealizowania
J1	Jednoetapowa	UAV Base $\rightarrow$ A $\rightarrow$ UAV Base
J2	Wieloetapowa	UAV Base $\rightarrow$ E $\rightarrow$ D $\rightarrow$ F $\rightarrow$ UAV Base
J3	Jednoetapowa	UAV Base $\rightarrow$ B $\rightarrow$ UAV Base
J4	Wieloetapowa	UAV Base $\rightarrow$ D $\rightarrow$ B $\rightarrow$ A $\rightarrow$ UAV Base
J5	Wieloetapowa	UAV Base $\rightarrow$ A $\rightarrow$ B $\rightarrow$ C $\rightarrow$ UAV Base
J6	Wieloetapowa	UAV Base $\rightarrow$ E $\rightarrow$ F $\rightarrow$ E $\rightarrow$ UAV Base
J7	Wieloetapowa	UAV Base $\rightarrow$ F $\rightarrow$ E $\rightarrow$ C $\rightarrow$ D $\rightarrow$ UAV Base
J8	Wieloetapowa	UAV Base $\rightarrow$ E $\rightarrow$ C $\rightarrow$ A $\rightarrow$ UAV Base
J9	Wieloetapowa	UAV Base $\rightarrow$ B $\rightarrow$ E $\rightarrow$ H $\rightarrow$ UAV Base
J10	Wieloetapowa	UAV Base $\rightarrow$ D $\rightarrow$ I $\rightarrow$ UAV Base
J11	Jednoetapowa	UAV Base $\rightarrow$ A $\rightarrow$ UAV Base
J12	Wieloetapowa	UAV Base $\rightarrow$ C $\rightarrow$ G $\rightarrow$ J $\rightarrow$ UAV Base
J13	Wieloetapowa	UAV Base $\rightarrow$ C $\rightarrow$ F $\rightarrow$ J $\rightarrow$ UAV Base
J14	Wieloetapowa	UAV Base $\rightarrow$ K $\rightarrow$ B $\rightarrow$ UAV Base
J15	Wieloetapowa	UAV Base $\rightarrow$ A $\rightarrow$ C $\rightarrow$ F $\rightarrow$ UAV Base
J16	Wieloetapowa	UAV Base $\rightarrow$ B $\rightarrow$ D $\rightarrow$ G $\rightarrow$ J $\rightarrow$ UAV Base
J17	Wieloetapowa	UAV Base $\rightarrow$ F $\rightarrow$ H $\rightarrow$ UAV Base
J18	Wieloetapowa	UAV Base $\rightarrow$ B $\rightarrow$ I $\rightarrow$ UAV Base
J19	Jednoetapowa	UAV Base $\rightarrow$ B $\rightarrow$ UAV Base
J20	Wieloetapowa	UAV Base $\rightarrow$ E $\rightarrow$ G $\rightarrow$ UAV Base

W wyniku działania algorytmu harmonogramowania dla zdefiniowanego zbioru destynacji wyznaczono zestaw misji przypisanych do poszczególnych UAV. Szczegółowe przypisania przedstawiono w Tabeli 6.36. Tabela prezentuje numer misji, numer przypisanego UAV oraz odpowiadającą sekwencję punktów przelotowych składających się na realizowaną misję.

Tabela 6.36: Przypisanie wybranych trajektorii do jednostek UAV


Nr misji	UAV	Realizowane zadanie
1	1	UAV Base $\rightarrow$ A $\rightarrow$ UAV Base

ciąg dalszy na następnej stronie


Tabela 6.36 (cd.)

Nr trajektorii	UAV	Realizowane zadanie
2	2	UAV Base $\rightarrow$ C $\rightarrow$ G $\rightarrow$ J $\rightarrow$ UAV Base
3	3	UAV Base $\rightarrow$ B $\rightarrow$ E $\rightarrow$ H $\rightarrow$ UAV Base
4	4	UAV Base $\rightarrow$ D $\rightarrow$ I $\rightarrow$ UAV Base
5	1	UAV Base $\rightarrow$ C $\rightarrow$ F $\rightarrow$ J $\rightarrow$ UAV Base
6	4	UAV Base $\rightarrow$ K $\rightarrow$ B $\rightarrow$ UAV Base
7	3	UAV Base $\rightarrow$ A $\rightarrow$ C $\rightarrow$ F $\rightarrow$ UAV Base
8	1	UAV Base $\rightarrow$ B $\rightarrow$ UAV Base

Na Rysunku 6.36 przedstawiono reprezentatywne trajektorie przestrzenne wybranych misji odwzorowane w układzie 3D na tle mapy satelitarnej. Widoki ilustrują zróżnicowanie topologii tras, poziom złożoności misji oraz strukturę przelotów realizowanych przez poszczególne UAV.



(a)




(b)



(c)

Rysunek 6.36: Przykładowe trajektorie przestrzenne realizowanych misji UAV

Zaprojektowane scenariusze realizowano następnie w środowisku SIL/HIL z wykorzystaniem naziemnych stacji kontroli RPAS. Wybrane widoki z poszczególnych etapów realizacji zadań przedstawiono na Rysunku 6.37. Zaprezentowano na nich pozycje UAV, trajektorie lotów oraz podstawowe parametry telemetryczne.



(a)

(b)




(c)


(d)

Rysunek 6.37: Widoki ze stacji RPAS podczas realizacji wybranych etapów misji


Dla misji przedstawionych w Tabeli 6.36 wygenerowano odpowiadające im przestrzenne trajektorie lotów w środowisku wykonawczym. Otrzymane odwzorowanie tras przedstawiono na Rysunku 6.38.




(a) T1




(b) T2




(c) T3




(d) T4




(e) T5



(f) T6



(g) T7



(h) T8

Rysunek 6.38: Wynikowe trajektorie lotów realizowanych zdań z Tabeli 6.36 (T - trajektoria)

Wybrane ujęcia z przeprowadzonych lotów rzeczywistych przedstawiono na Rysunku 6.39.



(a)



(b)

Rysunek 6.39: Wybrane ujęcia z przeprowadzonych lotów rzeczywistych

Należy podkreślić, że w trakcie eksperymentów rzeczywistych obserwowano niewielkie odchylenia pomiędzy trajektoriami planowanymi a realizowanymi, wynikające z fizycznych ograniczeń platform UAV, dokładności pozycjonowania GNSS, opóźnień transmisji telemetry oraz wpływu lokalnych warunków atmosferycznych. Odchylenia te mieściły się jednak w dopuszczalnych granicach operacyjnych i nie wpływały na naruszenie poprawności logicznej wygenerowanego harmonogramu ani na kolejność realizacji zadań.

Przeprowadzona walidacja wykazała, że wszystkie wygenerowane trajektorie mogły zostać poprawnie odwzorowane w środowisku wykonawczym, a system zachował zgodność pomiędzy harmonogramem planowanym a rzeczywistym przebiegiem realizacji misji. Potwierdzono również poprawność działania warstwy komunikacyjnej odpowiedzialnej za transmisję planów lotów do jednostek UAV oraz ich wykonanie przez środowisko sterowania RPAS.

Podsumowując, przeprowadzone eksperymenty potwierdziły możliwość praktycznej implementacji opracowanego systemu harmonogramowania w środowisku rzeczywistym oraz wykazały wykonalność generowanych harmonogramów i trajektorii w warunkach terenowych. Uzyskane rezultaty stanowią potwier-

dzenie poprawności implementacyjnej opracowanego modelu, zgodności pomiędzy warstwą planistyczną i wykonawczą systemu oraz jego potencjału aplikacyjnego w rzeczywistych systemach logistycznych wykorzystujących flotę bezzałogowych statków powietrznych.

6.6 Analiza porównawcza otrzymanych rezultatów z innymi podejściami

W celu określenia pozycji opracowanego podejścia ALMM na tle współczesnych metod rozwiązywania problemów harmonogramowania flot UAV przeprowadzono syntetyczną analizę porównawczą względem reprezentatywnych podejść raportowanych w literaturze. Uwzględniono zarówno klasyczne metody heurystyczne i programistyczne (VNS, CP, MILP), jak również nowsze rozwiązania hybrydowe oraz modele robust/stochastic.

Należy podkreślić, że przedstawione zestawienie ma charakter **meta-analityczny i jakościowo-porównawczy**, ponieważ porównywane wyniki pochodzą z odrębnych prac literaturowych realizowanych dla różnych instancji problemowych, konfiguracji flot, założeń modelowych oraz środowisk obliczeniowych. Tym samym analiza nie stanowi bezpośredniego benchmarku eksperymentalnego, lecz umożliwia określenie relatywnej pozycji proponowanego podejścia względem głównych klas metod stosowanych w literaturze.

Tabela 1.1 w Rozdziale 1.1 zestawia charakterystyki głównych podejść do problemów PDSTSP, obejmując konfiguracje flot operacyjnych, rodzaj niepewności oraz stosowane metody obliczeniowe. W niniejszym rozdziale zestawienie to rozszerzono o syntetyczne wskaźniki efektywności, odporności oraz kosztu obliczeniowego, pozwalające na jakościową ocenę kompromisu pomiędzy efektywnością, odpornością i reaktywnością poszczególnych podejść. Wyniki zestawiono w Tabeli 6.37.

W analizie wykorzystano następujące miary:

- ΔMS [%] – względna zmiana całkowitego czasu realizacji harmonogramu (makespan) względem rozwiązania referencyjnego:

$$\Delta MS = \frac{MS_{\text{ref}} - MS_{\text{model}}}{MS_{\text{ref}}} \times 100\% \quad (6.1)$$

Dodatnie wartości oznaczają poprawę efektywności względem wariantu bazowego, natomiast wartości ujemne odpowiadają wzrostowi czasu realizacji. Dla podejścia ALMM jako rozwiązanie referencyjne przyjęto harmonogram bazowy generowany bez zastosowania mechanizmów adaptacyjnej rekonfiguracji i optymalizacji dynamicznej.

- ROB – raportowana w literaturze miara odporności / stabilności procesu. Ze względu na brak jednolitego standardu raportowania odporności w analizowanych pracach wartości te odnoszą się do różnych aspektów jakości procesu harmonogramowania (np. redukcji opóźnień, wariancji, kosztu, braków lub nierównomierności procesu) i nie są bezpośrednio porównywalne numerycznie.

Dla podejścia ALMM zastosowano autorską metrykę stanową:

$$ROB_{ALMM} = \frac{|S_G|}{|S_G| + |S_N|} \quad (6.2)$$

gdzie: $|S_G|$ oznacza liczbę stanów docelowych, natomiast $|S_N|$ liczbę stanów niedopuszczalnych.



- $T_{\text{comp}} [s]$ – raportowany czas obliczeń/off-line.
- $T_{\text{react}} [s]$ – raportowany czas reakcji/reoptymalizacji on-line.

W przypadku metod typu robust/stochastic obserwowany wzrost czasu realizacji lub kosztu interpretowany jest jako tzw. *robustness tax*, tj. koszt uzyskania zwiększonej odporności rozwiązania.

Tabela 6.37: Syntetyczne zestawienie charakterystyk efektywnościowych wybranych klas podejść literaturowych oraz technologii ALMM

Praca	Typ podejścia	ΔMS (%)	Raportowana miara odporności / stabilności procesu	T (s) (comp/react)
Nguyen et al. (2022) [57]	Metaheurystyka (GRASP+VNS)	12–18	–	10–120
Saleu et al. (2022) [54]	Metaheurystyka (GRASP+ILS)	18–24	+30% wykorzystania UAV	30–180
Lei and Chen (2022) [44]	Metaheurystyka (VNS improved)	12–22	–	1–30
Montemanni et al. (2023) [55]	Programowanie z ograniczeniami (CP)	~ 18	–	≤ 30
Nguyen and Ha (2023) [58]	MILP + heurystyka	20–27	–15% energii	≤ 60
Pina-Pardo et al. (2024) [63]	Metaheurystyka hybrydowa	18–22	–15% kosztu	20–240
Zhao et al. (2022b) [95]	Robust MILP	–6 do –9	–30% wariacji	60–300
Bruni et al. (2023) [8]	Stochastic MILP	–6	–22–28% opóźnień	20–90
Yin et al. (2023) [89]	Two-stage robust	–7 do –10	–35–50% braków	60–180
Yang et al. (2023) [87]	Robust B&P&C	–6 do –10	–25% opóźnień	5–100
Wang et al. (2023) [76]	Two-stage robust + Benders	–5 do –8	–40% nierównomierności	60–240
Barzanjeh et al. (2025) [7]	LBBD (robust)	12–18	+28–35% robust.	30–240
ALMM (proponowana)	Sterowanie algebraiczno-logiczne on-line	10–15	94–100 %	1–2 / 1–2

Na Rysunkach 6.40 oraz 6.41 przedstawiono graficzną agregację raportowanych wartości ΔMS dla analizowanych podejść. Zestawienie umożliwia wizualną ocenę relatywnej pozycji podejścia ALMM względem dominujących klas metod stosowanych w literaturze.

Rysunek 6.40: Porównanie wartości ΔMS dla wybranych metod literaturowych oraz technologii ALMMRysunek 6.41: Średnie wartości ΔMS dla głównych klas metod

Analiza wyników zestawionych w Tabeli 6.37 oraz na Rysunkach 6.40–6.41 wskazuje, że proponowane podejście ALMM osiąga poziom redukcji makespanu porównywalny z klasycznymi metodami metaheury-

stycznymi oraz wybranymi podejściami hybrydowymi, przy jednoczesnym zachowaniu istotnie krótszego czasu generacji harmonogramu oraz czasu reakcji na zakłócenia.

W przeciwieństwie do metod robust/stochastic, które osiągają zwiększoną odporność kosztem wzrostu czasu realizacji (*robustness tax*), podejście ALMM implementuje odporność w sposób reaktywny, tj. poprzez dynamiczną rekonfigurację trajektorii procesu po ujawnieniu zakłócenia, zamiast stosowania odporności predykcyjnej opartej na nadmiarowych buforach lub scenariuszach robust. W badanych scenariuszach pozwoliło to uzyskać pełną lub niemal pełną realizację zbioru stanów docelowych przy zachowaniu wartości $ROB_{ALMM} = 94\text{--}100\%$.

Dodatkową właściwością proponowanego podejścia jest pełna interpretowalność procesu decyzyjnego. Dzięki algebraiczno-logicznej reprezentacji sterowania możliwe jest śledzenie sekwencji przejść stanów oraz analiza operacji moved/added/removed, co zapewnia pełną audytowalność procesu harmonogramowania.

Należy jednocześnie podkreślić, że przedstawione wartości czasów obliczeń dla metod literaturowych należy interpretować orientacyjnie, ponieważ pochodzą one z odmiennych środowisk sprzętowych i implementacyjnych. Ich celem jest wskazanie rzędu wielkości kosztu obliczeniowego poszczególnych klas podejść, a nie bezpośrednie porównanie wydajności implementacyjnej.

Ze względu na brak jednolitego benchmarku eksperymentalnego obejmującego wszystkie analizowane klasy metod przedstawiona analiza ma charakter porównania pozycyjnego (*positioning analysis*), a nie ścisłej walidacji benchmarkowej. Mimo tego umożliwia ona ocenę relatywnych właściwości proponowanego podejścia na tle dominujących kierunków badawczych w literaturze.

Podsumowując, przeprowadzona analiza wskazuje, że podejście ALMM lokuje się konkurencyjnie na froncie kompromisu *efektywność–odporność–reaktywność*, łącząc:

- efektywność czasową porównywalną z metodami metaheurystycznymi,
- wysoką odporność procesu bez konieczności modelowania scenariuszy niepewności ex-ante,
- minimalny koszt reoptymalizacji umożliwiający pracę w trybie on-line,
- pełną interpretowalność procesu decyzyjnego.

Uzyskane rezultaty potwierdzają, że proponowane podejście stanowi efektywne i praktycznie użyteczne narzędzie do dynamicznego harmonogramowania zadań flot UAV w środowiskach charakteryzujących się zmienną dostępnością zasobów oraz występowaniem zakłóceń operacyjnych.

Rozdział 7

Podsumowanie

Synteza przeprowadzonych badań

Celem niniejszej rozprawy było opracowanie modelu oraz metod harmonogramowania zadań logistycznych dla floty UAV, działającej w warunkach dynamicznie zmieniającej się dostępności przestrzeni powietrznej. Przyjęte podejście oparto na technologii algebraiczno-logicznego meta-modelowania, która umożliwia opis procesu harmonogramowania jako wieloetapowego procesu decyzyjnego z jawnie określoną przestrzenią stanów, decyzji, funkcją przejścia oraz zbiorami stanów niedopuszczalnych i docelowych.

Przeprowadzone badania objęły pełny cykl opracowania rozwiązania: od analizy problemu zarządzania flotą UAV w obszarze okołolotniskowym, stanowiącym środowisko operacyjne o podwyższonym poziomie ograniczeń wynikających z czasowej i przestrzennej dostępności korytarzy lotniczych, poprzez formalizację modeli ALMM, ALMM-TS, ALMM-CS, ALMM-TW i ALMM-D, aż do opracowania algorytmów harmonogramowania, dynamicznej realokacji oraz walidacji eksperymentalnej. Taka struktura badań pozwoliła na stopniowe przejście od opisu formalnego do implementacji procedur decyzyjnych i oceny ich skuteczności w scenariuszach symulacyjnych oraz warunkach zbliżonych do rzeczywistych. Uzyskane wyniki potwierdzają, że opracowane podejście algebraiczno-logiczne umożliwia wyznaczanie rozwiązań dopuszczalnych i efektywnych w warunkach ograniczeń czasowo-przestrzennych, zmiennej dostępności zasobów oraz występowania zakłóceń operacyjnych.

Realizacja celów pracy

Celem głównym rozprawy było opracowanie modelu oraz metod harmonogramowania zadań logistycznych dla floty UAV działającej w warunkach dynamicznie zmieniającej się dostępności przestrzeni powietrznej. Realizacja tego celu została osiągnięta poprzez wykonanie czterech komplementarnych zadań badawczych odpowiadających przyjętym celom szczegółowym.

W ramach pierwszego celu opracowano formalny model harmonogramowania zadań UAV oparty na strukturze algebraiczno-logicznego procesu decyzyjnego $P = (U, S, s_0, f, S_N, S_G)$, a następnie kaskadę jego rozszerzeń umożliwiających modelowanie kolejnych klas ograniczeń operacyjnych. Opracowane modele ALMM, ALMM-TS, ALMM-CS, ALMM-TW oraz ALMM-D umożliwiają reprezentację zadań, zasobów UAV, slotów czasowych, korytarzy powietrznych, okien czasowych oraz zakłóceń operacyjnych w ramach jednolitej przestrzeni stanów i decyzji.

W ramach drugiego celu opracowano metody rekonfiguracji trajektorii procesu decyzyjnego w warunkach występowania zakłóceń operacyjnych. Szczególny nacisk położono na mechanizmy adaptacyjnej reoptymalizacji umożliwiające dynamiczną aktualizację harmonogramu przy zachowaniu dopuszczalności procesu, ciągłości realizacji misji oraz ograniczeniu zakresu zmian do niezbędnego fragmentu przyszłej trajektorii.

Realizacja trzeciego celu obejmowała opracowanie i implementację procedur algorytmicznych realizujących operacje definiowane w modelach algebraiczno-logicznych. Opracowano zestaw algorytmów obejmujących redukcję przestrzeni decyzyjnej, przydział zadań do slotów czasowych, generowanie trajektorii lotu oraz dynamiczną realokację zadań w odpowiedzi na zakłócenia.

W ramach czwartego celu przeprowadzono walidację eksperymentalną opracowanego podejścia z wykorzystaniem scenariuszy symulacyjnych oraz środowiska badawczego odwzorowującego rzeczywiste ograniczenia operacyjne przestrzeni powietrznej. Uzyskane wyniki potwierdziły poprawność formalną opracowanych modeli, skuteczność zaproponowanych algorytmów oraz praktyczną wykonalność opracowanego podejścia w warunkach występowania ograniczeń czasowo-przestrzennych i zakłóceń operacyjnych.

Tym samym wszystkie przyjęte cele szczegółowe zostały zrealizowane, a osiągnięte rezultaty doprowadziły do opracowania spójnego formalizmu, kaskady modeli oraz procedur algorytmicznych umożliwiających harmonogramowanie i dynamiczną rekonfigurację zadań flot UAV w warunkach ograniczonej dostępności przestrzeni powietrznej.

Potwierdzenie tezy badawczej

Na podstawie przeprowadzonych analiz formalnych, opracowanych modeli algebraiczno-logicznych, zaprojektowanych algorytmów harmonogramowania oraz wyników badań eksperymentalnych stwierdzono, że sformułowana w rozprawie teza badawcza została potwierdzona w zakresie przyjętych założeń modelowych oraz przeprowadzonych scenariuszy walidacyjnych.

Wykazano, że technologia algebraiczno-logicznego meta-modelowania umożliwia konstrukcję modeli harmonogramowania zadań dla flot UAV, które zachowują spójność formalną przy rozszerzaniu problemu o kolejne klasy ograniczeń operacyjnych, obejmujące dostępność slotów czasowych, współdzielenie korytarzy powietrznych, okna czasowe realizacji zadań oraz zakłócenia dynamiczne. Opracowana kaskada modeli ALMM, ALMM-TS, ALMM-CS, ALMM-TW oraz ALMM-D potwierdziła możliwość systematycznego rozwijania formalizmu przy zachowaniu jednolitej reprezentacji procesu decyzyjnego.

Wykazano ponadto, że zaproponowane podejście umożliwia adaptacyjną rekonfigurację procesu harmonogramowania poprzez aktualizację bieżącego stanu procesu, zbioru decyzji dopuszczalnych oraz parametrów funkcji przejścia, bez konieczności każdorazowej rekonstrukcji kompletnego modelu decyzyjnego. Właściwość ta stanowi kluczowy mechanizm umożliwiający zachowanie spójności procesu decyzyjnego w warunkach zmiennej dostępności zasobów, ograniczeń przestrzeni powietrznej oraz występowania zakłóceń operacyjnych.

Wyniki badań eksperymentalnych wykazały ponadto, że opracowane podejście umożliwia generowanie rozwiązań dopuszczalnych i efektywnych obliczeniowo przy zachowaniu odporności procesu harmonogramowania na zakłócenia zasobowe, czasowe, przestrzenne oraz zadaniowe. Potwierdzono zdolność systemu

do dynamicznej rekonfiguracji harmonogramu w odpowiedzi na awarie jednostek UAV, czasową niedostępność korytarzy powietrznych oraz zmiany zbioru realizowanych zadań, przy jednoczesnym zachowaniu ciągłości procesu realizacji misji.

Oznacza to, że **potwierdzono możliwość wykorzystania technologii algebraiczno-logicznego meta-modelowania jako jednolitej podstawy formalnej do budowy skalowalnych i adaptacyjnych metod harmonogramowania flot UAV, zdolnych do rekonfiguracji procesu decyzyjnego w odpowiedzi na zmiany warunków operacyjnych bez utraty jego dopuszczalności.**

W konsekwencji **przyjęte założenia tezy rozprawy znajdują potwierdzenie zarówno w warstwie formalnej, jak i eksperymentalnej. Uzyskane wyniki dowodzą, że opracowane podejście stanowi skuteczne narzędzie harmonogramowania i dynamicznej rekonfiguracji zadań flot UAV działających w środowisku ograniczonej i zmiennej dostępności przestrzeni powietrznej.**

Oryginalne osiągnięcia naukowe autora pracy

Do najważniejszych oryginalnych osiągnięć naukowych niniejszej rozprawy należy zaliczyć:

- opracowanie algebraiczno-logicznego formalizmu harmonogramowania zadań logistycznych flot UAV działających w warunkach ograniczonej i zmiennej dostępności przestrzeni powietrznej,
- opracowanie kaskadowej struktury modeli ALMM, ALMM-TS, ALMM-CS, ALMM-TW oraz ALMM-D umożliwiającej systematyczne rozszerzanie problemu harmonogramowania o kolejne klasy ograniczeń operacyjnych przy zachowaniu spójności formalnej modelu,
- opracowanie jednolitej reprezentacji ograniczeń czasowych, przestrzennych, zasobowych i zadaniowych w ramach algebraiczno-logicznego procesu decyzyjnego,
- opracowanie mechanizmu dynamicznej rekonfiguracji trajektorii procesu decyzyjnego umożliwiającego adaptację harmonogramu do zmian warunków operacyjnych bez konieczności rekonstrukcji kompletnego modelu decyzyjnego,
- opracowanie zestawu procedur algorytmicznych realizujących harmonogramowanie, generowanie trajektorii oraz dynamiczną rekonfigurację procesu decyzyjnego w oparciu o formalizm ALMM,
- integrację warstwy modelowej i algorytmicznej w postaci spójnego podejścia do planowania i rekonfiguracji misji flot UAV funkcjonujących w środowisku występowania zakłóceń operacyjnych,
- eksperymentalne potwierdzenie skuteczności, odporności oraz skalowalności opracowanego podejścia w scenariuszach obejmujących ograniczenia czasowo-przestrzenne, awarie zasobów oraz dynamiczne zmiany zbioru realizowanych zadań.

Przedstawione osiągnięcia rozszerzają zakres zastosowań technologii algebraiczno-logicznego meta-modelowania o klasę problemów dynamicznego harmonogramowania flot UAV oraz stanowią wkład do

rozwoju metod adaptacyjnego planowania i rekonfiguracji procesów decyzyjnych w systemach autonomicznych. Opracowane rozwiązania tworzą spójne podstawy formalne i algorytmiczne umożliwiające harmonogramowanie oraz dynamiczną rekonfigurację misji UAV w warunkach niepewności i zmiennej dostępności zasobów operacyjnych.

Ograniczenia i kierunki dalszych badań

Pomimo potwierdzenia skuteczności opracowanego podejścia, przeprowadzone badania posiadają określony zakres obowiązywania wynikający z przyjętych założeń modelowych oraz charakteru środowiska eksperymentalnego. Przedstawione wyniki należy interpretować w kontekście rozpatrywanych konfiguracji flot UAV, analizowanych klas zakłóceń operacyjnych oraz przyjętych reprezentacji zasobów i ograniczeń czasowo-przestrzennych. Opracowane modele koncentrują się przede wszystkim na warstwie harmonogramowania i dopuszczalności procesu, nie obejmując pełnego modelowania dynamiki lotu, szczegółowych modeli energetycznych ani bezpośredniej integracji z rzeczywistymi systemami zarządzania ruchem lotniczym i bezzałogowym (ATM/UTM).

Dalsze badania powinny koncentrować się na rozszerzeniu opracowanego podejścia w kilku kluczowych kierunkach. Pierwszym z nich jest integracja modeli algebraiczno-logicznych z rzeczywistymi systemami zarządzania ruchem bezzałogowym i załogowym, co umożliwi wykorzystanie bieżących danych o dostępności przestrzeni powietrznej, ograniczeniach operacyjnych oraz sytuacji ruchowej. Drugim kierunkiem jest rozwój komponentów predykcyjnych wspierających wcześniejsze wykrywanie zakłóceń i prognozowanie zmian warunków operacyjnych.

Perspektywicznym obszarem dalszych prac pozostaje również rozszerzenie formalizmu o mechanizmy reprezentacji niepewności i probabilistycznego modelowania zdarzeń operacyjnych, umożliwiające uwzględnienie niepełnej informacji o przyszłych stanach systemu. Kierunek ten może stanowić naturalne połączenie opracowanego podejścia z metodami predykcyjnymi oraz technikami planowania odpornego na niepewność.

Istotnym kierunkiem dalszych badań jest także rozszerzenie modelu do pełnej reprezentacji trajektorii trójwymiarowych z uwzględnieniem separacji pionowej, przeszkód terenowych, warunków meteorologicznych oraz dynamicznych stref ograniczonego dostępu. Perspektywicznym obszarem rozwoju pozostaje również opracowanie rozproszonej wersji formalizmu umożliwiającej współdziałanie wielu agentów UAV w ramach wspólnej przestrzeni decyzyjnej.

Ze względu na ogólny charakter formalizmu algebraiczno-logicznego opracowane podejście może zostać zaadaptowane również do innych klas problemów optymalizacji dynamicznej, w szczególności w obszarach logistyki, transportu, zarządzania zasobami oraz systemów cyber-fizycznych. Wskazuje to na szeroki potencjał transferowy opracowanego rozwiązania oraz możliwość jego dalszego rozwoju jako uniwersalnego formalizmu modelowania i wspomagania decyzji w złożonych systemach dynamicznych o zmiennej dostępności zasobów.

Spis rysunków

2.1	Przykładowa trajektoria indywidualnego procesu P	15
2.2	Modułowa struktura ALMM Systemu	16
2.3	Struktura inteligentnego ALMM Sytemu [30]	17
2.4	Struktura Solving Module [30]	18
2.5	Architektura własności problemu II	21
2.6	Generowanie trajektorii dla kryterium separowalności	22
3.1	Schemat głównych modułów proponowanego systemu planowania zadań dla UAV	26
3.2	Graf destynacji lotniczych	29
3.3	Narzędzie wspomagające definiowanie grafów destynacji lotniczych wykorzystywanych w badaniach eksperymentalnych	30
3.4	Schemat zasobów wspólnych w rozważanym problemie	33
3.5	Schemat przydziału czasowego antysłota	34
3.6	Wizualizacja slotów wolnych i zajętych lipiec 2023	34
3.7	Wizualizacja slotów wolnych i zajętych listopad 2024	35
3.8	Czasy dostępności slotów w dniu 18.07.2023	37
3.9	Czasy dostępności slotów w dniu 22.11.2024	38
3.10	Narzędzie generowania instancji zadaniowych wykorzystywanych w badaniach eksperymentalnych	39
3.11	Przykładowe uzyskane wyniki dla funkcji sigmoidalnej	40
3.12	Przykładowe uzyskane wyniki dla funkcji Gaussa	40
3.13	Przykładowa przestrzeń trajektorii operacyjnych podlegających ograniczeniom przestrzennym	42
3.14	Schemat separowalności UAV	42
5.1	Etapy heurystyki redukcji przestrzeni decyzji z uwzględnieniem korytarzy powietrznych.	74
5.2	Zintegrowana struktura działania algorytmów harmonogramowania zadań UAV w systemie ALMM.	81
5.3	Schemat architektury systemu decyzyjnego ALMM-D dla harmonogramowania zadań UAV z predykcją zakłóceń i realokacją dynamiczną.	83
5.4	Graf destynacji lotniczej jako przykład struktury przestrzennej misji UAV.	85
5.5	Przykładowa strategia reakcji UAV na dynamicznie pojawiające się zakłócenie przestrzenne podczas realizacji przelotu między punktem startowym H a punktem docelowym B	85

5.6	Etapy modułu realokacji zadań UAV w modelu ALMM-D realizującego aktualizację trajektorii stanów i decyzji po wystąpieniu zakłócenia.	86
6.1	Schemat zaprojektowanego stanowiska badawczego	92
6.2	Dedykowane stanowiska badawcze do symulacji lotu UAV w trybach SIL oraz HIL	93
6.3	Zamodelowane bezzałogowe statki powietrzne: (a) wielowirnikowiec, (b) samolot	94
6.4	Schemat wymiany danych pomiędzy UAV a zaimplementowanym algorytmem w środowisku Matlab	95
6.5	Schemat rozmieszczenia destynacji lotniczych w analizowanym obszarze operacyjnym	97
6.6	Przykładowe przebiegi realizacji zadań i trajektorii lotu dla wybranych UAV	98
6.7	Przykładowa trajektoria 3D (a) oraz jej rzut pionowy (b) dla wybranego zadania	98
6.8	Przykład trajektorii przestrzennej (a) oraz rzut pionowy (b) dla zadania logistycznego	98
6.9	Rozkład wykonania kolejnych lotów przez flotę 6 UAV (a) najkrótszy i (b) najdłuższy czas	100
6.10	Rozkład wykonania kolejnych lotów przez flotę 6 UAV (a) najkrótszy i (b) najdłuższy czas	103
6.11	Rozkład wykonania kolejnych lotów przez flotę 7 UAV (a) najkrótszy i (b) najdłuższy czas	104
6.12	Rozkład wykonania kolejnych lotów przez flotę 9 UAV (a) najkrótszy i (b) najdłuższy czas	104
6.13	Schemat koincydencji dostępności korytarzy powietrznych	107
6.14	Harmonogram operacji UAV dla scenariusza 3: 6 UAV, 30 zadań	110
6.15	Harmonogram operacji UAV dla scenariusza 10: 6 UAV, 35 zadań	112
6.16	Harmonogram operacji UAV dla scenariusza 15: 7 UAV, 30 zadań	114
6.17	Harmonogram operacji UAV dla scenariusza 21: 9 UAV, 30 zadań	116
6.18	Harmonogram bazowy operacji floty UAV dla scenariusza 2	119
6.19	Harmonogram po wystąpieniu awarii UAV2	120
6.20	Porównanie harmonogramu przed i po wystąpieniu awarii UAV2	120
6.21	Harmonogram bazowy operacji floty UAV dla Scenariusza 9	122
6.22	Harmonogram po wystąpieniu awarii trzech jednostek UAV	123
6.23	Porównanie harmonogramu przed i po wystąpieniu awarii – scenariusz 9	123
6.24	Harmonogram bazowy operacji floty 6 UAV dla scenariusza 11	125
6.25	Harmonogram po wystąpieniu awarii trzech jednostek UAV	126
6.26	Porównanie harmonogramu przed i po wystąpieniu awarii – scenariusz 11	126
6.27	Harmonogram bazowy operacji floty 7 UAV dla scenariusza 18	128
6.28	Harmonogram po wystąpieniu awarii trzech jednostek UAV	129
6.29	Porównanie harmonogramu przed i po wystąpieniu awarii – Scenariusz 18	129
6.30	Harmonogram bazowy operacji floty UAV przed anulowaniem zadań	131
6.31	Porównanie harmonogramu przed i po anulowaniu zadań	132
6.32	Harmonogram bazowy operacji floty UAV przed dopływem nowych zadań	133
6.33	Porównanie harmonogramu przed i po dopływie nowych zadań	134
6.34	Wykorzystywane rzeczywiste modele UAV	136
6.35	Oznaczenie i usytuowanie UAV oraz punktów węzłowych na obszarze wykonywania lotów testowych	137

6.36	Przykładowe trajektorie przestrzenne realizowanych misji UAV	139
6.37	Widoki ze stacji RPAS podczas realizacji wybranych etapów misji	140
6.38	Wynikowe trajektorie lotów realizowanych zdań z Tabeli 6.36 (T - trajektoria)	141
6.39	Wybrane ujęcia z przeprowadzonych lotów rzeczywistych	142
6.40	Porównanie wartości ΔMS dla wybranych metod literaturowych oraz technologii ALMM .	145
6.41	Średnie wartości ΔMS dla głównych klas metod	145

Spis tabel

1.1	Reprezentatywne prace dotyczące harmonogramowania i trasowania UAV	5
3.1	Macierz sąsiedztwa rozważanego problemu	29
3.2	Trajektorie lotu dla rozważanych klas trajektorii	31
3.4	Parametry ruchu UAV wykorzystywane do estymacji czasu realizacji trajektorii	32
3.5	Charakterystyka dostępności slotów w wybranych dniach	36
6.1	Klasy trajektorii zadań	96
6.2	Czasy realizacji trajektorii dopuszczalnych $\tilde{s}^{(r)} \in \mathcal{T}_{ad}^D$ dla konfiguracji 20×6	99
6.3	Przydział zadań do UAV w kolejnych stanach trajektorii procesu $\tilde{s}$	100
6.4	Czasy realizacji harmonogramów dla konfiguracji 36×6	101
6.5	Przydzielone zadania dla floty UAV, decyzje $U_d(s_i)$	102
6.6	Wyniki eksploracji przestrzeni stanów procesu dla wybranych konfiguracji problemu	104
6.7	Wybrane scenariusze eksperymentalne z ograniczeniami czasowej dostępności korytarzy powietrznych	107
6.8	Grupowanie zadań według trajektorii misji dla Scenariusza 3	108
6.9	Czas dostępności korytarzy dla Scenariusza 3	109
6.10	Klasy trajektorii zadań dla Scenariusza 10	111
6.11	Czas dostępności korytarzy dla Scenariusza 10	111
6.13	Klasy trajektorii zadań dla Scenariusza 15	112
6.14	Czas dostępności korytarzy dla Scenariusza 15	113
6.15	Klasy trajektorii zadań dla Scenariusza 21	114
6.16	Czas dostępności korytarzy dla Scenariusza 21	115
6.18	Wybrane scenariusze wykorzystywane w eksperymentach z uwzględnieniem zakłóceń zasobowych	117
6.19	Dostępność czasowa korytarzy oraz przypisane zadania dla Scenariusza 2	119
6.20	Zmiany w alokacji zadań do UAV przed i po rekonfiguracji - Scenariusz 2	121
6.22	Dostępność czasowa korytarzy oraz przypisane zadania dla Scenariusza 9	122
6.23	Zmiany w przypisaniu zadań do UAV przed i po awarii – scenariusz 9	124
6.25	Dostępność czasowa korytarzy oraz przypisane zadania dla scenariusza 11	125
6.26	Zmiany w przypisaniu zadań do UAV przed i po awarii – scenariusz 11	127
6.28	Dostępność czasowa korytarzy oraz przypisane zadania dla scenariusza 18	128
6.29	Zmiany w przypisaniu zadań do UAV przed i po awarii – Scenariusz 18	130

6.31	Zmiany w przypisaniu zadań do UAV przed i po anulowaniu zadań	132
6.33	Zmiany w przypisaniu zadań do UAV po dopływie nowych zadań	135
6.35	Przykładowy zbiór zadań testowych wykorzystywanych podczas walidacji terenowej	138
6.36	Przypisanie wybranych trajektorii do jednostek UAV	138
6.37	Syntetyczne zestawienie charakterystyk efektywnościowych wybranych klas podejść litera- turalnych oraz technologii ALMM	144

Spis algorytmów

1	Fragment algorytmu tworzenia AL Modelu	20
2	Harmonogramowanie zadań UAV z uwzględnieniem ograniczeń korytarzy powietrznych . .	76
3	Algorytm przydziału zadań do slotów czasowych UAV	78
4	Algorytm generowania trajektorii lotu UAV	80
5	Zintegrowany algorytm obsługi zakłóceń w modelu ALMM-D	88
6	Algorytm dynamicznej realokacji zadań UAV	89

Bibliografia

- [1] Mohd Hirzi Adnan, Zuriati Ahmad Zukarnain, and Shamala K. Subramaniam. Efficient multi-uav coordination via rl: Joint path planning and task scheduling for post-disaster uav-assisted mec systems. *Computer Networks*, 274:111822, 2026.
- [2] M. Amine Masmoudi, Simona Mancini, Roberto Baldacci, and Yong-Hong Kuo. Vehicle routing problems with drones equipped with multi-package payload compartments. *Transportation Research Part E: Logistics and Transportation Review*, 164:102757, 2022.
- [3] Spyros Angelopoulos, Marcin Bienkowski, Christoph Dürr, and Bertrand Simon. Contract scheduling with distributional and multiple advice. In Kate Larson, editor, *Proceedings of the Thirty-Third International Joint Conference on Artificial Intelligence, IJCAI-24*, pages 3652–3660. International Joint Conferences on Artificial Intelligence Organization, 8 2024. Main Track.
- [4] EUROCONTROL Supporting European Aviation. Eurocontrol - supporting european aviation. <https://www.eurocontrol.int/>. Ostatni dostęp: 24.02.2026r.
- [5] Uchechukwu Awada, Jiankang Zhang, Sheng Chen, Shuangzhi Li, and Shouyi Yang. Edgedrones: Co-scheduling of drones for multi-location aerial computing missions. *Journal of Network and Computer Applications*, 215:103632, 2023.
- [6] Uchechukwu Awada, Jiankang Zhang, Sheng Chen, Shuangzhi Li, and Shouyi Yang. Edgedrones: Co-scheduling of drones for multi-location aerial computing missions. *Journal of Network and Computer Applications*, 215:103632, 2023.
- [7] Shakoar Barzanjeh, Fardin Ahmadizar, and Jamal Arkat. Logic-based benders decomposition algorithm for robust parallel drone scheduling problem considering uncertain travel times for drones. *Transportation Research Part E: Logistics and Transportation Review*, 193:103877, 2025.
- [8] Maria Elena Bruni, Sara Khodaparasti, and Guido Perboli. The drone latency location routing problem under uncertainty. *Transportation Research Part C: Emerging Technologies*, 156:104322, 2023.
- [9] Z. Bubnicki. Logic-algebraic method for a class of knowledge based systems. In Franz Pichler and Roberto Moreno-Díaz, editors, *Computer Aided Systems Theory — EUROCAST'97*, pages 420–428, Berlin, Heidelberg, 1997. Springer Berlin Heidelberg.

- [10] Z. Bubnicki. Learning processes and logic-algebraic method in knowledge-based control systems. In S. G. Tzafestas and G. Schmidt, editors, *Progress in system and robot analysis and control design*, pages 183–194, London, 1999. Springer London.
- [11] Alvaro Caballero, Francisco Javier Roman-Escorza, Ivan Maza, and Anibal Ollero. A multi-uav route planning method for fast inspection of electric power transmission lines. In *2024 International Conference on Unmanned Aircraft Systems (ICUAS)*, pages 835–842, 2024.
- [12] Lei Cai, Jiliu Li, Kai Wang, Zhixing Luo, and Hu Qin. Optimal allocation and route design for station-based drone inspection of large-scale facilities. *Omega*, 130:103172, 2025.
- [13] Ping Chen and Qianlong Wang. Learning for multiple purposes: A q-learning enhanced hybrid meta-heuristic for parallel drone scheduling traveling salesman problem. *Computers & Industrial Engineering*, 187:109851, 2024.
- [14] Walton P. Coutinho, Jörg Fliege, Maria Battarra, and Anand Subramanian. Routing a fleet of unmanned aerial vehicles: A trajectory optimisation-based framework. *Transportation Research Part B: Methodological*, 200:103312, 2025.
- [15] Erdi Dasdemir, Rajan Batta, Murat Köksalan, and Diclehan Tezcaner Öztürk. Uav routing for reconnaissance mission: A multi-objective orienteering problem with time-dependent prizes and multiple connections. *Computers & Operations Research*, 145:105882, 2022.
- [16] Kevin Dorling, Jordan Heinrichs, Geoffrey G. Messier, and Sebastian Magierowski. Vehicle routing problems for drone delivery. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 47(1):70–85, 2017.
- [17] E. Dudek-Dyduch, E. Kucharska, L. Dutkiewicz, and K. Rączka. Almm solver - a tool for optimization problems. In Leszek Rutkowski, Marcin Korytkowski, Rafał Scherer, Ryszard Tadeusiewicz, Lotfi A. Zadeh, and Jacek M. Zurada, editors, *Artificial Intelligence and Soft Computing*, pages 328–338, Cham, 2014. Springer International Publishing.
- [18] Ewa Dudek-Dyduch. *Formalizacja i analiza problematyki dyskretnych procesów produkcyjnych*. Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie, 1990.
- [19] Ewa Dudek-Dyduch. Learning-based algorithms in scheduling. *Journal of Intelligent Manufacturing*, 11:135–143, 2000.
- [20] Ewa Dudek-Dyduch. Algebraic logical meta-model of decision processes - new metaheuristics. In Leszek Rutkowski, Marcin Korytkowski, Rafał Scherer, Ryszard Tadeusiewicz, Lotfi A. Zadeh, and Jacek M. Zurada, editors, *Artificial Intelligence and Soft Computing*, pages 541–554, Cham, 2015. Springer International Publishing.
- [21] Ewa Dudek-Dyduch. Modeling manufacturing processes with disturbances - a new method based on algebraic-logical meta-models. In Leszek Rutkowski, Marcin Korytkowski, Rafał Scherer, Ryszard

- Tadeusiewicz, Lotfi A. Zadeh, and Jacek M. Zurada, editors, *Artificial Intelligence and Soft Computing*, pages 353–363, Cham, 2015. Springer International Publishing.
- [22] Ewa Dudek-Dyduch. Intelligent almm system for discrete optimization problems – the idea of knowledge base application. In Zofia Wilimowska, Leszek Borzemski, and Jerzy Świątek, editors, *Information Systems Architecture and Technology: Proceedings of 38th International Conference on Information Systems Architecture and Technology – ISAT 2017*, pages 3–12, Cham, 2018. Springer International Publishing.
- [23] Ewa Dudek-Dyduch, Zbigniew Gomolka, Bogusław Twarog, and Ewa Zesławska. Intelligent almm system - implementation assumptions for its knowledge base. *ITM Web Conf.*, 21:00002, 2018.
- [24] Ewa Dudek-Dyduch, Zbigniew Gomolka, Bogusław Twarog, and Ewa Zesławska. The concept of the almm solver knowledge base retrieval using protégé environment. In Wojciech Zamojski, Jacek Mazurkiewicz, Jarosław Sugier, Tomasz Walkowiak, and Janusz Kacprzyk, editors, *Engineering in Dependability of Computer Systems and Networks*, pages 177–185, Cham, 2020. Springer International Publishing.
- [25] Kucharska Edyta. Dynamic vehicle routing problem—predictive and unexpected customer availability. *Symmetry*, 11(4), 2019.
- [26] Kucharska Edyta. *Modelowanie dynamicznych procesów decyzyjnych w logistyce i produkcji : monografia*. NOT Naczelna Organizacja Techniczna Federacja Stowarzyszeń Naukowo-Technicznych, 2019.
- [27] Feng Gao, Jiaming Liu, Qiang Feng, Rui Feng, and Bin Yu. Task allocation and route planning for uav-based hybrid inspection of transmission towers, substations, and distribution poles from a fixed nest. *Expert Systems with Applications*, 313:131625, 2026.
- [28] Vipul Garg, Suman Niranjana, Victor Prybutok, Terrance Pohlen, and David Gligor. Drones in last-mile delivery: A systematic review on efficiency, accessibility, and sustainability. *Transportation Research Part D: Transport and Environment*, 123:103831, 2023.
- [29] Zbigniew Gomolka, Ewa Dudek-Dyduch, and Ewa Zesławska. Generalization of almm based learning method for planning and scheduling. *Applied Sciences*, 12(24), 2022.
- [30] Zbigniew Gomolka, Bogusław Twarog, Ewa Zesławska, and Ewa Dudek-Dyduch. Knowledge base component of intelligent almm system based on the ontology approach. *Expert Systems with Applications*, 199:116975, 2022.
- [31] Katarzyna Grobler-Dębska, Edyta Kucharska, and Jerzy Baranowski. Formal scheduling method for zero-defect manufacturing. *The International Journal of Advanced Manufacturing Technology*, 118(11):4139–4159, Feb 2022.
- [32] Bin Hang and Pengjun Guo. Low-cost safe path planning and exit scheduling of multi-uav aerial refueling based on swarm intelligence. *Swarm and Evolutionary Computation*, 101:102293, 2026.

- [33] Ali Hasani, Seyed Mohammad Hassan Hosseini, and Shib Sankar Sana. Scheduling in a flexible flow shop with unrelated parallel machines and machine-dependent process stages: Trade-off between makespan and production costs. *Sustainability Analytics and Modeling*, 2:100010, 2022.
- [34] Chang He, Haibin Ouyang, Weiqing Huang, Steven Li, Chunliang Zhang, Weiping Ding, and Zhi-Hui Zhan. An adaptive heuristic algorithm with a collaborative search framework for multi-uav inspection planning. *Applied Soft Computing*, 174:112969, 2025.
- [35] Qingying He, Wei Liu, Tian-Liang Liu, and Qiong Tian. Robust coordinated path planning for unmanned aerial vehicles and unmanned surface vehicles in maritime monitoring with travel time uncertainty. *Transportation Research Part B: Methodological*, 199:103284, 2025.
- [36] Yejun He, Kun Xiang, Xiaowen Cao, and Mohsen Guizani. Task scheduling and trajectory optimization based on fairness and communication security for multi-uav-mec system. *IEEE Internet of Things Journal*, 11(19):30510–30523, 2024.
- [37] Haiping Huang, Chengxi Hu, Jie Zhu, Min Wu, and Reza Malekian. Stochastic task scheduling in uav-based intelligent on-demand meal delivery system. *IEEE Transactions on Intelligent Transportation Systems*, 23(8):13040–13054, 2022.
- [38] Ho Young Jeong, Byung Duk Song, and Seokcheon Lee. Optimal scheduling and quantitative analysis for multi-flying warehouse scheduling problem: Amazon airborne fulfillment center. *Transportation Research Part C: Emerging Technologies*, 143:103831, 2022.
- [39] Jie Jiang, Ying Dai, Fei Yang, and Zujun Ma. A multi-visit flexible-docking vehicle routing problem with drones for simultaneous pickup and delivery services. *European Journal of Operational Research*, 312(1):125–137, 2024.
- [40] Hosang Jung and Junsu Kim. Drone scheduling model for delivering small parcels to remote islands considering wind direction and speed. *Computers & Industrial Engineering*, 163:107784, 2022.
- [41] Sławomir Korzonek and Ewa Dudek-Dyduch. Component library of problem models for almm solver. *Journal of Information and Telecommunication*, 1(3):224–240, 2017.
- [42] Edyta Kucharska, Katarzyna Grobler-Dębska, and Radosław Klimek. Collective decision making in dynamic vehicle routing problem. *MATEC Web Conf.*, 252:03003, 2019.
- [43] Edyta Kucharska, Katarzyna Grobler-Dębska, and Krzysztof Rączka. Algebraic-logical meta-model based approach for scheduling manufacturing problem with defects removal. *Advances in Mechanical Engineering*, 9(4):1687814017692291, 2017.
- [44] Deming Lei and Xiang Chen. An improved variable neighborhood search for parallel drone scheduling traveling salesman problem. *Applied Soft Computing*, 127:109416, 2022.
- [45] Keqin Li. Heuristic task scheduling on heterogeneous uavs: A combinatorial optimization approach. *Journal of Systems Architecture*, 140:102895, 2023.

- [46] Xiaoqing Li, Weidong Bao, Hui Yan, Qingbao Liu, Zhenxing Xu, Ji Wang, and Xiaomin Zhu. Dynamic demand-aware uav scheduling for iot data collection using deep reinforcement learning approach. *Future Generation Computer Systems*, 177:108248, 2026.
- [47] Yantong Li, Shengjie Wang, Shanshan Zhou, and Zheng Wang. A mathematical formulation and a tabu search heuristic for the joint vessel-uav routing problem. *Computers & Operations Research*, 169:106723, 2024.
- [48] Yuchen Li, Hongwei Ding, Zhijun Yang, Bo Li, and Zhuguan Liang. Integrated trajectory optimization for uav-enabled wireless powered mec system with joint energy consumption and aoi minimization. *Computer Networks*, 254:110842, 2024.
- [49] Junbin Liang and Liuxian Chen. Joint optimization of multiple path planning, charging scheduling and vnf deployment in rechargeable uavs-enabled edge networks. *Computer Networks*, 285:112377, 2026.
- [50] Bei Liu, Yuefeng Cai, Duantengchuan Li, Ke Lin, and Guanghui Xu. A hybrid aro algorithm and key point retention strategy trajectory optimization for uav path planning. *Drones*, 8(11), 2024.
- [51] Renke Liu, Rajesh Piplani, and Carlos Toro. A deep multi-agent reinforcement learning approach to solve dynamic job shop scheduling problem. *Computers and Operations Research*, 159:106294, 2023.
- [52] Yuying Long, Gangyan Xu, Jinqiu Zhao, Binglei Xie, and Meng Fang. Dynamic truck-uav collaboration and integrated route planning for resilient urban emergency response. *IEEE Transactions on Engineering Management*, 71:9826–9838, 2024.
- [53] Magdalene Marinaki, Andromachi Taxidou, and Yannis Marinakis. A hybrid dragonfly algorithm for the vehicle routing problem with stochastic demands. *Intelligent Systems with Applications*, 18:200225, 2023.
- [54] Raïssa G. Mbiadou Saleu, Laurent Deroussi, Dominique Feillet, Nathalie Grangeon, and Alain Quilliot. The parallel drone scheduling problem with multiple drones and vehicles. *European Journal of Operational Research*, 300(2):571–589, 2022.
- [55] Roberto Montemanni and Mauro Dell’Amico. Constraint programming models for the parallel drone scheduling vehicle routing problem. *EURO Journal on Computational Optimization*, 11:100078, 2023.
- [56] Roberto Montemanni, Mauro Dell’Amico, and Andrea Corsini. Parallel drone scheduling vehicle routing problems with collective drones. *Computers & Operations Research*, 163:106514, 2024.
- [57] Minh Anh Nguyen, Giang Thi-Huong Dang, Minh Hoàng Hà, and Minh-Trien Pham. The min-cost parallel drone scheduling vehicle routing problem. *European Journal of Operational Research*, 299(3):910–930, 2022.
- [58] Minh Anh Nguyen and Minh Hoàng Hà. The parallel drone scheduling traveling salesman problem with collective drones. *Transportation Science*, 57(4):866–888, 2023.

- [59] Haibin Ouyang, Leisen Liang, Steven Li, and Liquan Gao. A joint optimization method for multi-uav deployment and task scheduling in mobile edge computing with large-scale mobile users. *Expert Systems with Applications*, 255:124526, 2024.
- [60] Balasubramanian Sivarama Krishnan Panchatcharam Rajasekaran. US10902368b2 - intelligent decision synchronization in real time for both discrete and continuous process industries - google patents, 2019. Ostatni dostęp: 10.04.2025.
- [61] Bizhao Pang, Kin Huat Low, and Chen Lv. Adaptive conflict resolution for multi-uav 4d routes optimization using stochastic fractal search algorithm. *Transportation Research Part C: Emerging Technologies*, 139:103666, 2022.
- [62] Juan C. Pina-Pardo, Daniel F. Silva, and Alice E. Smith. The traveling salesman problem with release dates and drone resupply. *Computers & Operations Research*, 129:105170, 2021.
- [63] Juan C. Pina-Pardo, Daniel F. Silva, Alice E. Smith, and Ricardo A. Gatica. Fleet resupply by drones for last-mile delivery. *European Journal of Operational Research*, 316(1):168–182, 2024.
- [64] ATM Master Plan. Atm master plan. <https://atmmasterplan.eu/>. Ostatni dostęp: 24.02.2026r.
- [65] Stefan Poikonen, Xingyin Wang, and Bruce Golden. The vehicle routing problem with drones: Extended models and connections. *Networks*, 70(1):34–43, 2017.
- [66] POLFRA. Polfra - polska agencja Żeglugi powietrznej. <https://www.pansa.pl/polfra/>. Ostatni dostęp: 24.02.2026r.
- [67] Shaoming Qiu, Jikun Dai, and Dongsheng Zhao. Path planning of an unmanned aerial vehicle based on a multi-strategy improved pelican optimization algorithm. *Biomimetics*, 9(10), 2024.
- [68] Xiaoxue Ren, Houming Fan, Hao Fan, and Mengzhi Ma. Time-dependent electric vehicle-drone routing problem for scheduled deliveries and on-demand pickups considering variable drone speeds and no-fly zones. *Computers & Operations Research*, 182:107141, 2025.
- [69] Roberto Roberti and Mario Ruthmair. Exact methods for the traveling salesman problem with drone. *Transportation Science*, 55(2):315–335, 2021.
- [70] Fanfan Shen, Bofan Yang, Jun Zhang, Chao Xu, Yong Chen, and Yanxiang He. Td3-based trajectory optimization for energy consumption minimization in uav-assisted mec system. *Computer Networks*, 255:110882, 2024.
- [71] Yuan Tang, Yiming Miao, Ahmed Barnawi, Bander Alzahrani, Reem Alotaibi, and Kai Hwang. A joint global and local path planning optimization for uav task scheduling towards crowd air monitoring. *Computer Networks*, 193:107913, 2021.

- [72] Hannan Tureci-Isik, Murat Köksalan, and Diclehan Tezcaner-Öztürk. Interactive biobjective optimization algorithms and an application to uav routing in continuous space. *Transportation Research Part B: Methodological*, 193:103162, 2025.
- [73] Busra Tutumlu and Tugba Saraç. A mip model and a hybrid genetic algorithm for flexible job-shop scheduling problem with job-splitting. *Computers and Operations Research*, 155:106222, 2023.
- [74] Kehao Wang and Zhe Cheng. Multi-uav cooperative task scheduling and trajectory optimization system under communication constraints. *Physical Communication*, 76:103073, 2026.
- [75] Runhe Wang, Yang Huang, Yiwei Lu, Pu Xie, and Qihui Wu. Robust task offloading and trajectory optimization for uav-mounted mobile edge computing. *Drones*, 8(12), 2024.
- [76] Xin Wang, Ruiwei Jiang, and Mingyao Qi. A robust optimization problem for drone-based equitable pandemic vaccine distribution with uncertain supply. *Omega*, 119:102872, 2023.
- [77] Xinwei Wang, Xiaohua Gao, Lei Wang, Xichao Su, Junhong Jin, Xuanbo Liu, and Zhilong Deng. Resilient multi-objective mission planning for uav formation: A unified framework integrating task pre- and re-assignment. *Defence Technology*, 2024.
- [78] Xianglin Wei, Xiaolong Xu, and Mingyu Li. Longest chain-based battery mule scheduling in a multi-uav swarm. *Expert Systems with Applications*, 297:129365, 2026.
- [79] Yu Wu, Kin Huat Low, and Xinting Hu. Trajectory-based flight scheduling for airmetro in urban environments by conflict resolution. *Transportation Research Part C: Emerging Technologies*, 131:103355, 2021.
- [80] Binglei Xie, Tianyu Li, and Jinqiu Zhao. Multi-station flexible scheduling for uav emergency delivery under uncertain demand. *Transportation Research Part E: Logistics and Transportation Review*, 211:104845, 2026.
- [81] Li Chuntao Xie Mingyang, Cao Yuhui. Cn111880559a - optimization method for joint problem of task allocation and path planning of multiple unmanned aerial vehicles - google patents. <https://patents.google.com/patent/CN111880559A/en>, 2020. Ostatni dostęp: 10.04.2025.
- [82] Sai Xu, Jun Liu, Shengyu Huang, and Zhi Li. Drl-based task scheduling and trajectory control for uav-assisted mec systems. *Computers, Materials and Continua*, 86(3), 2026.
- [83] Zhou Xuanying, Ning Yida, Hou Yizhi, Wang Jiongqi, and He Zhangming. A two-stage self-learning jaya algorithm for the unmanned aerial vehicle scheduling problem under conflicting battlefield cargoes features. *Expert Systems with Applications*, 299:130007, 2026.
- [84] Shangyao Yan, Ching-Sheng Sun, Tzu-Bin Yan, and Ting-Sheng Chou. An optimization model and heuristic approach for routing and scheduling of mixed-type uav deliveries. *Computers & Industrial Engineering*, 217:112097, 2026.

- [85] Wenchao Yang, Yuxing Mao, Xueshuo Chen, Chunxu Chen, Bozheng Lei, and Qing He. A method for simultaneously implementing trajectory planning and dag task scheduling in multi-uav assisted edge computing. *Ad Hoc Networks*, 166:103668, 2025.
- [86] Ying Yang, Xiaodeng Hao, and Shuaian Wang. The drone scheduling problem in shore-to-ship delivery: A time discretization-based model with an exact solving approach. *Transportation Research Part B: Methodological*, 191:103117, 2025.
- [87] Yu Yang, Chiwei Yan, Yufeng Cao, and Roberto Roberti. Planning robust drone-truck delivery routes under road traffic uncertainty. *European Journal of Operational Research*, 309(3):1145–1160, 2023.
- [88] Weidu Ye, Junzhou Luo, Wenjia Wu, Feng Shan, and Ming Yang. Muta: An online trajectory optimization and task scheduling for uav-aided edge computing. *Computer Networks*, 218:109405, 2022.
- [89] Yunqiang Yin, Yongjian Yang, Yugang Yu, Dujuan Wang, and T.C.E. Cheng. Robust vehicle routing with drones under uncertain demands and truck travel times in humanitarian logistics. *Transportation Research Part B: Methodological*, 174:102781, 2023.
- [90] Ho Young Jeong and Seokcheon Lee. Drone routing problem with truck: Optimization and quantitative analysis. *Expert Systems with Applications*, 227:120260, 2023.
- [91] Ewa Zeslawska, Zbigniew Gomolka, and Ewa Dydek-Dyduch. Application of almm technology to intelligent control system for a fleet of unmanned aerial vehicles. In Biao Luo, Long Cheng, Zheng-Guang Wu, Hongyi Li, and Chaojie Li, editors, *Neural Information Processing*, pages 26–37, Singapore, 2024. Springer Nature Singapore.
- [92] Guowei Zhang, Ning Jia, Ning Zhu, Yossiri Adulyasak, and Shoufeng Ma. Robust drone selective routing in humanitarian transportation network assessment. *European Journal of Operational Research*, 305(1):400–428, 2023.
- [93] Jinqiu Zhao, Yuying Long, Binglei Xie, Gangyan Xu, and Yongwu Liu. A matheuristic solution for efficient scheduling in dynamic truck–drone collaboration. *Expert Systems with Applications*, 267:126218, 2025.
- [94] Lei Zhao, Xinhua Bi, Zhaohui Dong, Ni Xiao, and Anni Zhao. Robust traveling salesman problem with drone: balancing risk and makespan in contactless delivery. *International Transactions in Operational Research*, 31(1):167–191, 2024.
- [95] Lei Zhao, Xinhua Bi, Gendao Li, Zhaohui Dong, Ni Xiao, and Anni Zhao. Robust traveling salesman problem with multiple drones: Parcel delivery under uncertain navigation environments. *Transportation Research Part E: Logistics and Transportation Review*, 168:102967, 2022.
- [96] Zijia Zhao, Wenhan Zhan, Geyong Min, Xu Jiang, Liang Zhao, and Hualong Huang. Dynamic priority-based area partitioning, trajectory planning, and task scheduling in computing-while-flying uav networks. *Future Generation Computer Systems*, 183:108522, 2026.

-
- [97] Bolong Zhou, Wenjia Zeng, Wei Liu, and Hai Yang. Scheduling uav-assisted urban subway inspection services. *Transportation Research Part B: Methodological*, 199:103287, 2025.
- [98] Tengkuo Zhu, Stephen D. Boyles, and Avinash Unnikrishnan. Two-stage robust facility location problem with drones. *Transportation Research Part C: Emerging Technologies*, 137:103563, 2022.