



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

SÜRÜ İNSANSIZ HAVA ARAÇLARINDA
GÖREV PLANLAMA İÇİN BÜTÜNCÜL BİR
OPTİMİZASYON YAKLAŞIMI

Emre AYVAZ

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Temmuz-2025
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Emre AYVAZ tarafından hazırlanan “Sürü İnsansız Hava Araçlarında Görev Planlama İçin Bütüncül Bir Optimizasyon Yaklaşımı” adlı tez çalışması 28/07/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Mesut GÜNDÜZ
(Konya Teknik Üniversitesi)

.....

Danışman

Prof. Dr. İsmail BABAOĞLU
(Konya Teknik Üniversitesi)

.....

Üye

Prof. Dr. Mustafa Servet KIRAN
(Konya Teknik Üniversitesi)

.....

Üye

Dr. Öğr. Üyesi Onur İNAN
(Selçuk Üniversitesi)

.....

Üye

Dr. Öğr. Üyesi Eyüp SİRAMKAYA
(Nevşehir Hacı Bektaş Veli Üniversitesi)

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt Uyan
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Emre AYVAZ

Tarih: 28/07/2025

ÖZET

DOKTORA TEZİ

SÜRÜ İNSANSIZ HAVA ARAÇLARINDA GÖREV PLANLAMA İÇİN BÜTÜNCÜL BİR OPTİMİZASYON YAKLAŞIMI

Emre AYVAZ

**Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı**

Danışman: Prof. Dr. İsmail BABAOĞLU

2025, 89 Sayfa

Jüri

**Prof. Dr. İsmail BABAOĞLU
Prof. Dr. Mesut GÜNDÜZ
Prof. Dr. Mustafa Servet KIRAN
Dr. Öğr. Üyesi Onur İNAN
Dr. Öğr. Üyesi Eyüp SİRAMKAYA**

Çok sayıda ve farklı tipte İnsansız Hava Aracını (İHA) kapsayan görev planlama problemleri, her aracın sensör paketi, konumu, yakıtı ve faydalı yük kapasitesi gibi çeşitli kısıtlarına göre hangi görevlere atanabileceğini belirlemeyi amaçlar. Bu çalışma, böyle bir heterojen sürüde yakıt tüketimini, toplam görev süresini ve iniş-kalkış sayısını ve buna bağlı olarak riskini aynı anda en aza indiren çok-amaçlı bir planlama çerçevesi sunmaktadır. Literatürde yaygın olan Kısıt Tatmin Problemi (KTP) yaklaşımları, çoğu zaman statik kabuller ve açgözlü seçimler yüzünden büyük ölçekli, dinamik senaryolarda yetersiz kalmaktadır. Bu eksikliği gidermek için İyileştirilmiş Zamansal KTP (İZKTP) ve Adaptif Mutasyon Tabanlı Fizibilite-ve Restorasyon (AMFR) adlı iki arama stratejisi önerilmiştir.

Problemin biçimsel temeli Zamansal KTP'dir (ZKTP); burada görevler zamansal kümelerle ayrılır ve geri izleme, ileri kontrol, yay tutarlılığı ile düğüm tutarlılığını içeren, bunun yanı sıra havacılık problemleri özelinde hibrit bir çözücü geliştirilir. Çözücü, iniş yapmadan ardışıl görevlere geçiş veya havadan yakıt ikmali gibi havacılığa özgü dinamikleri hesaba katar. İlk aşamada sentetik ancak operasyonel gerçekliğe yakın verilerle çok sayıda atama senaryosu simüle edilir; ikinci aşamada ise her atama sonrası dinamik programlama temelli etki-alanı güncellemeleri çalıştırılarak zaman pencereleri yeniden düzenlenir. Yeni dinamik etki-alanı tekniği, eşdeğer zaman karmaşıklığında klasik ZKTP'den anlamlı ölçüde daha iyi çözümler üretmiştir. Buna karşılık AMFR, karmaşıklığı düşürmek amacıyla geliştirilmiş olup aynı problem kümesinde üretilen İZKTP çözümleriyle sistematik olarak karşılaştırılmıştır. Sonuçlar, İZKTP'nin global optimuma yakın çözümler bulma olasılığının yüksek fakat nispeten yavaş olduğunu; AMFR'nin ise daha kısa sürede düşük maliyetli çözümler sağlayabildiğini, ancak bu performansı her koşulda tutarlı biçimde koruyamadığını göstermiştir.

Deneyisel doğrulama için literatürden türetilen veri seti, yedi farklı İHA, on görev ve on bir lokasyondan oluşacak biçimde genişletilmiştir. Görevler irtifa, sensör gereksinimi, yetki seviyesi ve zaman pencereleri bakımından; İHA'lar ise yakıt kapasitesi, hız profili ve faydalı yük açısından heterojendir. Performans ölçütleri toplam yakıt tüketimi (litre), toplam uçuş süresi (dakika), iniş-kalkış sayısı ve görevi tamamlayabilen İHA yüzdesi olarak belirlenmiştir. Deneyler göstermiştir ki İZKTP, on görevlik paketler üzerinde klasik ZKTP'ye göre yakıt ve süre

maliyetini üç kata varan, yani yüzde 67'ye ulaşan oranlarda düşürmüştür. Doksan görevlik tam senaryoda İZKTP, otuz görevi havada yeni göreve atama yaparak iniş-kalkış sayısını 90'dan 60'a azaltmış ve yakıt tüketimini 3565 litreden 1953 litreye indirerek yüzde 45 tasarruf sağlamıştır. AMFR yönteminde ise, en kötü koşullarda İZKTP'den yüzde 15 daha fazla yakıt tasarrufu üretmesine rağmen, yüz görevlik simülasyonda toplam uçuş süresini 818 dakika artırmış; buna karşın İZKTP 19 kez daha az iniş-kalkış yaparak risk faktörünü azaltmıştır.

Bu bulgular, dinamik etki-alanı güncellemeli İZKTP'nin KTP ile aynı asimptotik karmaşıklıkta daha yüksek kaliteli çözümler üretebildiğini; AMFR'nin ise zincir iyileştirme mantığı sayesinde yerel tuzaklardan kaçarak özellikle ZKTP'nin zor örneklerinde maliyetleri düşürmek için etkin bir alternatif sunduğunu göstermektedir. Sınırlı veri setlerinde ve kısıtlı hesaplama süresinde bu iki yöntemin sağladığı başarı, yakıt ve zaman maliyetlerini uçuş emniyetinden ödün vermeden anlamlı ölçüde azaltabileceğimizi kanıtlamaktadır.

Anahtar Kelimeler: Adaptif Mutasyon, Çok Amaçlı Optimizasyon, Dinamik Etki Alanı, Dinamik Programlama, Görev Planlama, İnsansız Hava Araçları, Kısıt Tatmin Problemi,



ABSTRACT

PhD THESIS

A HOLISTIC OPTIMIZATION APPROACH FOR MISSION PLANNING IN SWARM UNMANNED AERIAL VEHICLES

Emre AYVAZ

**Konya Technical University
Institute of Graduate Studies
Department of Computer Engineering**

Advisor: Prof. Dr. İsmail BABAOĞLU

2025, 89 Pages

Jury

**Prof. Dr. İsmail BABAOĞLU
Prof. Dr. Mesut GÜNDÜZ
Prof. Dr. Mustafa Servet KIRAN
Asst. Prof. Dr. Onur İNAN
Asst. Prof. Dr. Eyüp SİRAMKAYA**

Mission planning problems involving large and heterogeneous fleets of Unmanned Aerial Vehicles (UAVs) aim to determine the feasible allocation of tasks to each vehicle, subject to diverse constraints such as sensor payload, location, fuel capacity, and useful load. This study introduces a multi-objective planning framework that simultaneously minimizes fuel consumption, total mission duration, and the number of takeoff–landing operations, thereby reducing the associated operational risks within such heterogeneous swarms. Conventional Constraint Satisfaction Problem (CSP) approaches in the literature often fail to cope with large-scale and dynamic scenarios due to their reliance on static assumptions and greedy selection strategies. To overcome these limitations, two search strategies are proposed: Improved Temporal CSP (ITCSP) and Adaptive Mutation-based Feasibility and Restoration (AMFR).

The formal foundation of the problem is the Temporal CSP (TCSP), where tasks are partitioned into temporal clusters, and a hybrid solver is developed that integrates backtracking, forward checking, arc consistency, and node consistency, while further incorporating aviation-specific dynamics. The solver accounts for operational constraints such as consecutive task transitions without landing and in-flight refueling. In the first stage, numerous assignment scenarios are simulated using synthetic yet operationally realistic data. In the second stage, dynamic programming-based domain updates are executed after each assignment to reorganize time windows. The proposed dynamic domain updating technique consistently yields superior solutions compared to classical TCSP, while maintaining equivalent time complexity. Conversely, AMFR is designed to reduce computational complexity and is systematically benchmarked against ITCSP over identical problem sets. Results indicate that ITCSP has a higher likelihood of converging to near-global optima, though at slower rates, whereas AMFR can produce lower-cost solutions more rapidly but with less consistency across diverse conditions.

For experimental validation, a dataset adapted from the literature was extended to encompass seven UAVs, ten tasks, and eleven locations. The tasks are heterogeneous in terms of altitude, sensor requirements, authorization levels, and time windows, while the UAVs differ in fuel capacity, speed profile, and payload characteristics.

Performance metrics are defined as total fuel consumption (liters), total flight duration (minutes), number of takeoff–landing operations, and the percentage of UAVs successfully completing their assigned missions. Experimental results demonstrate that, for ten-task packages, ITCSP reduced fuel and time costs by up to a factor of three (67%) compared with classical TCSP. In a full-scale scenario with ninety tasks, ITCSP reassigned thirty tasks in-flight, thereby reducing the number of takeoff–landing operations from 90 to 60 and cutting fuel consumption from 3565 liters to 1953 liters, achieving a 45% reduction. Under worst-case conditions, AMFR achieved up to 15% greater fuel savings than ITCSP; however, in simulations with 100 tasks it prolonged total flight time by 818 minutes, while ITCSP performed 19 fewer takeoff–landing cycles, thereby reducing the associated operational risk.

These findings demonstrate that ITCSP, enhanced with dynamic domain updates, is capable of producing higher-quality solutions at the same asymptotic complexity as conventional CSP. Meanwhile, AMFR, through its chain-improvement mechanism, offers an effective alternative for reducing costs in particularly challenging TCSP instances by escaping local optima. The demonstrated success of these two methods on limited datasets and under restricted computational budgets substantiates the potential for significantly reducing fuel and time costs without compromising flight safety.

Keywords: Adaptive Mutation, Constraint Satisfaction Problems, Dynamic Domains, Dynamic Programming, Unmanned Aerial Vehicles, Task Planning, Multi-Objective Optimization,

ÖNSÖZ

Bu tez çalışması, havacılıkta görev atama problemlerinin Kısıt Tatmin Problemi (KTP) yöntemine uyarlanmasıyla başlayan ve farklı çözüm yaklaşımlarının bir arada incelendiği bir serüveni anlatmaktadır. Çalışmada ilk olarak İHA'lara görev atama problemi KTP ile modellenmiş, ardından yeni bir bakış açısıyla iyileştirilmiş ve son olarak evrimsel temelli bir yöntem olan adaptif mutasyonla desteklenerek yöntemlerin çıktıları karşılaştırılmıştır. Böylece tez, hem kısıt tanım gücü yüksek klasik yapay zekâ yöntemlerini ve hem de evrimsel algoritmaları bir araya getirerek havacılık görev planlaması alanına yenilikçi bir bakış açısı sunmaktadır.

Doktora sürecim boyunca bana bilgisi ve tecrübesi ile destek olup yol gösteren, yardımlarını esirgemeyen değerli danışman hocam Sayın Prof. Dr. İsmail BABAÖĞLU'na, doktora tez sürecinde değerli fikirleriyle çalışmaya katkı sunan tez izleme komitesi üyeleri Sayın Prof. Dr. Mesut GÜNDÜZ'e ve Sayın Dr. Onur İNAN'a, jüri üyesi Sayın Dr. Eyüp SIRAMKAYA ile akademik çalışmalarımıza desteklerini esirgemeyen bölüm başkanımız Sayın Prof. Dr. Mustafa Servet KIRAN'a teşekkür ederim.

Elbette bu uzun ve yorucu sürecin benim için en büyük maliyeti, eşim, kızım, annem, babam ve sevdiklerim ile geçirebileceğim zamanlardan feragat etmektir. Ailemden uzak kalmak, onların sevgisi ve desteğinden mahrum yaşamak kimi zaman beni hüzünlendirse de çalışmalarımın ülkeme yapacağı katkı ve havacılığa duyduğum tutku, bu emeği sürdürmem için bana güç verdi. Ailemin inancı, sabrı ve manevi desteği olmasaydı, bu çalışmayı tamamlamak çok daha güç olurdu.

Gökyüzünün özgürlüğü ve büyüğü, bu tez sürecine ilham olmaya devam etti. Umuyorum ki çalışmam hem akademik çevrelere hem de uygulama sahasına yararlı bir katkı sunar. Bu vesileyle, anneme, babama, canım eşime ve kızıma, emeği geçen tüm aile bireylerime, hocalarıma, arkadaşlarıma ve meslektaşlarıma en içten teşekkürlerimi sunuyorum.

Emre AYVAZ
KONYA-2025

İÇİNDEKİLER

ÖZET	iv
ABSTRACT	vi
ÖNSÖZ	viii
İÇİNDEKİLER	ix
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	6
2.1. Matematiksel Programlama Temelli Görev Atama	6
2.2. Sezgisel Temelli Görev Atama	7
2.3. Pekiştirmeli Öğrenme Temelli Görev Atama	10
2.4. Derin Pekiştirmeli Öğrenme Temelli Görev Atama	10
2.5. Kısıt Tatmin Problemi Modeli Tabanlı Görev Atama	14
3. PROBLEMİN TANIMI	15
3.1. Karşılaştırma Kapsamı ve Hipotezler	17
3.1.1. Kapsam	17
3.1.2. Ölçütler ve Gösterimler	17
3.1.3. Hipotezler	17
3.1.4. Operasyon Önceliği ve Karar Kuralı	18
3.2. İstatistiksel Analiz Planı	18
4. MATERYAL VE YÖNTEM	20
4.1. Veri Seti	20
4.2. Görev Planlamada ZKTP	20
4.3. Görev Planlama için Materyal ve Önerilen Yöntemler	22
4.3.1. İZKTP	22
4.3.1.1. İZKTP'nin Sağladığı Avantajlar	25
4.3.1.2. Ön Hazırlık Aşaması	25
4.3.1.3. İZKTP Modelinin Oluşturulması	28
4.3.2. AMFR	33
4.3.2.1. AMFR Yöntemi Çalışma Prensibi	33
4.3.2.2. Yöntemin Özellikleri ve Katkıları	34
4.4. İZKTP Modeli Uygulaması	35
4.4.1. ZKTP – İZKTP Karşılaştırma Testleri	44
4.4.2. ZKTP – İZKTP İstatistiksel Analiz Sonuçları	52
4.4.3. ZKTP – İZKTP Modeli Karşılaştırma Test Yorumu	52
4.5. AMFR Modeli Uygulaması	53

4.5.1.	AMYO – GZİ Karşılaştırma Testleri	60
4.5.2.	AMYO – GZİ İstatistiksel Analiz Sonuçları	67
4.5.3.	AMYO – GZİ Karşılaştırma Test Yorumu	68
4.6.	İZKTP ve AMFR Karşılaştırma Testleri	69
4.6.1.	İZKTP – AMFR İstatistiksel Analiz Sonuçları	75
4.6.2.	İZKTP – AMFR Karşılaştırma Test Yorumu	76
5.	ARAŞTIRMA SONUÇLARI VE ÖNERİLER	78
KAYNAKÇA		82



SİMGELER VE KISALTMALAR

Simgeler:

T : Görevler kümesi
U : Uçaklar Kümesi
 $\mathcal{A}$: Havaalanları kümesi
L : Litre
T : Süre
F : Yakıt

Kısaltmalar:


AMFR : Adaptif Mutasyon tabanlı Fizibilite ve Restorasyon
AMYO: : Adaptif Mutasyon tabanlı Yerel Onarım
GZİ : Görev Zinciri İyileştirme
MILP : Mixed Integer Linear Programming
MIQP : Mixed Integer Quadratic Programming
AC : Arc Consistency
BT : Backtracking
CSP : Constraint Satisfaction Problem
DT : Düğüm Tutarlılığı
GA : Genetik Algoritma
Gİ : Geri İzleme
GZİ : Görev Zinciri İyileştirme
EO : Elektro Optik
FC : Forward Checking
IR : Infrared
ITCSP : Improved Temporal Constraint Satisfaction Problem
İHS : İnsansız Hava Aracı Sistemleri
İK : İleri Kontrol
İZKTP : İyileştirilmiş Zamansal Kısıt Tatmin Problemi
KTP : Kısıt Tatmin Problemi
İHA : İnsansız Hava Aracı
MOGA : Multi Objective Genetic Algorithm
NC : Node Consistency
Q-Learning: Quality Learning
RL : Reinforcement Learning
SS : Standart Sapma
TCSP : Temporal Constraint Satisfaction Problem
UAV : Unmanned Aerial Vehicle
YKİ : Yer Kontrol İstasyonu
YT : Yay Tutarlılığı
ZKTP : Zamansal Kısıt Tatmin Problemi

1. GİRİŞ

İnsansız Hava Araçları (İHA), insan müdahalesi olmaksızın veya uzaktan kumandayla görev icra edebilen hava platformlarıdır. Askerî amaçlarla doğan bu araçlar (Floreano ve Wood, 2015), zamanla sivil ve ticari kullanım alanlarında da yaygınlaşarak modern dünyanın ayrılmaz bir parçası hâline gelmiştir. Özellikle sıkıcı, kirli ve tehlikeli (Dull, Dirty, Dangerous – 3D) görevlerde insanlı hava araçlarına kıyasla daha düşük maliyetli ve daha güvenli çözümler sunmaları, onları stratejik önemde bir teknoloji hâline getirmiştir (Shakhatreh ve diğ., 2019; van Lieshout ve Friedewald, 2018) Bu büyümenin doğal sonucu olarak, artan görev çeşitliliği, karmaşık çevresel koşullar ve yoğun hava sahası trafiği, çoklu İHA görev planlamasını hem kritik hem de mevcut yöntemlerle yönetilmesi güç bir problem hâline getirmiştir.

İHA konseptine ilişkin akademik referansların tarihi I. Dünya Savaşı'na kadar uzanır. “The Pilotless Aircraft” (Low, 1916) bu dönemde görev planlamanın askerî harekâtlardaki önemine işaret eden erken çalışmalardandır. Daha sonra 1963 yılında yayımlanan “Ryan Firebee” çalışması, İHA'nın gerçek dünyada kullanılabildiği ilk örneklerden biri olarak kayda geçmiştir (McGetrick, 1963). 20. yüzyılın ikinci yarısında özellikle Vietnam Savaşı sırasında İHA'lar keşif ve istihbarat amaçlı yoğun biçimde kullanılmıştır. Bununla birlikte, 2000'li yıllara kadar yüksek maliyetler ve sınırlı teknolojik altyapı nedeniyle görev planlama araştırmaları beklenen ölçüde gelişmemiştir (Steven R. LaValle, 1995). Ancak 2000'li yıllarla birlikte sensör teknolojilerindeki ilerleme, haberleşme imkânlarının artması ve yapay zekâ tabanlı kontrol sistemlerinin gelişmesiyle İHA araştırmaları hız kazanmıştır (Mohsan SAH, 2022).

Bu ivmelenmenin akademik yansıması, 2001–2024 yılları arasında yapılan çalışmaların Scopus verileri üzerinden incelenmesiyle de görülmektedir. Şekil 1.1, bu dönemdeki yayın yoğunluğunu göstermektedir ve alandaki bilimsel ilgideki istikrarlı artışa işaret etmektedir.



Şekil 1.1. 2001-2024 yılları arasında gerçekleştirilen İHA odaklı bilimsel çalışma yoğunluğu

İHA'ların farklı sektörlerdeki kullanım örnekleri, bu araçların çok yönlü değerini ortaya koymaktadır. Telekomünikasyon, sağlık (Hiebert ve diğ., 2020), lojistik (Johannessen ve diğ., 2021), trafik kontrolü (Shrestha ve diğ., 2021), kamu güvenliği (Shakoor ve diğ., 2019), orman izleme (De Almeida ve diğ., 2021) ve askeri görevler (Achtelik, 2011) başlıca uygulama alanlarıdır (Ji, 2019; Song J, 2023; Wang ve diğ., 2023).

Askerî İHA'lar artık yalnızca keşif için değil, silah taşıma ve hassas angajman görevleri için de kullanılmaktadır. Örneğin, MQ-9 Reaper gibi platformlar uzun süre havada kalabilmekte, geniş bölgeleri tarayabilmekte ve gerektiğinde operasyonel müdahaleler gerçekleştirebilmektedir. Sivil tarafta ise İHA'ların tarımda bitki sağlığını izleme, arazi analizi ve hassas ilaçlama (Zhang ve Kovacs, 2012); lojistikte hızlı teslimat ve kırsal bölgelerde erişim (Dorling ve diğ., 2016; Eskandaripour ve Boldsai Khan, 2023); sağlıkta kan, aşı ve ilaçların afet bölgelerine ulaştırılması (Amukele, 2022) gibi kritik görevleri başarıyla üstlendiği bilinmektedir. Ruanda'da kan bankalarının köylere erişiminde İHA'lar standart bir yöntem hâline gelmiştir. Çevre izleme ve afet

yönetiminde de yangın tespiti, sel hasar analizi veya deprem sonrası arama-kurtarma için yüksek çözünürlüklü sensörlerle donatılmış İHA'lar kullanılmaktadır. Örneğin, Ghauri ve diğ. (2024) tarafından sunulan çoklu-İHA görev atama algoritmaları üzerine kapsamlı inceleme, özellikle arama-kurtarma operasyonlarında İHA'ların görev etkinliğini ve operasyonel kapsamını artırma potansiyelini ortaya koymakta ve İHA'ların operasyonel sistemlerin kritik bileşenleri olduğunu göstermektedir (Ghauri ve diğ., 2024).

Sayısal veriler de bu yaygınlaşmayı desteklemektedir: 2023 yılında küresel İHA pazarının büyüklüğü yaklaşık 31,98 milyar \$ olarak tahmin edilmiş, bu değerin 2034 yılına kadar 157 milyar \$'ı aşacağı öngörülmüştür. Aynı yıl dünya genelinde yaklaşık 7,6 milyon İHA sevkiyatı gerçekleşmiş ve sevkiyatların önümüzdeki dönemde çift haneli oranlarda artması beklenmektedir. Ayrıca 100'den fazla ülkenin envanterinde farklı tipte askerî İHA bulunmakta ve bu alandaki savunma yatırımları her yıl katlanarak büyümektedir (Abdulrahman ve diğ., 2025). Bu rakamlar, hem akademik hem de endüstriyel açıdan İHA görev planlaması probleminin ne kadar stratejik bir öneme sahip olduğunu göstermektedir.

İHA'ların başarısı, yalnızca sahip oldukları platform özelliklerinden değil, aynı zamanda görev planlama süreçlerinin etkinliğinden de doğrudan etkilenmektedir. Havacılık operasyonları doğası gereği belirsizliklerle doludur (Shakhathreh ve diğ., 2019). Çoklu İHA görev planlamasında çevresel koşullar, enerji kısıtları, öncelikler ve hava sahası durumu gibi faktörler birbiriyle bağımlıdır. Verilen her karar, sonraki adımları etkileyen bir **karar zinciri** oluşturur. Bu zincir, çözüm uzayını yalnızca genişletmekle kalmaz, aynı zamanda dinamik hâle getirir. Sonuçta görev planlama, tekil rota planlamadan farklı olarak çok boyutlu, zamansal ve mekânsal kısıtları bir arada değerlendiren karmaşık bir optimizasyon problemine dönüşür.

Problemin boyutları sayısal olarak düşünüldüğünde güçlük daha açık ortaya çıkar: 10 görev için milyonlarca, 100 görev için ise astronomik boyutlarda olasılık söz konusudur. Bu da, klasik yöntemlerle çözümün hem zaman hem de hesaplama açısından sürdürülemez olmasına yol açmaktadır.

Görev planlama yöntemleri, genellikle matematiksel modelleme, yapay zekâ ve optimizasyon teknikleri etrafında şekillenir. Kısıt Tatmin Problemi (KTP) yaklaşımı, yakıt, zaman ve rota gibi temel parametrelerin tatminini hedefleyen bir modelleme çerçevesi olarak öne çıkar. Bunun yanı sıra genetik algoritmalar (GA), parçacık sürü optimizasyonu ve karınca kolonisi optimizasyonu gibi meta-sezgisel yöntemler, büyük ölçekli problemlerde pratik çözümler

sunmaktadır. Son yıllarda ise yapay zekâ ve makine öğrenimi tabanlı algoritmalar giderek daha yaygın hale gelmiş, İHA'ların çevresel değişkenlere hızlı adaptasyonu ve karmaşık görevlerin yerine getirilmesi mümkün olmuştur (Aggarwal ve Kumar, 2020; Meng ve diğ., 2025).

Örneğin, orman yangınlarında yangının yayılma hızını analiz ederek gerçek zamanlı rota güncellemesi yapabilen İHA'lar; ya da yoğun trafik koşullarını değerlendirerek tıbbi malzemeleri en hızlı şekilde ulaştıracak güzergâhı seçebilen sistemler, bu eğilimin pratik karşılıklarıdır. Ancak, mevcut KTP tabanlı yaklaşımlar çoğu zaman statik kabuller, açgözlü seçimler ve ölçeklenebilirlik sorunları nedeniyle dinamik ve büyük ölçekli senaryolarda yetersiz kalmaktadır.

Bu tez çalışması, yukarıda özetlenen zorlukları aşmayı hedefleyerek iki yeni yöntem önermektedir: İyileştirilmiş Zamansal KTP (İZKTP) ve Adaptif Mutasyon Tabanlı Fizibilite-ve Restorasyon (AMFR).

- İZKTP, yakıt tüketimi, risk ve bağıl konum gibi dinamik kısıtları havacılığa özgü şekilde modelleyerek ardışıl görev çiftlerini zaman pencereleri içinde ilişkilendirmekte ve klasik ZKTP ile aynı zaman karmaşıklığında daha maliyet etkin çözümler üretmektedir.
- Ancak çözüm uzayı büyüdüğünde KTP'nin doğası gereği ortaya çıkan en kötü durum (worst-case) işlem yükünü dengelemek amacıyla AMFR modeli geliştirilmiştir. Bu model, rastgele atanan görev-İHA eşleşmelerini mutasyon tabanlı evrimsel bir algoritma ile adım adım iyileştirerek İZKTP'ye kıyasla daha düşük zaman karmaşıklığında benzer çözümler üretebilmektedir.

Gerçekleştirilen testlerde, İZKTP yönteminin daha az sayıda İHA ile görevlerin tamamlanmasını sağladığı ve standart ZKTP'ye kıyasla %33 oranında iniş-kalkış tasarrufu elde ettiği görülmüştür. Örneğin, 90 görev içeren bir testte ZKTP'de 90 iniş-kalkış yapılırken, İZKTP'de bu sayı 60'a düşmüştür. Bu, havacılıkta operasyonel riskin azaltılması açısından son derece kritik bir bulgudur (BOEING, 2023). Bu tür sayısal iyileştirmeler, yalnızca operasyonel verimliliği artırmakla kalmaz, aynı zamanda güvenliği doğrudan etkileyen parametrelerde kayda değer bir katkı sağlar.

Bu çalışmanın temel katkıları şu şekilde özetlenebilir:

- Klasik ZKTP'nin sınırlılıklarını aşmak üzere, dinamik kısıtları ve ardışıl görev ilişkilerini zamansal pencereler içinde ele alan İZKTP modelinin geliştirilmesi,
- En kötü durumlarda yüksek zaman karmaşıklığına karşı AMFR algoritmasının alternatif çözüm yöntemi olarak önerilmesi,

- Her iki modelin çoklu görev senaryolarında test edilerek yakıt, süre ve iniş-kalkış sayısı bakımından karşılaştırmalı performans sonuçlarının sunulması.

Bu katkılarla birlikte tez, yalnızca kısıtların modellenmesiyle sınırlı kalmayan; aynı zamanda dinamik karar değişkenlerine uyum sağlayabilen yeni yaklaşımlar da önermektedir. İleride hibrit yöntemlerin geliştirilmesiyle, daha karmaşık senaryolara ölçeklenebilir çözümler üretilmesi mümkündür (Alqudsi ve Makaraci, 2025).

Tezin organizasyonu şu şekildedir: Bölüm 2’de görev planlamaya dair literatür sunulmakta, Bölüm 3’te problem tanımı yapılmakta, Bölüm 4’te önerilen yöntemler (İZKTP ve AMFR) ayrıntılı biçimde açıklanmakta, Bölüm 5’te deneysel sonuçlar tartışılarak genel çıkarımlar ve gelecek araştırma önerileri sunulmaktadır.

2. KAYNAK ARAŞTIRMASI

Bu bölümde, İHA'ların çoklu görev atama problemi ve bu problemin optimizasyonuna yönelik literatürde yer alan çalışmalar özetlenmiştir. Özellikle farklı yöntemlerin performansları, avantajları ve sınırlılıkları ele alınarak, bu alandaki güncel yaklaşımlar tartışılmıştır. İHA'lar için görev planlamayla ilgili literatür taraması matematiksel programlama, sezgisel, pekiştirmeli öğrenme, derin pekiştirmeli öğrenme ve KTP modellemesi temelli görev atama adlı alt başlıklarda incelenmiştir. Bu bölümde özellikle KTP modelinin uygulandığı çözümler ve türevleri araştırılmıştır. Bir sonraki içerikte bu modelin görev planlamada kullanımının detaylarına bakılarak, olası yeniliklerin olumlu ve olumsuz taraflarına yer verilmiştir. Bu çalışma öncelikle en temel anlamda İHA görev planlama konseptleri incelenmiştir (J. Gaowei, 2019; S. Yi, 2019). Kaynak araştırması görev planlama sürecinin temelde görev atama ve rota planlama olarak iki ana fonksiyondan oluştuğunu göstermektedir. Görev atama işlemi ile ilgili olarak farklı özelliklere sahip heterojen yapıdaki İHA dağılımında, planlama ve tasarım safhasının genel anlamda tüm sürecin en kritik adımını temsil ettiği bilinir (S. Yi, 2019). Aşağıda bahsi geçen konulara kaynak oluşturacak düzeyde literatür özeti sunulmuştur.

2.1. Matematiksel Programlama Temelli Görev Atama

Görev atama problemi, matematikte Harekât Araştırması (Operational Research) dalındaki kombinasyonel optimizasyon problemlerinin (Combinatorial Optimization Problem-COB) temellerinden biridir (Hillier, 2001). 2010'lu yıllara kadar yaygın olarak kullanılan görev atama metotlarından bazıları şunlardır: Kapsamlı Metod (Exhaustive Algorithm), Dallanma ve Sınırlandırma (Branch And Bound-B&B), Macar Algoritması (Hungarian Algorithm)(Mills-Tetty ve diğ., 2007) ve Çoklu Gezgin Satıcı (Multi Travelling Salesman Problem - MTSP) problemi gibi etkin yaklaşımlar. Kapsamlı metottaki ana fikir kaba kuvvetle tüm ihtimalleri denemekten ibarettir. Dolayısıyla geniş çözüm uzayına sahip problemlerde kullanılamaz. Ramirez'in çalışmasındaki optimizasyon çözümü ise Dallanma ve Sınırlandırma algoritması için başarılı bir yaklaşım sunar (C. Ramirez-Atencia, 2014). Karışık Tamsayı Doğrusal Problem (mixed integer linear problem - MILP) modeli üzerine de birçok çalışma yapılmıştır (Byung Duk Song, 2018). Schumacher ve arkadaşları., hava-yer saldırı görevlerinin aynı tipte İHA'lara (izomorfik İHA) atanması sorununu çözmek için MILP model analizini kullanmışlardır. MILP

yöntemi ile zaman kısıtlarının da hesaplanabildiği ve daha geniş bir alanda heterojen bir filo için ortak görev atamaları ve zamanlama sorunlarının optimum çözümü için uygun koşulları yarattığını göstermişlerdir (C Schumacher, 2003). Doherty çalışmasında, görev planlama ve izleme için Zamansal Eylem Mantığı (Temporal Action Logic - TAL) üzerinde çalışan bir altyapı sunmuştur (Doherty, 2009). Atama eylemlerini ve yaşanan değişiklikleri anlamlandırarak insansız helikopterler üzerinde denemeler yapılması da döner kanatlı sistemler üzerinde yapılan önemli çalışmalardandır (P. Fabiani, 2007). ReSSAC (Search and Rescue by Cooperative Autonomous System) adında benzer bir proje ise arama kurtarma operasyonlarında kullanılmak üzere görev atamaları kapsamında French Aerospace Lab (ONERA)'da denenmiş ve dinamik proglamlama ile Markov Karar Süreci (Markov Decision Process - MDP) kullanılarak modellenmiştir (P. Laroche, 1999).

2.2. Sezgisel Temelli Görev Atama

Son yıllarda, İHA görevlerinin otomatik olarak planlanması ve programlanması; Kısıt Tatmin Problemi – KTP (CSP), evrimsel algoritmalar, sürü zekâsı, pekiştirmeli öğrenme, güncel makine öğrenmesi ve derin öğrenme yaklaşımları gibi yapay zekanın farklı metodolojileriyle çözülmeye çalışılmıştır. Bu bölümde sezgisel yaklaşımların çoklu İHA görev atama problemleri kapsamında nasıl uygulandığı detaylı olarak incelenmiştir.

Literatürde görev planlama probleminin (M)TSP modeli (Adbelhafiz ve diğ., 2010; Secrest, 2001), Araç Rotalama Problemi (Vehicle Routing Problem -VRP) (Geng ve diğ., 2014) gibi durumlara indirgenerek çözüldüğü örneklere sıkça rastlamak mümkündür. Yakın dönemlerde de çok sensörlü çoklu İHA görev atama problemlerinin TSP ve Çok Depolu Araç Rota Problemi (Multiple Depot Vehicle Routing Problem-MDVRP) ile hibritleyerek çözülmesi üzerine çalışmalar yapıldığı görülmektedir (Li, 2017). Shima ve arkadaşları, çoklu İHA görev ataması problemini çözmek için GA'ların avantajlarından yararlanmışlardır. Bu çalışmada GA'ların klasik kombinatoriyal optimizasyon yöntemlerinin hesaplama karmaşıklığından daha başarılı olduğu sonucuna varıldığını vurgulamışlardır (T Shima, 2006). Benzer bir çalışmada heterojen İHA'larda belirli bir zaman aralığında kooperatif çoklu görev atama için aynı şekilde GA başarılı bir şekilde kullanılmış ve deterministik model ile kıyaslanarak avantajları ortaya konulmuştur (Zhenyue Jia, 2018). Edison ve Shima, rota planlamayı Dubins Araç Modeli (a dubins car) ile görev planlamayı

GA ile çözen (Edison E, 2011) veya Hedef Paketi Tabanlı (Target-Bundle-Based) kodlama ve özel genetik operatörleri kullanan modifiye edilmiş bir GA üzerine çalışmışlardır (Xu G, 2020).

Huang ve arkadaşlarının yaptığı çalışmada savaş uçaklarının görevlere atama probleminin çözümü için İyileştirilmiş Parçacık Sürü Optimizasyonu (Improved Particle Swarm Optimization - IPSO), Karınca Kolonisi Algoritması (Ant Colony Optimization – ACO) ve GA yaklaşımları önerilmiş ve uygulanan testlerle ilgili karşılaştırmalı analiz yapılarak GA'nın doğru sonuçlar üretmesine rağmen zaman karmaşıklığında yavaş kaldığını ortaya koymuşlardır (Huang H, 2019). Gng ve arkadaşları, robot kurtarma görevi ile yaptıkları çalışmada optimum atama problemine odaklanarak uygunsuz atamaların oluşturulmasını önlemeye yönelik esnek bir atama çözümü sunan modifiye PSO algoritması tasarlamışlardır (Geng ve diğ., 2021).

Literatürde klasik yöntemleri revize ederek çözüm bulmaya çalışan birçok yöntem mevcuttur. Kurt Sürüsü Arama (Wolf Pack Search - WPS) algoritması (Chen, 2018), 2010'lu yıllara kadar kısıt temelli optimizasyon problemlerinde sıklıkla tercih edilen Tabu Arama (Tabu Search) (Yan, 2013), etkin çözümler sunan İyileştirilmiş Benzetimli Tavlama (Improved Simulated Annealing- ISA) ve birçok optimizasyon probleminde uygulanan GA'daki etkin arama sağlayan ve popülasyon çeşitliliğini arttıran mekanizmaların kullanıldığı özgün yöntemler örnek verilebilir (X. Wu, 2021). Benzer şekilde ACO yöntemini genişleten ve feromon üyeliği yöntemiyle güzergahta geri besleme sağlayan Gruplama Karınca Koloni Algoritması (Grouping Ant Colony Optimization-GACO) çalışmasının, geniş ölçekli atama problemlerinde etkili olduğu ve çözüm uzayında lokal optimuma takılmadan keşif yapabildiği sonucuna varılmıştır (Gao, 2021).

Merkeziyetsiz görev atamada, optimizasyon temelli merkeziyetsiz çoklu ajan ve çoklu görev atama problemi için Uzlaşma Temelli Paket Algoritması (Consensus-Based Bundle Algorithm - CBBA) üzerinde çalışılmış (Ye, 2021) ve yine CBBA ile zaman kısıtına bağlı olarak dağıtık yeniden çoklu görev atama (Distributed Multiple Reassignments) özelliği eklenerek optimizasyon sağlandığı bildirilmiştir (J. Turner, 2018).

Literatürde İHA'larla ilgili kooperatif görev atama ve planlama problemlerini müzakereci bir paradigmayla ele alan çok az yayın mevcuttur. Bir görev planlayıcısı temel olarak, araçların görevleri ve yetenekleri hakkında bilgilere dayanarak her bir görevi yerine getirecek araçların atandığı bir liste sağlamalıdır. Bu amaçla Bethke ve arkadaşları kooperatif görev ataması için Massachusetts Institute of Technology (MIT)'de geliştirilen geri çekilen ufuk görev atama (Receding-Horizon Task Assignment - RHTA) algoritmasını genişleten bir algoritma

önermektedir (B. Bethke, 2008). Benzer bir çalışmada RHTA, açgözlü (greedy) yöntem ile kıyaslanmakta ve hızlı sonuç alınmasına rağmen açgözlü yöntemin daha etkili çözümler sunmakta RHTA kadar iyi olmadığı belirtilmektedir (Alighanbari, 2004).

Zhang ve arkadaşları, çoklu-İHA görev atama kapsamında dört hedefi aynı anda optimize etmek için klon seçimi algoritması tabanlı bir yaklaşım önerdiler. Amaç başarıyla tahsis edilen görev sayısını ve kazançları maksimize etme, kaynak ve zaman maliyetlerini minimize etmeydi (Zhang ve Chen, 2021). Benzer bir çalışmada ise sınırlı uçuş süresi ve sınırlı yük kapasitesi gibi iki temel kısıt sorununu aşmak ve yakınsak Pareto çözümleri bulmak (approximate pareto solutions) için hesap karmaşıklığı daha az olan yakınsak iki aşamalı yaklaşım (approximate two-phase approach) geliştirildiği bildirilmiştir (Song ve diğ., 2022).

İHA görev planlamasındaki son gelişmelerde, Çok Amaçlı Genetik Algoritmalar (Multi Objective Genetic Algorithm - MOGA) ve bunların varyantları aracılığıyla çok amaçlı optimizasyon yaklaşımlarına odaklanan çalışmalar da bulunmaktadır (Ramirez-Atencia ve diğ., 2017). Elitist stratejiye dayalı baskılanmamış sıralı GA (Non-Dominated Sorting Genetic Algorithm II - NSGA-II), toplam görev tamamlama süresi, toplam görev ödülü ve küme hasar seviyesi gibi birden fazla optimizasyon hedefini eş zamanlı olarak ele alarak görev atama problemini çözmek için kullanılmaktadır (Singh ve diğ., 2023). İHA sürülerindeki kısıtlı iletişim ortamlarında, konfigürasyonun değişen görevlerle dinamik olarak değişmesi gerektiği durumlarda, araştırmacılar motif tabanlı planlama modelleri kullanarak görev konfigürasyonlarını otomatik olarak üreten sürü koordinasyonu ve görev planlaması için geliştirilmiş NSGA-III algoritmaları geliştirmişlerdir (Wang ve diğ., 2023). Çok Amaçlı Evrimsel Algoritmalar (Multi Objective Evolutionary Algorithm - MOEA), karmaşık çok-İHA görev planlama problemleri için özellikle etkili olduğunu kanıtlamış olup, çalışmalar gerçek zamanlı görev senaryolarının doğasında var olan karmaşıklığı ele almak için tasarlanmış özel MOGA çerçevelerinin uygulanmasını göstermektedir (Ghambari ve diğ., 2020). Zorlu hava koşulları altında çok-İHA denizcilik arama kurtarma operasyonları için geliştirilmiş NSGA-II algoritmaları, heterojen hedef senaryolarını ele almak için uyarlanabilir optimizasyon tekniklerinin son gelişmelerini temsil etmektedir (Ma ve diğ., 2023). Ayrıca, İHA sürüleri için çok amaçlı görev planlama problemlerinin çözümünde geliştirilmiş NSGA-III algoritması, özellikle hesaplama kaynaklarının ve görev hedeflerinin etkili bir şekilde dengelenmesi gereken karmaşık operasyonel ortamlarda, karar vericilere optimal çözümler seçmede yardımcı olmak için gelişmiş seçim stratejileri sunmaktadır (Liu ve diğ., 2018).

2.3. Pekiştirmeli Öğrenme Temelli Görev Atama

Karşılaşılan karmaşık ve değişken savaş durumu, son derece dinamik saldırı ve savunma, karar verme süreçlerinin optimalitesi ve gerçek zamanlı performansı açısından son derece yüksek talepler ortaya koymaktadır. Ancak yukarıda bahsedilen algoritmalar, hesaplama verimliliği ve genel optimalite açısından yetersiz kalmaktadır. Yapay zekâ teknolojisinin gelişimiyle birlikte sinir ağları, görüntü tanıma, akıllı kontrol gibi alanlarda yaygın olarak araştırılmıştır. Güçlü keşif ve optimizasyon yetenekleri nedeniyle, Pekiştirmeli Öğrenme (Reinforcement Learning – RL), "genel zekâ"ya ulaşmanın en muhtemel aracı olarak kabul edilmektedir (Jiang ve diğ., 2023). RL, dinamik programlama teorisine dayanmakta ve davranışçı psikolojiden ilham almaktadır. "Keşif" ve "istismar"ı dengeleyerek, çevresel ödüller alarak optimal stratejileri öğrenir. Go ve video oyunlarında, karmaşık RL'nin insan performansına ulaştığı veya aştığı görülmüştür. RL aynı zamanda hedef atama ve akıllı kontrolde de uygulanmıştır (Shin, 2019).

Zhao ve arkadaşları, tahsis kurallarını kodlayan bir Q ağı geliştirerek Q-öğrenme temelli hızlı görev tahsis algoritması önerdiler. Önerilen algoritma, çevrimiçi hesaplamaları çevrimdışı bir öğrenme prosedürüne aktararak hesaplama açısından verimli ve çevresel belirsizlik etkileriyle başa çıkabilir olarak önerilmiştir (Zhao ve diğ., 2019). Çevresel belirsizlik bulunan koordineli dinamik görev tahsisine yönelik olarak, Liu ve arkadaşları, dinamik göreve katılıp katılmama konusunu belirlemek için istekleri gönderen çoklu ajan RL tabanlı koordineli bir ağ önerdiler (Liu ve diğ., 2022).

2.4. Derin Pekiştirmeli Öğrenme Temelli Görev Atama

Bu çalışma kapsamında görev atama problemi için odaklanılan diğer bir yaklaşım, derin pekiştirmeli (takviyeli) öğrenme (Deep Reinforcement Learning - DRL) yöntemidir. Bu yöntem, yapay zekâ alanındaki en güçlü tekniklerden biridir ve İHA'lar için önemli bir uygulama alanı sunar. Burada derin pekiştirmeli öğrenme, bir İHA'nın çevresiyle etkileşime girerek ve ödül sinyalleri alarak kendi davranışlarını öğrenmesini sağlar. İHA'lar için bu, uçuş kontrolü, otonom navigasyon, görev planlaması ve engel tespiti gibi birçok alanda uygulama bulmaktadır. Örneğin, bir İHA'nın hedefe otonom olarak ulaşması gerektiğinde, derin pekiştirmeli öğrenme, çevresindeki engelleri tanıyıp, en verimli uçuş yolunun belirlenmesini sağlar. Ayrıca, karmaşık hava koşullarında veya yoğun trafik ortamlarında uçuş yapabilmesi için uygun stratejiler geliştirir.

İHA'ların otonom görevlerde daha etkili olabilmesi adına, ilgili teknikler, çevreden gelen geri bildirimlerle ajanı eğitir ve zamanla performansını optimize eder. Derin pekiştirmeli öğrenmenin, İHA'ların sadece uçuş davranışlarını değil, aynı zamanda görev planlaması ve koordinasyonu gibi karmaşık süreçleri de öğrenebilmesi açısından büyük bir potansiyeli vardır. Bu teknoloji, özellikle arama-kurtarma, haritalama, izleme gibi görevlerde, daha güvenli ve verimli otonom İHA sistemlerinin geliştirilmesini sağlayabilir. Literatürdeki çalışmalar incelendiğinde, öncelikle rota planlama (path planning) alanında yapılan araştırmalara odaklanılmıştır. Bu alanda İnsansız Hava Aracı Sistemleri (İHS) gibi otonom sistemlerin etkin çözümler sunmada derin pekiştirmeli öğrenme temelli yaklaşımlar sayesinde başarılı çıktılar sunduğu görülmektedir (Bayerlein ve diğ., 2021; Maw ve diğ., 2021; Theile ve diğ., 2021; Westheider ve diğ., 2023). Rota planlama konusundaki başarımlar, araştırmacılara görev atama problemine de uygun çözümler sunabilmek amacıyla derin pekiştirmeli öğrenme yaklaşımlarının uygulanmasını mümkün kılmıştır.

Zuo ve arkadaşları tarafından sunulan çalışmada (Zuo ve diğ., 2022) , büyük ölçekte İHA kümeleri için görev planlamasında yeni bir yöntem önerilmiştir. Burada, dinamik bilgi takviye öğrenmesi (Dynamic Information Reinforcement Learning - DIRM) ve basit dikkat modeli (Simple Attention Model - SAM) hibritlenerek geliştirilen DIRM-SAM, yüksek boyutlu küme bilgilerini hızlıca işlemekte ve dinamik görev ortamlarında model dayanıklılığını artırmaktadır. Gerçekleştirilen simülasyonlar, yöntemin saniyeler içinde uygulanabilir çözümler sunduğunu ve büyük ölçekli planlama problemlerinde başarılı bir şekilde uygulandığını göstermektedir.

Diğer bir çalışmada Jung ve Oh, İHA için heterojen görev planlaması sağlayan derin öğrenme tabanlı bir algoritma önermiştir. Görev planlama problemi, bir VRP olarak formüle edilmiş ve dikkat tabanlı derin takviye öğrenme yaklaşımıyla çözüm üretilmeye çalışılmıştır. Burada, heterojen görevler için birleşik özellik temsili kullanılarak görev türleri aynı boyutlu vektörlere kodlanmıştır. Ayrıca, İHA'nın kaynak kısıtlamalarını (örneğin uçuş süresi) göz önünde bulundurmak için maskeleme stratejisi uygulanmıştır. Simülasyon sonuçları, önerilen algoritmanın diğer temel yaklaşımlara göre daha kısa sürede çözümler sunduğunu ve uygun bir performans sağladığını göstermektedir. Bu makalede hava koşulları ve çoklu İHA'larla çalışmalar yapılmasına da vurgu yapılmıştır (Jung ve Oh, 2022).

“Deep Reinforcement Learning for UAV Intelligent Mission Planning” isimli çalışmada ise kapsamlı bir analiz yapılmış ve derinlemesine değerlendirmeler sunulmuştur. Burada, İHA'ların otonom görev planlaması için DRL tabanlı bir yeni yöntem önerilmektedir. Önerilen

politika optimizasyonu (Proximal Policy Optimization - PPO) temelli yaklaşımla, düşman hava savunması (Suppression of Enemy Air Defense - SEAD) odaklı planlama modeli geliştirilmiş ve öğrenme performansını artırmak için üç eğitim stratejisi (alan rastgeleleştirme, politika entropisi maksimize etme ve ağ parametre paylaşımı) eklenmiştir. Test sonuçları, modelin verimli ve stabil çıktılar sunduğunu ve yüksek boyutlu ortamlara uyum sağlayabildiğini göstermektedir (Yue ve diğ., 2022).

İHA görev planlamasında literatüre sunulan diğer bir çalışmada, derin pekiştirmeli öğrenme kullanılarak İHA'ları barındıran bir sürü modeli için çok hedefli görev planlaması üzerine yenilikçi bir yaklaşım sunulmuştur. Bu yaklaşım da Yu ve arkadaşları; problem tanımlaması, durum ve eylem alanı tasarımı, ödül fonksiyonu yapılandırması, hava araçları modelinin formülasyonu ve çoklu hedefli optimizasyon stratejilerinin oluşturulmasını incelemişlerdir. Burada, görev dağılımı ve yol planlama gibi alt problemleri de ele alır. Gerçekleştirilen deneyler, önerilen modelin geleneksel yöntemlerden daha hızlı görev tamamlama ve daha verimli uçuş mesafesi sağladığını göstermektedir. Ancak, yazarlar büyük veri gereksinimleri, farklı koşullarda testler gerçekleştirme ve gerçek zamanlı planlamadaki aksilikler gibi sınırlamalara daha fazla odaklanılması gerektiğini vurgulamışlardır. Buna göre gelecekteki çalışmalar, önerilen modelin daha karmaşık kısıtlarda optimize edilmesine odaklanabilir. Bu tür çıkarımlar, tez çalışmalarına kaynak oluşturulması açısından değerli çıktılar sunmaktadır (Yu ve Dingcheng, 2023).

Çoklu ajan problemlerinin gelişimiyle birlikte, çoklu amaçlı optimizasyon problemlerini çözmek için RL ve Pareto'nun birleşimi de incelenmiştir. Geleneksel derin RL yöntemleri, sınır ağlarını tek bir toplam ödülü maksimize etmek için eğitir. Bir gelişme olarak, Çoklu Amaçlı Derin Pekiştirmeli Öğrenme (Multi-Objective Deep Reinforcement Learning-MODRL) algoritmaları, farklı ödül fonksiyonları kullanarak aynı ortam bilgisini paylaşarak eş zamanlı olarak birden çok politikayı eğitir. Sullivan ve arkadaşları, çoklu amaçlı bir çözüm uzayına sahip bir paylaşılan ortamda PPO temelli bir MODRL algoritması tasarladılar. Farklı ödül fonksiyonları kullanan politikalar birbirlerinden de öğrenebilir, bu da daha istikrarlı ve verimli bir eğitim dönemine yol açabilir (Sullivan ve Bosanac, 2020). Ancak, simülasyon ortamı ile gerçek dünya arasındaki fark, genelleme yeteneği ve sağlamlık için daha yüksek gereksinimler ortaya koyar ve RL'nin performans odaklı felsefesi ile uygulama odaklı istikrarın nasıl uzlaştırılacağı hala açık bir sorudur (Buşoniu ve diğ., 2018).

Bazı durumlarda aranan çözüm, çeşitlilikten dolayı Pareto dominant çözümün işe yaramadığı seyrek bir bölgede bulunabilmektedir (Liu ve diğ., 2018). Çok amaçlı optimizasyonda bu problemi aşmak için Q-öğrenme önerilmiştir. Orijinal görev kümesinin önceliklendirilmesini basitleştirmek için Q-öğrenme tanıtılmış ve geleneksel Pareto algoritmasını geliştirmek için modifiye edilmiş kayma tabanlı yoğunluk tahmini yöntemi kullanılmıştır (Li ve diğ., 2021). Gao ve arkadaşları, işbirlikçi algılama tespitinde görev zamanlaması ve rota planlaması için derin RL kullanmışlardır (Gao ve diğ., 2022). Luo, kapsamlı bir ödül fonksiyonu tasarlayarak, derin RL ile düşman füze-hedef atama için veri tabanlı bir politika optimizasyonu önerdi. Öğrenilen politikayla, veri tabanından alınan bilgilerle düşman ortamında füzelerin penetrasyonunun içsel olarak modellenemediği savunulmaktadır (Luo ve diğ., 2021).

Son yıllarda KTP çerçevesi RL ve çok-etmenli RL (Multi Agent Reinforcement Learning MARL) ile birleştirilerek farklı senaryolara uyarlanmıştır. Örneğin Kong ve arkadaşları (Kong ve diğ., 2024), dinamik çoklu engel ortamında eşzamanlı hedef atama ve rota planlama problemini kısmi gözlemlenebilen MDP (Partially Observable Markov Decision Process – POMDP) temelli derin pekiştirmeli öğrenme (Twin Delayed Deep Deterministic Policy Gradient - TD3) ile çözmüş, çarpışmama ve tam atama kısıtlarını ödül fonksiyonları üzerinden sağlamıştır. Vashisth ve arkadaşları (Vashisth ve diğ., 2024) ile Westheider ve arkadaşları (Westheider ve diğ., 2023), çok-etmenli görev atama ve rota planlamada merkezi eğitim-yerel yürütme (Centralized Training with Decentralized Execution - CTDE) yaklaşımını, grafik sinir ağları (Graph Neural Network - GNN) ile destekleyerek ölçeklenebilir ve iletişim kısıtlarına dayanıklı çözümler önermiştir.

Buna ek olarak, sinir ağları tabanlı yöntemlerde C51 (Categorical Deep Q- Network- DQN) veya Dueling (ikili) -DQN mimarisi ile iletişimsiz ortamlarda dahi her bir İHA'nın kendi gözlemlerine dayanarak rota planlayabildiği modeller geliştirilmiştir (Xu ve diğ., 2023). Hibrit meta-sezgisel yöntemlerde ise, MPSO, Yapay Arı Kolonisi (Artificial Bee Colony - ABC), ACO gibi algoritmaların KTP çerçevesinde kısıt işleme teknikleriyle (ceza fonksiyonları, iki aşamalı onarım mekanizmaları) entegre edildiği çalışmalar artmaktadır.

Bu eğilimler, KTP tabanlı görev atamanın yalnızca klasik MOGA veya tamsayı programlama ile değil, derin öğrenme, çok-etmenli öğrenme, grafik sinir ağları ve meta-sezgisel hibrit yaklaşımlar ile de zenginleştirildiğini ve özellikle 2023–2025 döneminde dinamik yeniden atama, eşzamanlı varış, hava sahası dekonflikasyonu yani İHA Trafik Yönetim Sistemlerine Uyum

(Unmanned Aircraft System Traffic Management – UTM) gibi ek kısıtların modele dahil edildiğini göstermektedir.

2.5. Kısıt Tatmin Problemi Modeli Tabanlı Görev Atama

KTP modelinin çoklu İHA görev atama problemine uyarlanması kapsamında kısıtları tanımlamak ve arasındaki ilişkileri doğru belirlemek önemlidir. Literatürde kısıtların farklı şekillerde sınıflandırıldığı görülmüştür (Mohsan SAH, 2022; Song J, 2023). Burada çözülmek istenen problem, eldeki kaynakların belirlenen görevler için kısıtları tatmin eden en optimize seçeneği sunmaktır. Optimizasyon amaçları ise ihtiyaca göre maliyet, risk ya da zaman etkinliğini sağlamak olabilecektir. Temelde görev atama “kısıt içeren kombinasyonel optimizasyon problemi”dir. Kısıt, çok ve büyük ölçekli olan problemler için zaman karmaşıklığı kabul edilemeyecek bir noktaya vardığı için NP-Zor (Non-deterministic Polynomial-time -NP-Hard) olarak tanımlanmaktadır (Wang, 2023).

Son 10 yıldır İHA görev planlamanın kısıt tatmin problemi temelli modellemesi hakkında birkaç yayın mevcuttur. Literatürdeki ilk KTP temelli çalışmalardan birinin 1968 yılında minimum yol maliyetini bulmak üzere önerildiği bilinmektedir (P. E. Hart, 1968). Benzer şekilde çalışmaların 20 yıl sonra artmaya başladığı görülmektedir (Fargier, 1993; WALLACE ve FREUDER, 1998).

KTP’nin özellikle İHA atama problemlerinde uygulanma yöntemleri incelenmiştir. Ayvaz ve arkadaşları yaptıkları çalışmada İHA görev atama problemini KTP yöntemine göre modelleyerek geliştirmiştir (Ayvaz ve diğ., 2025a). Çalışmada her göreve en etkin olabilecek İHA’nın seçilimi yönünde kabiliyetler eklenmesinin yanı sıra görevden dönen henüz havadaki İHA’lara iniş yapmadan bir sonraki görevi gidebilme yeteneği kazandırılarak toplam yakıt tüketimi ve süre azaltılmıştır. Sonrasında bu yeteneğin ardışıl görevlerin tümünde kullanılabilmesi için hibrit yöntemler kullanarak çalışmayı bir ileri noktaya taşımışlardır (Ayvaz ve diğ., 2025b). Ramirez ve arkadaşları, basit bir KTP modeli ile İHA’lara başarılı bir şekilde görev ataması yapılabileceğini göstermişlerdir (C. Ramirez-Atencia, 2014). Sonrasında MOGA ile KTP’nin başarılı bir şekilde hibritlendiğine dair çalışma önermişlerdir (Ramirez-Atencia, 2015). Hemen arkasından yakıt maliyeti, uçuş süresi ve uçak sayısı minimizasyonu yapmak için B&B yöntemiyle bir optimizasyon fonksiyonu geliştirmişlerdir, sonrasında ise çok amaçlı bir uygunluk fonksiyonu için MOGA kullanan çalışmalar yapmışlardır (Atencia ve diğ., 2019; Ramirez-Atencia, 2015).


3. PROBLEMİN TANIMI

Görev planlama problemi, NP-Zor sınıfta yer alan zorlu bir optimizasyon problemidir. Klasik grafik arama ve mantık tabanlı algoritmalar, bu problem için yetersiz kalmaktadır. Aşırı hesaplama gerektiren bu tip problemler, optimizasyon zorlukları nedeniyle etkin algoritmalar gerektirmektedir (Cabreira ve diğ., 2019). İHA görev planlamasında, yönlendirme (guidance), seyir (navigation) ve kontrol (control) olmak üzere üç ana bileşeni ve ilişkileri Şekil 3.1’de sunulmuştur. Bu çalışma, İHS’nin yönlendirme bileşenine odaklanmakta ve “görev planlama” ile “rota planlama” süreçlerini incelemektedir.

- Görev Atama: Görevlerin uygun İHA’lara atanmasını sağlar.
- Rota Planlama: Atanan görevlerin fiziksel olarak nasıl gerçekleştirileceğini tanımlar.

Rota planlama süreci iki alt bileşeni kapsamaktadır:

- Yol Planlama: Engellerden kaçınma, akıcılık ve yakıt verimliliği gibi kriterleri optimize ederek en iyi rotayı belirler.
- Güzergâh Planlama: Belirlenen rota üzerinde hız, irtifa, manevra ve zamanlama gibi detayları optimize eder.



Şekil 3.1. Görev planlamada yönlendirme ve alt bileşenleri

Bu çalışmada, görev tahsisi ve rota planlama süreçleri bütünleşik bir yaklaşımla ele alınmıştır. Görev atama, yol planlama sırasında tanımlanan kısıtlar dikkate alınarak gerçekleştirilmiştir. Bu kısıtlar şunları içermektedir:

- Görevin İHA’ya göre konumu,

- Başlama zamanı ve süresi,
- Görev alanına yakın havaalanları,
- Bir sonraki görevle olan zamansal ve mekânsal ilişkiler.

Varsayımlar: Rota planlama ve güzergâh planlama süreçleri aşağıdaki varsayımlar altında modellenmiştir:

- Yer Kontrol İstasyonlarının (YKİ) İHA'larla sürekli iletişimde olduğu,
- Fiziksel veya meteorolojik engellerin bulunmadığı,
- İHA'nın hızı, faydalı yük veya dış etkenlerden bağımsız, üç farklı hız profiline sahip olduğu ve bu profillere göre yakıt tüketiminin hesaplandığı,
- İHA görev planlamasında insan faktörü (örneğin insan karar alma süreçleri, bilişsel yük) rolü ihmal farz edilmiştir.

Güzergâh planlama kapsamında, İHA'nın görev alanına gidişinin iki boyutlu düz bir rotada gerçekleştiği, planlanan görev için kuş uçuşu en kısa rotayı izlediği, görev sırasında ihtiyaç duyulan tüm manevraları (hız, irtifa değişimleri vb.) otonom bir şekilde gerçekleştirdiği kabul edilmiştir. Ayrıca, sinyal kesintisi veya olumsuz hava koşulları olmadığı varsayımları altında model sadeleştirilmiştir. İHA görev planlamasında insan faktörünün (ör. karar vericilerin reaksiyonları, bilişsel yük vb.) etkileri ihmal edilmiş; tüm kararların veriler temelinde tam otonom olarak alındığı düşünülmüştür. Bu varsayımlar, modelin analitik olarak incelenmesini kolaylaştırmak amacıyla kabul edilmiştir. İHA'ların yüksek otonomi seviyesinde çeşitli görevleri farklı uçuş kısıtları altında yerine getirmesi, toplam maliyetin veya riskin en aza indirilmesi hedefiyle ele alınmıştır.

Evrimsel ve sürü tabanlı algoritmalar (GA, PSO, ACO, NSGA-II/III) genel amaçlı arama gücü sunmakla birlikte, bu çalışmadaki havacılığa özgü sert kısıtların (zaman pencereleri, üs/iniş-kalkış, yakıt optimizasyonu) adil biçimde ele alınabilmesi için ceza katsayıları, onarım teknikleri veya kısıt-işleme tasarımlarıyla yeniden tanımlanmaları gerekir. Bu nedenle bu tezde, bir konseptin ispatı (proof-of-concept) kapsamına uygun olarak, (i) aynı kısıt-temelli model ailesi içinde ZKTP→İZKTP kıyası ve (ii) evrimsel onarım yaklaşımı AMYO→AMFR ile iç-aile kıyası ve son olarak İZKTP → AMFR kıyası gerçekleştirilmiştir. Evrimsel ve sürü temelli yöntemlerle geniş ölçekli, kısıt-eşleştirmeli karşılaştırma 'Gelecek Çalışma' bölümünde önerilmektedir.

3.1. Karşılaştırma Kapsamı ve Hipotezler

Karşılaştırmalar üç test seti üzerinde yürütülmüştür: (i) ZKTP↔İZKTP (n=9), (ii) AMYO↔AMFR (n=10), (iii) İZKTP↔AMFR (n=10). Toplam süre (dk) ve toplam yakıt (L) ölçütlerinin yanı sıra iniş-kalkış sayısı raporlanır. Hipotezler: H1—İZKTP, ZKTP’ye göre yakıt/süreyi iyileştirir; H2—AMFR, AMYO’ya göre iyileştirir; H3—İZKTP ve AMFR arasında anlamlı fark vardır.

İstatistiksel veri içeren çizelgeler de yer alan istatistikler, iki yöntemi aynı görevler üzerinde karşılaştırırken hem “fark var mı?” sorusunu hem de “farkın büyüklüğü/operasyonel anlamı nedir?” sorusunu birlikte yanıtlamak için seçilmiştir.

3.1.1. Kapsam

Bu çalışma üç test kümesi üzerinde yürütülmüştür: ZKTP ↔ İZKTP (Veri Seti Sayısı n=9), AMYO ↔ AMFR (n=10) ve İZKTP ↔ AMFR (n=10). Her kümede yöntemler, aynı görev setleri üzerinde karşılaştırılmış; böylece koşulların eşlenik olması sağlanmıştır. Raporlamada her test kendi içinde değerlendirilmiş, sonuçlar bölümler arası karışmayı önlemek için ilgili alt başlıklarda verilmiştir.

3.1.2. Ölçütler ve Gösterimler

Birincil ölçütler toplam süre (T, birim: dakika) ve toplam yakıt (F, birim: litre) olarak belirlenmiştir; iniş-kalkış sayısı (İ/K_S, birim: adet) ikincil/gösterge ölçüttür. Metin içinde “↓” daha az/daha iyi, “↑” daha çok/daha kötü yönünü belirtmek için yalnızca yorum kolaylığı amacıyla kullanılmıştır (T ve F için); yüzde değişimler gerektiğinde “Δ%” ile raporlanır. Tüm değerler ham birimlerinde sunulmuş, yorumlanabilirliği korumak için dönüştürme yapılmamıştır.

3.1.3. Hipotezler

Her test kümesinde T ve F için yönsüz (iki kuyruklu) hipotezler sınanır; anlamlılık düzeyi $\alpha=0.05$ ’tir. Sorulan temel soru, “iki yöntemin ortalama süre ve yakıt değerleri birbirinden farklı mı?” şeklindedir. Buna göre sıfır hipotezi (H0) ilgili ortalamaların eşitliği iken, alternatif hipotez (H1) ortalamalar arasında fark bulunduğunu ifade eder. Aynı yapı ZKTP–İZKTP, AMYO–AMFR ve İZKTP–AMFR için ayrı ayrı uygulanır; böylece her kıyasın sonucu doğrudan kendi verisi üzerinden yorumlanır.

3.1.4. Operasyon Önceliği ve Karar Kuralı

Performans değerlendirmesi tek boyutlu değildir; güvenlik/risk (iniş-kalkış sıklığı), ekonomi (yakıt) ve süre birlikte ele alınır. En iyi durum, $T\downarrow$, $\dot{I}/K_S\downarrow$ ve $F\downarrow$ olduğunda gerçekleşir. Kabul edilebilir bir takasta $T\uparrow$ olsa bile $\dot{I}/K_S\downarrow$ ve $F\downarrow$ ise süre artışı güvenlik ve yakıt kazanımları için tolere edilebilir. Tartışmalı durum, $T\downarrow$ olmasına karşın $\dot{I}/K_S\uparrow$ ve/veya $F\uparrow$ olduğunda ortaya çıkar; hız kazancı güvenlik/ekonomi kaybına değip değmediği ayrıca değerlendirilir. İstenmeyen durum ise $T\uparrow$ ile birlikte $\dot{I}/K_S\uparrow$ ve/veya $F\uparrow$ görüldüğünde söz konusudur. Bölüm 4'teki istatistiksel bulgular bu karar kuralı ışığında yorumlanacaktır (Kullanılan testler ve gerekçeleri için Bkz. 3.2).

3.2. İstatistiksel Analiz Planı

Bu çalışmada iki yöntem arasındaki ortalama farkları sınamak için birincil test olarak iki kuyruklu Welch t-testi kullanılmıştır. Welch, küçük örneklem ve/veya eşit olmayan varyans koşullarında klasik t-testine göre daha güvenilirdir; bu nedenle birincil karar ölçütü olarak seçilmiştir. Anlamlılık düzeyi $\alpha=0.05$ 'tir. Her test kümesinde iki birincil ölçüt bulunduğu (süre T, yakıt F), aynı test sayfasında elde edilen p-değerleri Holm–Bonferroni yöntemiyle düzeltilmiş; yorumlarda düzeltilmiş p esas alınmıştır. İstatistiksel anlamlılığın yanında farkın pratik önemini göstermek için Hedges' g etki büyüklüğü ve %95 güven aralığı raporlanmıştır. Raporlama standardı olarak her grup için n, ortalama, standart sapma ve %95 GA (dakika ve litre birimlerinde) verilmiştir; p-değerleri üç ondalıkla, $p<0.001$ biçiminde gösterilir. Görev setleri iki yöntem arasında birebir eşleştirilebiliyorsa bu bilgi çizelge de belirtilir; birincil analiz yine bağımsız iki örneklem varsayımındaki Welch testiyle sunulur, gerekirse eşleştirilmiş alternatifler ek olarak raporlanır.

Dağılım varsayımlarına duyarlılığı görmek için Mann–Whitney U testi sağlamlık kontrolü olarak iki kuyruklu biçimde uygulanmış ve p-değeri ayrıca verilmiştir. Bu test, ortalama yerine sıralamalar üzerinden karşılaştırma yaptığı için uç değer ve simetri ihlallerine karşı daha dayanıklıdır; Welch ile tutarlı sonuç beklenir, farklılık varsa yorumda belirtilir. Küçük örneklemde belirsizliği görünür kılmak amacıyla Bootstrap/Monte Carlo özeti de raporlanır: her karşılaştırmada mevcut koşu sonuçları gruplar içinde yeniden örneklenir (ör. 10 000 tekrar), ortalama farkın ($\Delta = \mu_B - \mu_A$) örneklem dağılımı elde edilir ve bootstrap %95 güven aralığı (yüzdelik temelli) verilir. Ek olarak, faydalı yönde “üstünlük olasılığı” (ör. T için $\mu_B < \mu_A$ veya

F için $\mu_B < \mu_A$ olasılığı) raporlanır. Bu yeniden örnekleme, algoritmayı yeniden koşturmayı temsil etmez; yalnızca mevcut sonuçların ölçüm/örnekleme belirsizliği altında ne kadar kararlı olduğunu gösterir. İstenirse tekrarlanabilirlik için rastgelelik değişkeni sabitlenir.

Veri kalitesi, her blokta “toplam satırı” ile “görev satırları toplamı” arasındaki uyumla kontrol edilmiştir (hedef bandı $\approx \pm\%0.25$); bu kontrol hesap/aktarım hatalarını yakalamaya yöneliktir ve performans yorumunu etkilemez. Eksik/aykırı değer bulunduğunda kaynak düzeyinde doğrulama yapılmış, veri girişi hatası olmadığı sürece değerler kapsamda tutulmuş ve sağlamlık testleriyle duyarlılık gösterilmiştir. Sonuçların yorumu, yalnızca istatistiksel farklara değil, Bölüm 3.1’de tanımlanan operasyonel karar kuralına (T, İ/K_S, F’nin birlikte değerlendirilmesine) göre yapılmıştır. Bu çalışma algoritmik karar değişimini simüle etmeyi amaçlamaz.

4. MATERYAL VE YÖNTEM

4.1. Veri Seti

Ramirez ve arkadaşlarının çalışmasından alınan sentetik veriler (C. Ramirez-Atencia, 2014), gerçek dünya problemine yakın senaryoları denemek amacıyla belirli değişikliklerle uyarlanmıştır. Sentetik veriler çizelgeler halinde bölüm 4.4'te "İZKTP Modeli Uygulaması" başlığı altında sunulmuştur. Uygulama geliştirmeye yönelik konum koordinatları, farklı özelliklerdeki faydalı yükler ve görevin yapılabilmesi için gereken faydalı yükler gibi yardımcı Çizelge verileri bölüm 4.4.1'de paylaşılmıştır.

4.2. Görev Planlamada ZKTP

Görev planlama problemi, Kısıt Tatmin Problemi (KTP) çerçevesinde, değişkenler, kısıtlar ve etki alanları olmak üzere üç temel bileşene ayrılarak modellenir. Bu çalışmada, değişkenler görevleri temsil ederken; etki alanı, görevlerin gerçekleştirilmesinden sorumlu İHA'ları kapsar. Görevlerin başarıyla tamamlanmasını etkileyen tüm parametreler ise kısıtlar olarak ele alınmıştır. Kısıtlar, çözüm uzayını daraltarak görev planlama sürecini optimize etmekte kritik bir rol oynar ve şu kategorilerde incelenir.

Derecelerine göre: Tekil (unary), ikili (binary) ve çok değişkenli (high-order).

Doğasına göre: Katı (hard), yumuşak (soft), statik (zamanla değişmeyen), dinamik (zamanla değişen), bağımlı ve bağımsız.

Kapsamına göre: Genel (global) ve yerel (local).

Zaman bağımlılığına göre: Zamansal (temporal) ve zamansal olmayan.

Bu sınıflandırmalar, kısıtların doğru bir şekilde modellenmesini ve çözüm algoritmalarının etkin çalışmasını sağlamak için gereklidir. Bu çalışmada kısıtlar iki ana gruba ayrılmıştır. Bunlar *Statik* ve *Dinamik* kısıtlardır.

Statik Kısıtlar: Görev irtifa aralığı, bölgeye giriş izni ve dahili görev yükü gibi görev seti süresince değişmeyen parametreler.

Dinamik Kısıtlar: Görev seti içerisinde zamanla değişebilen İHA'nın konumu, yakıt durumu ve görevi tamamlama süresi gibi değişkenler.

Statik ve dinamik kısıtlar ise İHA görev atama probleminde aşağıdaki kapsamda sınıflandırılabilir.

Zaman Kısıtları: İHA'ların belirli bir görev zaman dilimi içinde planlanması ve buna bağlı yakıt, konum gibi kısıtları beraberinde getirmesi, hava sahasının belirli saatlerde müsait olması gibi süreye bağlı dinamik kısıtlardır. Zamansal KTP (ZKTP) görevi başlatma veya bitirme zamanlarının, üst düzey operasyonel planlarla (örn. hava koridoru kullanım izinleri, hava trafik düzeni) uyumlu olması zorunluluğunu temsil eder.

Konum ve Yol Kısıtları: İHA'ların kalkış ve iniş noktaları, arada geçilmesi zorunlu rota veya görev noktaları (waypoints) gibi coğrafi kısıtlardır. Her bir İHA için belirlenmiş uçuş profili (maksimum menzil, uçuş yüksekliği, rota kısıtları) ve hava sahası kullanım izni (kontrollü bölgeler, yasaklı sahalar vb.) gibi kısıtları temsil eder. Konum, İHA'nın havadaki konumu ise zamana bağlı dinamik kısıt iken görev noktaları statik kısıttır.

Yakıt ve Bakım Kısıtları: İHA'ların her bir görev veya rota değişikliğinde kalan yakıt miktarına göre planlama yapılması; takviye, ikmal veya iniş gereksinimlerinin hesaba katılması dinamik kısıtlardır. Görev sonrasında veya belirli saatlerde yapılması gereken bakım faaliyetleri (teknik kontrol, sensör bakımı vb.) ise rutin faaliyet kapsamında statik kısıtlardır.

Beklenmedik Etkiler: Hava koşullarının aniden değişmesi, acil bir görev çağrısı, uçağın sistem arızası veya hava sahasında oluşabilecek yeni tehditlerin planı etkilemesi. Bu etkiler, karar zincirinin sürekli güncellenmesi gerekliliğini doğuran dinamik kısıtlardır. Böylesine dinamik bir süreçte en iyi sonucu bulmaktansa önce geçerli bir sonuç bulmak ve kalan süre zarfında bu çözümü iyileştirme yoluna gitmek makul bir seçenektir.

Burada kısıtlar, metasezgisel bir algoritmada çok amaçlı bir optimizasyon modeli ile amaç fonksiyonu olarak değerlendirilebilir. Benzer şekilde deterministik bir yaklaşımla ZKTP olarak önerilen model, Şekil 4.1'de gösterilen görev planlama sürecine uygun olarak iki aşamalı bir yöntemle gerçekleştirilebilmektedir.

ZKTP yaklaşımıyla ilk aşamada görevlerin irtifa aralığı, bölgeye giriş izni ve dahili görev yükü gibi statik kısıtlarına göre İHA'lar belirlenerek görevlerin etki alanı oluşturulur. Ardından görevin etki alanına giren İHA'lar o görev çifti özelinde konuma ve zamana bağlı dinamik kısıtlara (kalkış-görev-iniş) göre incelenerek etki alanı daraltılır.

İyileştirilmiş ZKTP'de ise artık zamansal komşuluğu olan ardışıl görevler zaman pencerelerine bölünerek modellenip, öncesinde görev verilmiş havadaki İHA'ların görevler arası zamana bağlı yakıt ve konum gibi dinamik kısıtlarını ardışıl tüm görevler için hesaplamaya uyumlu

hale getirilmektedir. Ardışıl görev çiftleri arasındaki dinamik kısıtlar (örneğin, yakıt ve konum gibi değişkenler) sırasıyla incelenir ve bu görevler için İHA'lerden en uygun olanı seçilir.


Önerilen matematiksel model, her bir İHA'nın performansını zamana bağlı yakıt tüketimi, görev başarısı ve konum uyumluluğu gibi kriterlere göre değerlendirerek baskın bir çözüm kümesi oluşturmayı amaçlamaktadır. Bu model, görev tamamlama süresini ve yakıt tüketimini minimize ederken çözüm kalitesini artırmakta ve operasyonel verimliliği iyileştirmektedir.

4.3. Görev Planlama için Materyal ve Önerilen Yöntemler

Çalışma kapsamında İZKTP yöntemi AMFR yöntemi ve bu yöntemin alt bileşenleri olan AMYO ve GZİ metotları detaylı olarak incelenmiştir. Bu kapsamda her yöntem için testler oluşturulmuş ve sonuçları incelenerek yorumlanmıştır. Kodun çalışma süresince oluşturduğu loglara göre İHA atama seçimlerinde nelere dikkat edildiği analiz edilebilmektedir.

4.3.1. İZKTP

Bu bölümde İZKTP'nin, ZKTP'den farklı olarak nasıl kurgulandığı ve ZKTP'nin Geri İzleme – Gİ (Backtracking -BT), İleri Kontrol – İK (Forward Checking - FC), Yay Tutarlılığı – YT (Arc Consistency - AC) ve Düğüm Tutarlılığı - DT (NC - Node Consistency) yöntemlerinin havacılık problemine nasıl uyarlandığı kapsamlı bir şekilde açıklanmaktadır. Model, görev planlama sürecindeki kısıtları optimize ederek İHA'ların en etkin şekilde atanmasını amaçlamaktadır. Önerilen modelin çalışabilmesi için tüm kısıtların, çözüm uzayını daraltacak şekilde iki değişkene (binary constraint) indirgenmesi gerekmektedir. Bu normalizasyon aşaması, değişkenlerin temel statik kısıtlarını karşılayan değerleri belirler ve etki alanını ilk kez daraltır. Sonraki aşamada, zamana bağlı konum ve yakıt gibi dinamik değişkenler hesaplanarak etki alanı son halini alır. Bu süreç, uygun atamaların yapılabilmesi için kontrol yöntemlerinin uygulanmasıyla tamamlanır. Bahsedilen süreçler Şekil 4.1' de gösterilen işlem sırasına göre detaylandırılmıştır.



Şekil 4.1. Önerilen görev planlama yaklaşımının temel adımları

İZKTP'nin zengin kısıt tanımlama yapısı, gerçekçi sahne kurgularında dahi fizibil çözümler üretebilmeyi kolaylaştırmaktadır.

Dinamik Etki Alanı Kontrolü: Dinamik kısıtlara göre etki alanı kontrol işlemi, öncesinde statik kısıtlar ile belirlenen etki alanını, zamana bağlı değişkenlik gösteren dinamik kısıtları (süre, konum, yakıt, durum) sağlayamayan İHA'ları tespit ederek daraltır. Göreve atanan her İHA zamanla konumu ve yakıtı değişiklik göstereceğinden ve bu durumun sonraki görevlere yetiştirme süresi, görevi yapabilirlik durumunu etkilediği için etki alanlarının havada görevli İHA'lar ya da görev sonrası başka bir havaalanına iniş yapmış olabileceği için yerdeki İHA'lar üzerindeki etkilerini yansıtmak için yürütülen bir süreçtir.

Düğüm Tutarlılığı – Node Consistency: İlk görevin atama sürecinde dinamik kısıtlar değişmediği için DT hesaplanmaz. Ancak, sonraki görevlerde aşağıda açıklaması yapılan İK ve

YT süreçlerinden elde edilen güncellemelerle, atama yapılacak düğümün kısıtları yeniden değerlendirilir. Etki alanının tutarlılığını gözden geçirmek için uygulanan bu süreçte havadaki İHA atamalarının son durumu değerlendirilir, güncel kısıtlar ile planlanan görevi yapamayacak olan İHA'lar etki alanından çıkarılır ya da yapabilecek duruma gelen İHA'lar etki alanına eklenir.

Geri İzleme – Backtracking: Gİ yöntemi, kısıtları sağlamak amacıyla önceki adımlara geri dönerek alternatif çözümler arar. Bu çalışmada ise Gİ, yalnızca kısıt tatmini sağlamak için değil, aynı zamanda en iyi çözümü bulmaya yönelik bir optimizasyon aracı olarak yeniden tasarlanmıştır. Görev atama sürecinde, mevcut görev için en uygun aday bulunamadığında, Gİ devreye girerek diğer olası çözümleri arar. Bu sayede, önerilen Gİ yöntemi, klasik ZKTP yaklaşımından farklı olarak, daha geniş bir perspektifle optimizasyon amacıyla kullanılmaktadır. Önemli bir yenilik olarak, en iyi adayın belirlenmesi sürecinde yapılan hesaplamalar bir sonraki görevi üstlenebilecek İHA'lar için de YT kapsamında kullanılmaktadır. Bu süreç, görevler arasında iniş yapmadan geçiş sağlayarak daha etkili bir optimizasyonla hem yakıt tüketimini hem de zaman kaybını minimize edebilmektedir.

Yay Tutarlılığı – Arc Consistency: YT yöntemi, görevler (değişkenler) arasındaki İHA'ların kısıtlarını kontrol ederek uyumsuz olan İHA'ları, etki alanından eler. Böylece, yalnızca kısıtları karşılayan İHA'ların etki alanında kalması sağlanır. Bu yaklaşım, YT'nin görevler arası havada geçiş için gerçek dünya görev planlamasına uyarlanmış bir versiyonudur. Böylece değişken çiftleri arasındaki kısıtların sağlanması için etki alanları daraltılır. Görev ataması sırasında bir önceki göreve atanan İHA mevcut görevin de etki alanının da ise İK loglarına bakılır, çakışma yoksa, yakıt kaynağı yeterli ise ve bu görevi de tamamlıyorsa bu göreve de planlanabilir. Değilse müdahale edilmez ve görev sonrası iniş planlandığı gibi gerçekleşir.

İleri kontrol – Forward Checking: Göreve atanan İHA seçiminin kesinleşmesi sonrası yeni görev verilen İHA'nın bilgileri güncellenir ve seçilen İHA'nın İK kapsamında sonraki değişkenler (görevler) üzerindeki etkilerine bakılır. Bir sonraki göreve atamaya uygun değilse o görevin etki alanından çıkarılır. Bir sonraki görev atamasına gelindiğinde ise DT kapsamında İK kayıtları incelenir. Eğer İHA zamansal anlamda çakışma yaratmıyor, yakıt yeterliliği sağlıyor ve bu görevi de tamamlayabiliyorsa, göreve havadayken atanabilir. Daha önceki görevlerden havada olan ancak iniş yapmamış İHA'larda bu yöntem ile sonraki görevlere planlanabilmektedir. Yeni atamaların ardından, İHA'nın bilgileri güncellenir ve İK kapsamında sonraki görevler üzerindeki etkileri

değerlendirilir. Eğer bir sonraki göreve İHA'nın atanması mümkün değilse, o görevin etki alanından çıkarılır ve son görevi sonrası en yakın havaalanına iniş yapmış olarak kaydedilir.

4.3.1.1. İZKTP'nin Sağladığı Avantajlar

Yukarıdaki yöntemler bir arada kullanılarak, görev geçişlerinin iniş yapmadan kesintisiz gerçekleştirilmesi ve kaynakların verimli kullanılması İyileştirilmiş ZKTP'nin sağladığı dikkate değer avantajlardandır. Buradaki dikkate değer husus, gerçek dünya problemlerinde ihtiyaç duyulan, havadaki İHA'ların sonraki görevlere atanma durumu KTP'deki İK ve YT yöntemlerinin hibritlenmesi ve dinamik programlamanın avantajı kullanılarak çözülmektedir. Böylece yeni hibrit model sadece bir sonraki görevin yapılabilirliğin kontrol etmek ile sınırlı tutulmayıp, havadaki İHA'ların kısıtları sağladığı ölçüde sonraki görevlerle de eşleşmesini sağlamaktadır. Başarılı bulunan aday atamalar, son olarak Karma Tamsayılı İkili Programlama (Mixed-Integer Quadratic Programming, MIQP) tabanlı çok amaçlı bir puanlama fonksiyonu ile değerlendirilir. Bu puanlama, görev atamalarının tüm görev kümesi kapsamında ne kadar başarılı yapıldığını sorgulamakta; DT, Gİ ve YT yöntemlerinin sağladığı iyileştirmelerle yerel optimumların engellenmesine çalışmaktadır. Puanlamada en yüksek skoru alan aday İHA, ilgili göreve nihai olarak atanır.

4.3.1.2. Ön Hazırlık Aşaması

Bu problemde, görevler dizisi $\mathcal{T} \doteq \{T_1, T_2, \dots, T_t\}$ 'nin, İHA'lar dizisi olan $\mathcal{U} \doteq \{U_1, U_2, \dots, U_u\}$ filo tarafından gerçekleştirilmesi beklenir. Ayrıca hava üsleri $\mathcal{A} \doteq \{Ab_1, Ab_2, \dots, Ab_a\}$ olarak temsil edilmiştir. Burada temel amaç görev atama ve bu kapsamda incelenen kısıtlardır. Nihayetinde ulaşılmak istenen hedef $A_{\mathcal{T}}[T_t, U_u] = 1$ 'dir. Burada T_t görevine, U_u İHA'sı atanmıştır.

Zamansal Kısıt (Temporal Constraint): Her görev için atanan İHA zamanında göreve yetişebilmeli, görevin ifasıyla tekrar kalktığı yere inebilmelidir. Denklem (4.1)'deki görev başlangıç zamanı $BaşlaT_{\mathcal{T}}[T_t, U_u]$, kalkış zamanı $KalkışT_{\mathcal{T}}$ ve göreve gidiş için geçen süre $GidişSüresi_{\mathcal{T}}$ toplamına eşit olmalıdır. Benzer şekilde Denklem (4.2)'deki görev bitiş zamanı $BitişT_{\mathcal{T}}$, görev başlangıç zamanı $BaşlaT_{\mathcal{T}}$ ve görev süresi $GörevSüresi_{\mathcal{T}}$ toplamına eşit olmalıdır.

$$\forall T_t \in \mathcal{T} \wedge \forall U_u \in \mathcal{U} \quad \Longrightarrow$$

$$BaşlaT_{\mathcal{T}}[T_t, U_u] = KalkışT_{\mathcal{T}}[T_t, U_u] + GidişSüresi_{\mathcal{T}}[T_t, U_u] \quad (4.1)$$

$$BitişT_{\mathcal{T}}[T_t, U_u] = BaşlaT_{\mathcal{T}}[T_t, U_u] + GörevSüresi_{\mathcal{T}}[T_t, U_u]$$

Göreve giderken geçen süre $GidişSüresi_{u \rightarrow t}$, kastedilen mesafe $Mesafe_{u \rightarrow t}$ 'nin, profile belirlenen en yüksek hızı temsil eden $Hız_{u,max}$ 'a bölünmesiyle Denklem (4.3)'deki gibi bulunur. Hava üssünden kalkan veya önceki görevden dönüşte havadayken atanan İHA'lar olabilmektedir. Konumlar dinamik olarak hesaplanır.

$$\forall T_t \in \mathcal{T} \wedge \forall U_u \in \mathcal{U} \quad \Longrightarrow \quad GidişSüresi_{u \rightarrow t} = \frac{Mesafe_{u \rightarrow t}}{Hız_{u,max}} \quad (4.3)$$

Görev süresinin tamamlanması sonrası İHA u'nun $DönüşSüresi_{t \rightarrow u}$, en yakın üsse (Ab_a) dönüş mesafesinin $Mesafe_{t \rightarrow a}$ seçilen uçuş profilinde belirlenen hıza bölünmesiyle Denklem (4.4)'deki gibi bulunur.

$$\forall T_t \in \mathcal{T} \wedge \forall U_u \in \mathcal{U} \quad \Longrightarrow \quad DönüşSüresi_{t \rightarrow u} = \frac{Mesafe_{t \rightarrow a}}{Hız_{u,max}} \quad (4.4)$$

Atanan İHA'ların görevlere zamanında ulaşabilmesi için gidiş geliş güzergâhları ve hızları önem taşımaktadır. Hesaplamalar İHA'nın gidiş ve geliş sürecini en yüksek hızlarda tamamlayacak şekilde yapılmakta, görev sırasında ise ortalama hız uygulanmaktadır.

İrtifa Kısıtı (Altitude Constraint): İHA'nın göreve atanabilmesi için çıkabileceği irtifa aralığı $İrtifaAralığı[U_u]$, görevin irtifa aralığı $İrtifaAralığı[T_t]$ 'ni Denklem (4.5)'de ifade edildiği gibi kapsamalıdır.

$$\forall T_t \in \mathcal{T} \wedge \forall U_u \in \mathcal{U} \quad İrtifaAralığı_{\mathcal{T}}[T_t, U_u] \rightarrow İrtifaAralığı[T_t] \supseteq İrtifaAralığı[U_u] \quad (4.5)$$

Sensör Kısıtı (Sensor Constraint): Denklem (4.6)'da İHA, göreve atanabilmesi için uygun faydalı yüklere (sensörlere) sahip olduğunu garanti etmelidir. İHA u'nun sahip olduğu sensörleri

ifade eden $IHASensör[U_u]$, görevin gerektirdiği sensörleri ifade eden $GörevSensör[T_t]$ 'i sağlamalıdır;

$$\forall T_t \in \mathcal{T} \wedge \forall U_u \in \mathcal{U} \implies \begin{aligned} &FaydalıYük_{\mathcal{T}}[T_t, U_u] \rightarrow GörevSensör[T_t] \\ &\quad \sqsubseteq IHASensör[U_u] \end{aligned} \quad (4.6)$$

Yetkilendirme Kısıtı (Permission Constraint): İHA'nın atanabilmesi için giriş izni ifadesi $Girişİzni[U_u]$, görev yetki ifadesi $GörevYetki[T_t]$ ile Denklem (4.7)'de görüldüğü üzere örtüşmelidir.

$$\forall T_t \in \mathcal{T} \wedge \forall U_u \in \mathcal{U} \implies \begin{aligned} &GörevYetkilendirme_{\mathcal{T}}[T_t, U_u] \rightarrow GörevYetki[T_t] \\ &\quad = Girişİzni[U_u] \end{aligned} \quad (4.7)$$

Yakıt Kısıtı (Fuel Constraint): Her görev için atanan uçağın toplam yakıtı $ToplamYakıt_{\mathcal{T}}$; göreve gidişi $GidişYakıt_{\mathcal{T}}$, görev bekleme $GörevBeklerYakıt_{\mathcal{T}}$, görev $GörevYakıt_{\mathcal{T}}$ ve görev sonrası dönüş $DönüşYakıt_{\mathcal{T}}$ yetecek miktarda, Denklem (4.8)'de ifade edildiği gibi olmalıdır. İHA'lar göreve hava üssünden kalkarak ya da önceki görevinden henüz inmeden de göreve gidilebilmektedir.

$$\forall T_t \in \mathcal{T} \wedge \forall U_u \in \mathcal{U} \implies \begin{aligned} ToplamYakıt_{\mathcal{T}}[T_t, U_u] = &GidişYakıt_{\mathcal{T}}[T_t, U_u] + GörevBeklerYakıt_{\mathcal{T}}[T_t, U_u] \\ &+ GörevYakıt_{\mathcal{T}}[T_t, U_u] + DönüşYakıt_{\mathcal{T}}[T_t, U_u] \end{aligned} \quad (4.8)$$

Göreve giderken ki yakıt tüketimi $GidişYakıt_{\mathcal{T}}[T_t, U_u]$ hesaplanır. Bunun için Denklem (4.9)'da gösterildiği gibi İHA u ile görev arasındaki mesafeyi temsil eden $d_{u \rightarrow t}$ ve İHA u'nun yakıt tüketim oranı $YakıtTüketimOran_u$ çarpılır.

$$\forall T_t \in \mathcal{T} \wedge \forall U_u \in \mathcal{U} \implies GidişYakıt_{\mathcal{T}}[T_t, U_u] = d_{u \rightarrow t} \times YakıtTüketimOran_u \quad (4.9)$$

Denklem (4.10)'daki $Yakıt_{\mathcal{T}}[T_t, U_u]$, İHA'nın görevi icra ettiği sürece harcadığı yakıtın hesaplanması işlemini tarif eder. Bunun için $GörevSüresi_u$, uçuş profiline bağlı $Hız_t$ ve İHA yakıt tüketim oranı $YakıtTüketimOran_u$ çarpılır.

$$\forall T_t \in \mathcal{T} \wedge \forall U_u \in \mathcal{U} \implies Yakıt_{\mathcal{T}}[T_t, U_u] = GörevSüresi_u \times Hız_t \times YakıtTüketimOran_u \quad (4.10)$$

Denklem (4.11)'de dönüşte harcanan yakıt $DönüşYakıt_{\mathcal{T}}[T_t, U_u]$ hesaplanır. Bunun için görev bitimi en yakın hava üssü ile mesafeyi tarif eden $Mesafe_{t \rightarrow a}$ ile İHA'nın yakıt tüketimini ifade eden $YakıtTüketimOran_u$ ile çarpılır.

$$\forall T_t \in \mathcal{T} \wedge \forall U_u \in \mathcal{U} \implies DönüşYakıt[T_t, U_u] = Mesafe_{t \rightarrow a} \times YakıtTüketimOran_u \quad (4.11)$$

4.3.1.3. İZKTP Modelinin Oluşturulması

İlk aşamayı geçen İHA'ların hangi görevleri yerine getirebileceği belirlenerek görevlerin etki alanları kısmen netleşir. İkinci aşama olan İZKTP, ardışıl görev ikililerinin (binary constraints) zaman pencereleri kapsamındaki dinamik kısıtlarla yeniden değerlendirilmesini içerir. Bu aşamada, görevler arasındaki zamansal ilişkilendirme yapılır ve şu kısıtlar dikkate alınır: havada bekleme (loiter) süresi, göreve gidiş güzergahı, yakıt durumu ve zamana bağlı diğer parametreler. Havada bulunan İHA'ların sonraki görevlere atanabilmesi için, görevlerin güncel etki alanında yer alması, süre bakımından göreve yetişebilmesi ve yakıt miktarının görev sonrası en yakın havaalanına inişe yetmesi gibi kısıtların sağlanması gerekmektedir. Bu nedenle, tamamlanan her görev sonrası bir sonraki görevin etki alanı güncellenir (DT kontrolü). Yeni görevin etki alanındaki tüm İHA'ların (havada olanlar dahil) görevi yerine getirebilme durumu yeniden değerlendirilir. Bu değerlendirme, yerde olan İHA'lar ile halihazırda havada olan İHA'lar için iki farklı şekilde gerçekleştirilir; yerde olan İHA'larda, İHA'nın mevcut konumundan sıradaki göreve yakıt açısından ulaşabilmesi, Denklem (4.12)'de gösterildiği gibi kontrol edilir.

Buna göre $GidişYakıt_T$, $GörevBeklerYakıt_T$, $GörevYakıt_T$ ve $DönüşYakıt_T$ toplamı $İlkYakıt_T$ ' den büyük olamaz. Havada olan İHA'larda ise görev sonrası iniş durumu ve yakıt gereksinimleri dikkate alınarak, mevcut görevden sonraki görevi tamamlama durumu hesaplanır.

$$\forall T_t \in \mathcal{T} \wedge \forall U_u \in \mathcal{U} \implies GidişYakıt_T[T_{t+1}, U_u] + GörevBeklerYakıt_T[T_{t+1}, U_u] + GörevYakıt_T[T_{t+1}, U_u] + DönüşYakıt_T[T_{t+1}, U_u] < İlkYakıt_T[T_t, U_u] \quad (4.12)$$

Buna göre Denklem (4.13)'de sunulan görev ikililerinde bir sonraki görevin başlangıç zamanı ifadesi $BaşlaT_T[T_{t+1}, U_u]$, önceki görevin bitiş zamanını ifade eden $BitişT_T[T_t, U_u]$ ve yeni göreve gidiş süresini ifade eden $GidişSüresi_T[T_{t+1}, U_u]$ 'in toplamından büyük olamaz. Böylece zamansal anlamda çakışan iki farklı göreve aynı uçağın atanma durumu önlenabilir. Hem havadan hem yerden planlanan İHA içinde aynı yöntem kullanılır.

$$\forall T_t \in \mathcal{T} \wedge \forall U_u \in \mathcal{U} \implies BaşlaT_T[T_{t+1}, U_u] \geq BitişT_T[T_t, U_u] + GidişSüresi_T[T_{t+1}, U_u] \quad (4.13)$$

Fakat bir sonraki göreve de aynı İHA atanabilirse ve havada bekleme süresi oluşursa $GörevBeklerSüresi_{\tau}[T_{t+1}, U_u]$ bu süre Denklem (4.14)'de sunulduğu şekilde hesaplanır.

$$\forall T_t \in \tau \wedge \forall U_u \in U \quad \Longrightarrow$$

$$GörevBeklerSüresi_{\tau}[T_{t+1}, U_u] = BaşlaT_{\tau}[T_{t+1}, U_u] - (BitişT_{\tau}[T_t, U_u] + GidişSüresi_{\tau}[T_{t+1}, U_u]) \quad (4.14)$$

Üs'ten kalkış yapan İHA'ların (U_u) havada bekleme süresinin (loiter) $GörevBeklerSüresi_{\tau}[T_{t+1}, U_u]$ 'nin sıfır olduğu Denklem (4.15)'de ifade edilmiştir.

$$\forall T_t \in \tau \wedge \forall U_u \in U \wedge \forall U_{u'} \in U \quad \Longrightarrow \quad GörevBeklerSüresi_{\tau}[T_{t+1}, U_{u'}] = 0 \quad (4.15)$$

Bu durumda görev ikilileri arası şartlar sağlanırsa Denklem (4.16)'da ifade edildiği gibi aynı İHA ile her iki görevi de tamamlayabilir ya da Denklem (4.17)'deki gibi sonraki göreve aynı İHA atanamaz ve farklı İHA atanması gerekir.

$$\forall T_t \in \tau \wedge \forall U_u \in U \quad \Longrightarrow \quad AynıİHA[T_t, T_{t+1}] \rightarrow A_{\tau}[T_t, U_u] = A_{\tau}[T_{t+1}, U_{u'}] \quad (4.16)$$

$$FarklıİHA[T_t, T_{t+1}] \rightarrow A_{\tau}[T_t, U_u] \neq A_{\tau}[T_{t+1}, U_{u'}] \quad (4.17)$$

Görev ikililerinde aynı İHA'nın atandığı durumlarda karşılaşılan zamansal süreçler Allen'ın Zaman Aralıkları Cebiri ile ilişkilendirilebilir (JF, 1983). Burada kullanılan “m-meets” bir görev biterken diğerinin başladığını, “o-overlaps” görevlerin üst üste çakışan kısımları olduğunu, “s-start” görevlerin beraber başladığını, “d-during” görevlerden birinin diğer görev süresi içerisinde başlayıp bittiğini, “e-equals” görevlerin başlangıç ve bitişlerinin eşit olduğunu, “f-finish” ise görevlerin beraber bittiğini ifade eder. Bu kapsamda $A_{\tau}[T_t, U_u] = A_{\tau}[T_{t+1}, U_u] = 1$ olduğu durumlar için Allen'ın cebirine göre zamansal çakışmalar her görev için Denklem (4.18-4.24)'de ifade edilen şekilde incelenir.

$$\forall T_t \in \mathcal{T} \wedge \forall U_u \in \mathcal{U} \implies$$

$$T_t < T_{t+1} \rightarrow \left. \vphantom{\begin{matrix} T_t < T_{t+1} \end{matrix}} \right\} \text{Bitiş}T_{\mathcal{T}}[T_t, U_u] \leq \text{Başla}T_{\mathcal{T}}[T_{t+1}, U_u], \quad (4.18)$$

$$T_t \text{ m } T_{t+1} \left. \vphantom{\begin{matrix} T_t \text{ m } T_{t+1} \end{matrix}} \right\} \text{Bitiş}T_{\mathcal{T}}[T_t, U_u] = \text{Başla}T_{\mathcal{T}}[T_{t+1}, U_u], \quad (4.19)$$

$$T_t \text{ o } T_{t+1} \rightarrow \left. \vphantom{\begin{matrix} T_t \text{ o } T_{t+1} \end{matrix}} \right\} \begin{aligned} &\text{Başla}T_{\mathcal{T}}[T_t, U_u] \leq \text{Bitiş}T_{\mathcal{T}}[T_{t+1}, U_u], \\ &\text{Bitiş}T_{\mathcal{T}}[T_t, U_u] \leq \text{Bitiş}T_{\mathcal{T}}[T_{t+1}, U_u], \\ &\text{Başla}T_{\mathcal{T}}[T_t, U_u] = \text{Başla}T_{\mathcal{T}}[T_{t+1}, U_u], \end{aligned} \quad (4.20)$$

$$T_t \text{ s } T_{t+1} \rightarrow \left. \vphantom{\begin{matrix} T_t \text{ s } T_{t+1} \end{matrix}} \right\} \begin{aligned} &\text{Başla}T_{\mathcal{T}}[T_t, U_u] = \text{Başla}T_{\mathcal{T}}[T_{t+1}, U_u], \\ &\text{Başla}T_{\mathcal{T}}[T_t, U_u] \leq \text{Bitiş}T_{\mathcal{T}}[T_{t+1}, U_u], \end{aligned} \quad (4.21)$$

$$T_t \text{ d } T_{t+1} \rightarrow \left. \vphantom{\begin{matrix} T_t \text{ d } T_{t+1} \end{matrix}} \right\} \begin{aligned} &\text{Başla}T_{\mathcal{T}}[T_t, U_u] \geq \text{Başla}T_{\mathcal{T}}[T_{t+1}, U_u] \\ &\text{Bitiş}T_{\mathcal{T}}[T_t, U_u] \leq \text{Bitiş}T_{\mathcal{T}}[T_{t+1}, U_u], \end{aligned} \quad (4.22)$$

$$T_t \text{ f } T_{t+1} \rightarrow \left. \vphantom{\begin{matrix} T_t \text{ f } T_{t+1} \end{matrix}} \right\} \begin{aligned} &\text{Başla}T_{\mathcal{T}}[T_t, U_u] \geq \text{Başla}T_{\mathcal{T}}[T_{t+1}, U_u] \\ &\text{Bitiş}T_{\mathcal{T}}[T_t, U_u] = \text{Bitiş}T_{\mathcal{T}}[T_{t+1}, U_u], \end{aligned} \quad (4.23)$$

$$T_t = T_{t+1} \rightarrow \left. \vphantom{\begin{matrix} T_t = T_{t+1} \end{matrix}} \right\} \begin{aligned} &\text{Başla}T_{\mathcal{T}}[T_t, U_u] \geq \text{Başla}T_{\mathcal{T}}[T_{t+1}, U_u] \\ &\text{Bitiş}T_{\mathcal{T}}[T_t, U_u] = \text{Bitiş}T_{\mathcal{T}}[T_{t+1}, U_u]. \end{aligned} \quad (4.24)$$

Görev atamasından sonra, atanan İHA'ların yakıt durumu ve konumları değiştiği için etki alanları yeniden düzenlenir. Bu durumda, görev ikilileri arasındaki kontroller yapılmadan önce, sıradaki görev için dinamik kısıtlar (yakıt, konum vb.) güncel duruma göre incelenir. Denklem (4.25-4.27)'de ifade edildiği üzere, güncel yakıt ve konum verileri kullanılarak görev etki alanı tekrar hesaplanır. Bu süreç, her görev için dinamik etki alanının güncellenmesini ve etki alanı tutarlılığının sağlanmasını mümkün kılar.

$$\forall T_t \in \mathcal{T} \wedge \forall U_u \in \mathcal{U} \implies$$

$$\text{GidişYakıt}_{\mathcal{T}}[T_t, U_u] = \text{Mesafe}_{u \rightarrow t} \times \text{YakıtTüketimOran}_u \quad (4.25)$$

$$\text{GörevYakıt}_{\mathcal{T}}[T_t, U_u] = \text{GörevSüresi}_u \times \text{Hız}_{u \rightarrow t} \times \text{YakıtTüketimOran}_u \quad (4.26)$$

$$\text{DönüşYakıt}_{\mathcal{T}}[T_t, U_u] = \text{Mesafe}_{u \rightarrow t} \times \text{YakıtTüketimOran}_u \quad (4.27)$$

Görev ikilileri arasında sensörler, giriş izni gibi değişmeyen tekil kısıtlar tekrar kontrol edilmez. Bunun yerine, yalnızca dinamik kısıtlar dikkate alınır. Özellikle, göreve gidiş, görev

sırasında bekleme, görev icrası ve ardından en yakın üssün belirlenerek İHA'nın inişi gibi süreçler, yakıt yeterliliği kısıtını sağlamak için değerlendirilir. Bu değerlendirme, göreve gidiş yakıtı $GidişYakıt_T$ üzerinden gerçekleştirilir. Örneğin, İHA u'nun bekleme süresi için harcanan yakıt $GörevBeklerYakıt_T$, görev sırasında tüketilen yakıt $GörevYakıt_T$ ve en yakın üsse iniş yakıtı $DönüşYakıt_T$ toplamı, İHA u'nun başlangıçtaki yakıt miktarı $İlkYakıt_T[T_t, U_u]$ ile karşılaştırılmalıdır. Bu toplamın, başlangıçtaki yakıt miktarından az olması gerekir. $Mesafe_{t+1 \rightarrow a}$ değişkeni, son görevinden en yakın hava üssüne iniş mesafesini temsil eder. T_{t+1} görevindeki toplam yakıt tüketiminin hesaplanması Denklem (4.28-4.32)'de sunulmuştur. Denklem (4.30)'daki $Hız_{u \rightarrow t+1}$ görev süresince yapılan hızı ifade etmektedir.

$$\forall T_t \in T \wedge \forall U_u \in U \quad \implies$$

$$GidişYakıt_T[T_{t+1}, U_u] = Mesafe_{u \rightarrow t+1} \times YakıtTüketimOran_u \quad (4.28)$$

$$GörevBeklerYakıt_T[T_{t+1}, U_u] = Mesafe_{t+1} \times YakıtTüketimOran_u \quad (4.29)$$

$$GörevYakıt_T[T_{t+1}, U_u] = GörevSüresi_u \times Hız_{u \rightarrow t+1} \times YakıtTüketimOran_u \quad (4.30)$$

$$DönüşYakıt_T[T_{t+1}, U_u] = Mesafe_{t+1 \rightarrow a} \times YakıtTüketimOran_u \quad (4.31)$$

$$\sum_{\substack{t \in T, u \in U \\ atama[t+1]=u}} = GidişYakıt_T[T_{t+1}, U_u] + GörevBeklerYakıt_T[T_{t+1}, U_u] + GörevYakıt_T[T_{t+1}, U_u] + DönüşYakıt_T[T_{t+1}, U_u] < İlkYakıt_T[T_t, U_u] \quad (4.32)$$

Sonuç olarak, görev ikilisini başaran İHA'ların görev performansı puanlanır. İHA'nın göreve gidiş süresi $GidişSüresi_T$ ve havada bekleme süresi $GörevBeklerSüresi_T[T_{t+1}, U_u]$ ne kadar kısa olursa o kadar yüksek puan alır. Ayrıca bu değerlerin etkisinin kontrol edilebilmesi için “c” katsayısı ya da İHA'nın önceki görevden dönüp inmek yerine yeni göreve atanmasının teşvik edilmesi için İHA'nın havada olduğunu belirten “Hava” ifadesi “k” katsayısı ile çarpılır ve kalan yakıt $KalanYakıt_T$, ilk kalkış yakıtı $İlkYakıt_T$ 'a bölünüp “n” katsayısı eklenerek formül oluşturulur. Yakıt deposu $YakıtDepo_T[T_t, U_u]$ 'nın, yakıt tüketimi $YakıtTüketimOran_u$ 'ne oranı ise testlere göre belirlenen bir “p” katsayısı ile çarpılır. En yüksek toplam skorunu ifade eden $TSkorU$ ise Denklem (4.33)'teki gibi hesaplanır ve tespit edilen İHA göreve seçilir. Burada dikkate değer husus Denklem (4.33)'de tarif edilen matematiksel model aslında bir uygunluk (fitness) fonksiyonu gibi çalışmaktadır.

$$\forall T_t \in \mathcal{T} \wedge \forall U_u \in \mathcal{U} \quad \Longrightarrow$$

$$\sum_{\substack{t \in \mathcal{T}, u \in \mathcal{U} \\ atama[t]=u}} TSkorU = \frac{YakitDepo_{\mathcal{T}}[T_t, U_u]}{k * YakitTuketimOran_u} - GidişSüresi_{\mathcal{T}}[T_t, U_u] - c * GörevBeklerSüresi_{\mathcal{T}}[T_{t+1}, U_u] + (Hava * p * \frac{KalanYakit_{\mathcal{T}}[T_t, U_u]}{ilkYakit_{\mathcal{T}}[T_t, U_u]} + n) \quad (4.33)$$

Seçilen İHA havadaki İHA'lar listesine eklenir. İK'da havada olan tüm İHA'ların görev bitiş süresi incelenir. İnme süresi dolanlar listeden çıkarılarak sonraki görev etki alanları güncellenir. Listeye yeni eklenen İHA'nın sonraki görevi başarma durumu incelenir. Başarırsa listede kalmasına izin verilir ve sonraki görevi başarma durumu havadan göreve gidecek şekilde hesaplanır. Bunun için Denklem (4.34)'de sunulduğu gibi İHA'nın süresi ve Denklem (4.35)'de sunulduğu üzere yakıt durumu incelenir.

$$\forall T_t \in \mathcal{T} \wedge \forall U_u \in \mathcal{U} \quad \Longrightarrow$$

$$BitişT_{\mathcal{T}}[T_t, U_u] + GidişSüresi_{\mathcal{T}}[T_{t+1}, U_u] + GörevBeklerSüresi_{\mathcal{T}}[T_{t+1}, U_u] + \leq BaşlaT_{\mathcal{T}}[T_{t+1}, U_u] \quad (4.34)$$

$$GidişYakit_{\mathcal{T}}[T_{t+1}, U_u] + GörevBeklerYakit_{\mathcal{T}}[T_{t+1}, U_u] + Görev_{\mathcal{T}}[T_{t+1}, U_u] + DönüşYakit_{\mathcal{T}}[T_{t+1}, U_u] \leq KalanYakit_{\mathcal{T}}[T_t, U_u] \quad (4.35)$$

Bir sonraki görev isterlerini yerine getiremeyen İHA'lar, mevcut görevlerinin tamamlanmasının ardından en yakın üsse iniş yapar ve görev planlama listesi dışına çıkarılır. Ancak, bu İHA'lar sonraki görev atamalarında düğüm kontrolü sırasında başarılı oldukları takdirde, yeniden etki alanına dahil edilebilir. Bu bağlamda dikkate değer bir husus, gerçek dünya görev planlama problemlerinde karşılaşılan havadaki İHA'ların sonraki görevlere atanma durumu, klasik KTP'de kullanılan İK yön-teminin ötesine geçmiştir. Önerilen çözümde, YT yöntemi uyarlanarak ve dinamik programlamanın avantajlarından yararlanılarak bu sorun ele alınmıştır. İZKTP'de İK, yalnızca bir sonraki görevin yapılabilirliğini kontrol etmekle sınırlı kalmamış; aynı zamanda havadaki İHA'ların kısıtları sağladığı sonraki görevlerle eşleşmesini mümkün kılmıştır. Bu yaklaşım, havadaki İHA'ların zaman, yakıt ve diğer dinamik kısıtlar çerçevesinde birden fazla görevle ilişkilendirilmesini sağlamaktadır.

4.3.2. AMFR

Geleneksel KTP veya ZKTP yaklaşımlarında çözüm üretmek için kullanılan İK, Gİ, YT, DT gibi yöntemlerle karmaşık işlemler sonucu üretilen çözümler (Haralick ve Elliott, 1980) yerine evrimsel algoritma mantığından esinlenmiş bir yaklaşım benimsenmiştir. Gerçek dünya problemlerinde kullanılan KTP modellerinin kodlaması ve çözümü; zamana yayılmış, karmaşık ve ayrıntılı bir süreç gerektirir. Üretilen çözümlerin kalitesinin ne ölçüde global optimuma yakınsadığı ise genellikle belirsizdir. İZKTP gibi modeller bu belirsizlikleri kısmen iyileştirmek için geliştirilmekle birlikte, üretilen çözümlerin başarısının farklı bir yaklaşımla değerlendirilmesi büyük önem taşımaktadır.

Bu kapsamda adaptif temelli yöntem önerilmiştir. Bu yaklaşım İZKTP'de olduğu gibi kompleks hibritlemeler ile kesin bir çözüm yerine hata potansiyeli az olan etkin çözümler üretmeyi amaçlar. Yöntem öncelikle kesin geçerli ve iyi bir çözüm bulma yönüne odaklanmaz, yüzeysel olarak bulunan çözümler sonrasında geçerli olmayan çözümleri ayıklar. Çünkü çözümlerin değerlendirme aşamasında geçerli olup olmadığını kontrol etmek İZKTP gibi bir modeli geliştirmekten daha basit bir yaklaşımdır.

4.3.2.1. AMFR Yöntemi Çalışma Prensipleri

Önerilen yöntem de ilk aşamada öncelikle görevin asgari ihtiyaçlarını karşılayan İHA'lar gruplanır. Bu süreç KTP'de statik kısıtları gözeterek etki alanı oluşturma yöntemine benzetilmektedir. İHA'nın görevi yapabilmesi için yeterli irtifa aralığı, faydalı yük ve giriş izni olup olmadığına göre İHA'lar görev bazlı gruplanır.

Sürecin devamında Allen'in zaman aralığında tanımladığı gibi zamana bağlı değişen yakıt, konum gibi kısıtları sadece o görev özelinde kontrol eden mekanizmalarla desteklenerek uyum sağlayamayan İHA'lar görev kümesinden ikinci kez çıkarılarak filtrelenir. Bu aşamada İHA'nın lokal olarak o görevi yapabilmesi yeterlidir. Yani İHA'nın önceki bir görevde kullanılıyor olma durumu ya da mevcut yakıtle bir sonraki göreve havadan gidebilme durumu incelenmez, sonraki görevlerle olan ilişkilerine bakılmaz, o görevin diğer görevlerle olan ilişkileri ya da başka görevlerin isterlerini karşıladığı ile ilgilenilmez.

Tüm görev setine atanan İHA'ların seçimlerinin tamamlanmasının ardından Adaptif Mutasyon temelli yerel onarım yöntemi devreye girer. Oluşturulan çözümlerin uygunluk açısından

geçerli olup olmadığı tüm görev setinin simüle edilmesi ile test edilir. Bu değerlendirme simülasyonu İZKTP’de kullanılan simülasyonun aynısıdır. Başarısızlığa neden olan bir görev olması durumunda, o görevi yapabilecek görev etki alanında başka bir İHA varsa İZKTP’deki karmaşık seçim aşamasının aksine adaptif mutasyon lokal fizibilite yöntemiyle rasgele bir İHA seçimiyle değiştirilir ve tekrar simüle edilir. Çözüm bulunana kadar kümedeki tüm İHA’ları deneme işlemi devam eder. Burada dikkate değer husus, tümüyle görev seti ataması yapılan bir çözümün geçersiz bile olsa mevcut olmasıdır. Bu durum, bir mutasyon yapılması gerektiğinde yerel minimumlara sıkışmayı önlemesi kapsamında İZKTP’ye göre bir avantaj sağlar çünkü İZKTP’den farklı olarak artık görev setinde her bir görev için atanan bir İHA bulunmaktadır. Adaptif olarak mutasyon yapılabilmesinin sebebi, tüm atamaların gerçekleşmiş olması ve mutasyonun en sağlıklı nerede yapılması gerektiğinin tespit edilebilmesidir.

Son aşamada ise elde edilen her bir görev setinde (bireylerde) İHA'ların atamaları analiz edilir. Görev seti içerisinde her İHA tarafından oluşturulan görev zincirleri, diğer bireylerde aynı İHA’ya ait zincirlerle karşılaştırılarak yakıt tüketimi, zaman ve risk gibi performans metrikleri değerlendirilir. Farklı bir bireyde aynı İHA için daha optimal (örneğin daha az yakıt tüketimi, daha kısa süre veya daha düşük risk içeren) bir görev zinciri varsa, mevcut zincir yerine bu optimal zincir ile değiştirilir. Daha sonra, yapılan değişikliğin uygulanabilirliğini kontrol etmek üzere amaç fonksiyonu yeniden çalıştırılır. Başarılı ve öncekine nazaran daha iyi bir çözüm bulunursa yeni çözüm ile devam edilir. Burada zincir iyileştirme sonrası görevi yapamadığı saptanan İHA’lar yerine, görevi yapan daha iyi İHA’ların karşılaştırması için MIQP ile modellenen bir ölçüm yöntemi kullanılmaktadır.

4.3.2.2.Yöntemin Özellikleri ve Katkıları

Önerilen yöntem probleme özel olarak geliştirilmiş adaptif bir mutasyon mekanizması içermektedir. Zaman serisi tabanlı görev planlama yapısı nedeniyle çaprazlama (crossover) gibi rastgele GA yöntemlerinin uygulanması etkin bir sonuç vermez. Ayrıca GZİ modülünün entegre edilmesi, İHA'ların görev zincirlerini daha az işlem karmaşıklığı ve zaman karmaşıklığı ile iyileştirmeye imkân tanıyan dönüştürücü bir katkı niteliğindedir; bu sayede kaynak harcamaları azaltılmaktadır.

Küresel restorasyon tekniklerini yerel ve iteratif optimizasyonlarla sentezleyen bu yaklaşım, değişen kısıtlar altında İHA görev atama probleminin NP-zor yapısına uygun olmakla

kalmayıp, gerçek dünya dinamik ortamlarına da etkili biçimde uyum sağlayan, operasyonel açıdan uygulanabilir sağlam bir çözüm sunmaktadır.

4.4. İZKTP Modeli Uygulaması

Bu bölümde, önerilen İZKTP modeli, kurgulanan senaryolar kapsamında oluşturulan sentetik veriler üzerinde test edilmiştir. Önerilen İZKTP modeli, problem dinamiğine özgü bir yaklaşımla, dinamik bir altyapı kullanılarak değerlendirilmiştir. Daha önce literatüre sunulan modelleyiciler ve çözümleyiciler (örneğin, Gecode (Nethercote, 2007), Opturion-CPX (Richoux, 2016), Choco (Jussien, 2008) genel problemler için modelleme ve çözümde hız ve kolaylık sağlasa da bu araçlar problem dinamiklerine uyarlanırken çeşitli zorluklarla karşılaşmaktadır. Bu nedenle, İZKTP modelini iyileştirmek ve modelin metasezgisel algoritmalarla entegrasyonu, görev ikilileri arası ilişkilerin farklı bir düzlemde incelenmesi gibi özellikleri desteklemek amacıyla Python’da özel bir çözüm geliştirilmiştir. Bir modelleme aracı kullanmak yerine tüm sürecin Python’da kodlanması, ZKTP modeli üzerinde daha esnek işlemler yapılmasını mümkün kılmıştır. Önerilen İZKTP modeliyle, çözümün iyileştirilmesine yönelik adaptasyon sağlanmış ve dinamik problemlerin çözümüne daha etkili bir yaklaşım sunulmuştur. Senaryo kapsamında belirlenen görevler Çizelge 4.1.’de sunulmaktadır.

Çizelge 4.1. Görev tanımları için oluşturulan sentetik veriler

ID	Görev	Süre/ Dakika	Zaman	İrtifa Aralığı-km	Yetki İsteri	Öncelik	Konum
1	Alanın Resimlenmesi	25	13:30	[3 – 5]	Hayır	5	6
2	Alanda Hareketlilik Takibi	65	13:50	[1 – 4]	Hayır	7	4
3	Gerçek Zamanlı görüntü aktarım	10	15:00	[2 – 4.75]	Evet	8	8
4	Alanın Resimlenmesi	20	17:00	[0.9 – 9.25]	Hayır	4	9
5	Alanda Hareketlilik Takibi	35	17:35	[0.4 – 5.75]	Hayır	3	7
6	Gerçek Zamanlı görüntü aktarım	20	21:00	[3.85 – 5]	Hayır	6	6
7	Alanın Resimlenmesi	40	21:05	[3.85 – 5]	Hayır	1	5
8	Alanın Resimlenmesi	15	21:30	[1 – 6]	Hayır	2	3
9	Alanın Resimlenmesi	25	21:40	[1 – 5]	Hayır	9	2
10	Alanda Hareketlilik Takibi	5	23:55	[2 – 6.75]	Evet	10	5

Benzer şekilde mevcut olan İHA’lar ve özellikleri Çizelge 4.2.’de belirtilmiştir. Çalışmada kullanılan İHA’lar heterojendir. Bunlardan sabit kanatlı ve döner kanatlı olanların farklı yakıt kapasiteleri, tüketimleri ve çeşitli faydalı yükleri mevcuttur.

Çizelge 4.2. İHA tanımları için oluşturulan sentetik veriler

ID	Hız Aralığı km/h	İrtifa Aralığı km	Yakıt Tüketimi L/km	Tip	Kanat Tipi
1	[90 – 110]	[0.3 – 6.5]	0.159	2	1
2	[90 – 200]	[0.3 – 6]	0.159	2	1
3	[110 – 190]	[0.8 – 10]	0.2	3	1
4	[90 – 250]	[0.3 – 10]	0.272	3	1
5	[90 – 800]	[0.3 – 10]	0.00159	2	1
6	[0 – 110]	[0.3 – 2]	0.459	1	2
7	[0 – 110]	[0.3 – 2]	0.459	1	2

İHA'ların dinamik olarak değişkenlik gösteren bilgilerine kalan yakıt, ilk yakıtı, konum, zorunlu ve opsiyonel faydalı yükler sütunları ile Çizelge 4.3.'de yer verilmiştir.

Çizelge 4.3. İHA dinamik süreçler için oluşturulan sentetik veriler

İHA ID	Kalan Yakıt	İlk Yakıt	Yakıt Tankı	Konum	Yasaklı Alan	Yük 1	Yük 2	Yük 1 Ops.	Yük 2 Ops.	Yük 3 Ops.
1	97.52 L	97.52 L	100 L	1	Evet	1	2	3	-	-
2	58.48 L	58.48 L	60 L	1	Hayır	2	-	-	7	-
3	140.23 L	140.23 L	150 L	1	Evet	1	2	-	-	-
4	47.12 L	47.12 L	60 L	1	Evet	1	-	-	-	-
5	101.48 L	101.48 L	150 L	1	Hayır	1	2	3	-	-
6	101.37 L	101.37 L		1	Hayır	1	2	3	-	-
7	58.15 L	58.15 L	60 L	1	Evet	1	-	-	7	-

İHA'ların sınıflandırılması kapsamında hazırlanan veriler Çizelge 4.4.'de sunulmuştur. Burada LALE – Low Altitude Long Endurance (Düşük İrtifa Uzun Havada Kalış), MALE – Mid Altitude Long Endurance (Orta İrtifa Uzun Havada Kalış), HALE -High Altitude Long Endurance (Yüksek İrtifa Uzun Havada Kalış) adlarıyla kullanılmaktadır. İrtifa aralığı “feet” ölçeğiyle kullanılmıştır.

Çizelge 4.4. İHA sınıflandırması kapsamında hazırlanan sentetik veriler

ID	İHA Tip	İrtifa Aralığı (ft.)	Hız Türü
1	LALE	0-3000	Ses Altı
2	MALE	3000-9000	Ses Altı
3	HALE	9000>	Ses Altı
4	LALE	0-3000	Ses Üstü
5	MALE	3000-9000	Ses Üstü
6	HALE	9000>	Ses Üstü

İHA görev planlaması, birden fazla İHA'nın belirli bir dizi görevi yerine getirecek şekilde organize edilmesi sürecini ifade eder. Bu süreç, "m" sayıda İHA'nın "n" adet görevi başarıyla icra etmesini hedefler. Her bir görev, belirli bir coğrafi bölge ve belirli bir zaman diliminde gerçekleştirilir. Görevlerin doğasına göre farklı ekipman ve sensörler kullanılması gerekebilir. Görevlerin etkin bir şekilde yerine getirilebilmesi için her bir görev tipi belirli bir ekipman setine ve sensöre ihtiyaç duyar. Bu bağlamda, farklı görev türlerinin gereksinimlerini daha ayrıntılı bir şekilde incelemek mümkündür. Çizelge 4.5. dört farklı görev tipini ve her bir görev için gerekli olan sensör ve ekipmanları içeren görev yükü (Grv_yük) numaralarını göstermektedir. Çizelge 4.5'teki veriler, her bir görev türü için kullanılan ekipman ve sensörlerin özelliklerini temsil etmektedir. Çizelge 4.8.'de tüm sensör ve ekipmanlar sunulmuş olup örnek olarak, aşağıda bazı ekipmanlar ve işlevleri sunulmuştur.

- **Kamera (Elektro Optik/Infrared - EO/IR):** Belirli bir bölgenin görüntülenmesi için gereklidir.
- **Radar/SAR:** Belirli bir bölgede hedef takibi yapmak için radar ekipmanları ve sensörleri kullanılmaktadır.
- **Veri İletişim Ekipmanları:** Bir bölgenin anlık görüntüsünü almak için EO/IR kamera ve iletişim teçhizatı kullanılmalıdır.

Bu tanımlama, İHA görevlerinin başarılı bir şekilde gerçekleştirilmesi için gereken ekipman ve görev tiplerinin açık bir şekilde sınıflandırılmasını sağlamaktadır. Bu kapsamda tanımlanan görevlerin yapılabilmesi için gerekli faydalı yükleri gösteren veriler Çizelge 4.5.'te sunulmuştur.

Çizelge 4.5. Görev gereği ihtiyaç duyulan faydalı yükleri tanımlayan sentetik veriler

Görev Tanımı	Grv_yük1	Grv_yük2	Grv_yük3
Alanın Resimlenmesi	1	-	-
Alanda Hareketlilik Takibi	2	-	-
Gerçek Zamanlı görüntü aktarım	1	3	-
SAR Görüntüsü	2	-	-

Tüm görevlerin ve hava üslerinin koordinatları konum ID'si verilerek Çizelge 4.6.'da sunulmuş olup iniş yapmaya uygun üsler "Ln" olarak temsil edilmektedir. Ln sütunundaki değerin "1" olması inişe uygun olduğunu, "0" olması inişe uygun olmadığını ifade etmektedir. Çizelge 4.7.'de İHA'lara yüklü olan faydalı yüklerin listesi bulunmaktadır. Çizelge 4.8.'de ise İHA'ların taşıyabileceği tüm faydalı yük envanteri sunulmuştur.

Çizelge 4.6. Görev yeri ve üs koordinatlarını tanımlayan koordinatlar

ID	X	Y	Ln
1	32.75348	39.877469	1
2	32.75799	39.87571	0
3	32.83334	39.962202	0
4	32.7652	39.869057	0
5	32.74078	39.880317	0
6	34.78647	39.747955	0
7	32.56289	40.0828	1
8	32.62219	40.50884	0
9	32.99929	40.131169	1
10	32.76139	39.875361	1
11	32.78647	39.747955	0

Çizelge 4.7. İHA’larda mevcut olan faydalı yükleri tanımlayan sentetik veriler

PK	İHA ID	Yüklü
1	1	Kamera EO/IR
2	1	Radar/SAR
3	1	Veri İletişim Ekipmanları
4	2	Radar/SAR
5	3	Kamera EO/IR
6	3	Radar/SAR
7	4	Kamera EO/IR
8	5	Kamera EO/IR
9	5	Radar/SAR
10	5	Veri İletişim Ekipmanları
11	6	Kamera EO/IR
12	6	Radar/SAR
13	6	Veri İletişim Ekipmanları
14	7	Kamera EO/IR

Çizelge 4.8. Faydalı yükleri tanımlayan sentetik veriler


ID	Faydalı Yük Envanteri
1	Kamera EO/IR
2	Radar/SAR
3	Veri İletişim Ekipmanları
4	FOX-II
5	FOX-III
6	FOX-I
7	Yakıt Tankı

Bölüm 4.2’de belirtildiği üzere problem İZKTP modelinin kurgulanması için üç parçaya (değişken, etki alanı ve kısıt) ayrıldıktan sonra bir kısıt iki değişkene (binary constraint) indirgenebilmelidir. Öncelikle görevlere İHA’ların atanabilmesi için sabit ve tekil (unary constraint) kısıtlar (İHA’nın çıkabileceği irtifa, bölge giriş izni, sabit faydalı yük)’a göre her bir değişken için etki alanı bulunması Şekil 4.2.’de gösterilmiştir.



Şekil 4.2. Etki alanına göre İHA görev atama

Dinamik kısıtların (süre, yakıt, yük, konum vb.) görev bazında incelenmesi sonrası tüm görevlerin nihai etki alanları oluşur. Bu durumda sırasıyla görevlerin tanımlı etki alanındaki İHA'lerden yakıt, süre vb. kısıtlar gözetilerek belirlenen formüle göre en uygun İHA atanır. Artık problem, her atama sonrası diğer görevlerin ardışıl ikililerinin zaman kısıtı temelinde incelenerek benzer süreçlerin tekrarlanması için uygundur. Tüm ardışıl görev ikililerinin atanma sürecini kapsayan çoklu görev atama konsepti Şekil 4.3.'te gösterilmiştir.




Şekil 4.3. Çoklu görevlere çoklu İHA atama

Görev ikilileri, zaman ve buna bağlı dinamik kısıtlar kapsamında, tüm görevler tamamlanana kadar ardışıl olarak incelenir. Görevlerin zamana bağlı çakışa durumları, Çizelge-4.9.'da sunulan Allen'in Aralık Cebiri (Allen's Interval Algebra) ile kontrol edilir.


Çizelge 4.9. Allen'ın aralık cebiri (JF, 1983)

İlişki	Gösterim	Açıklama
$T_1 < T_2$	$\frac{T_1}{T_2}$	T_1, T_2 den öncedir
$T_1 m T_2$	$\frac{T_1}{T_2}$	T_1, T_2 'ye kavuşur
$T_1 o T_2$	$\frac{T_1}{T_2}$	T_1, T_2 ile örtüşür
$T_1 s T_2$	$\frac{T_1}{T_2}$	$T_1 T_2$ ile başlar
$T_1 d T_2$	$\frac{T_1}{T_2}$	T_1 T_2 süresince
$T_1 f T_2$	$\frac{T_1}{T_2}$	$T_1 T_2$ ile biter
$T_1 = T_2$	$\frac{T_1}{T_2}$	$T_1 T_2$ 'ye eşittir.

Bu süreçte, bir önceki görev ataması ve havadaki İHA'ların durum güncellemeleri dikkate alınarak etkiler incelenir. Her bir görev çifti için, dinamik etki alanı güncellemesi yapılır ve son duruma göre görev ikilileri arasındaki güncel etki alanında en uygun İHA belirlenir. Bu süreçte; atanan İHA'nın başarısız olması durumunda Gİ ile alternatif çözümlerin aranması, YT ile görevler arasındaki kısıtların sağlanması ve aday İHA'lar içerisinde en uygun İHA'nın belirlenmesi adımları uygulanır. Eğer uygun bir İHA bulunursa, atama gerçekleştirilir. Bu işlemin görsel akışı Şekil 4.4.'te sunulmuştur. Sonraki aşamada, görev verilmiş havadaki tüm İHA'ların sonraki göreve atanma durumu incelenebilmesi için İK metodu devreye girer. Bu yöntem, görevler arasındaki uçuş sürekliliğini sağlamak için kritik bir rol oynar. İK metodunun görev çiftleri arasında nasıl işletildiği, Şekil-4.5.'te gösterilmiştir.



Şekil 4.4. Zamansal görev ikilileri penceresi




Şekil 4.5. Zamansal görev ikilileri pencereler arası geçiş

Öncelikle ilk göreve T_1 etki alanındaki İHA'lerden biri atanır. İlk görev için yapılacak atama için en uzun menzilli ve en az yakıt tüketen İHA ya da etki alanındaki ilk İHA vb. seçenekler tercih edilebilir. Burada işlem karmaşıklığını azaltmak için ilk görev atamasında etki alanından rasgele İHA seçimi benimsenmiştir. Sonraki atamalarda ise görev ikilileri arası İHA'ların puanlaması Bölüm 4.3.1.'deki (4.33) numaralı formüle göre hesaplanır.

İHA'ların seçiminde göz önünde bulundurulacak etkenler şu şekilde ifade edilebilir: havadaki uçağa öncelik verilmesi, görev için harcanan toplam yakıtın, toplam sürenin düşük olması ve sonraki görevleri yapabilecek olma potansiyelidir. Denklem bu kısıtları en yüksek puanla tamamlayan İHA'yı atama üzerine tasarlanmıştır. Ataması yapılması planlanan uçağın bir sonraki görev için YT metodu ile kontrolü yapılır ve en yüksek puanlı İHA atanır.


Sürecin genel işleyişini tarif eden görsel Şekil 4.6.'da sunulmuştur. Görselde havaalanı 1'den kalkan İHA, Görev 1'i henüz tamamlamıştır. Görev 2 ise Görev 1'deki İHA ya da diğer havaalanlarındaki İHA'lerden birisi ya da Görev 3'teki görevini tamamlayan helikopter İHA ile yapılabilir. Görevlerin ikili bir şekilde zamansal komşuluğuna bakılarak hangi İHA'nın göreve uygun olduğu durumu, birbirine zincirli zaman pencereleri ile takip edilip karar verilmektedir.

Böylece problem küçük parçalara ayrılmakta ve ZKTP yöntemlerinin hibritlenmesi ile çözüm uzayında etkin aramalar yapılabilmektedir.



Şekil 4.6. Zamansal görev ikili pencereleri genel bakış

Atama sonrası havadaki tüm İHA'ların bir sonraki görevi yapabileceğinin kontrolü için İK metodu kullanılır. Kaynakları yetmediği belirlenen İHA'lar son görev yaptığı yerden havada bekleme olmaksızın en yakın üsse inmiş gibi hesaplanır ve maliyet hesapları kaydedilir. Döngü, bir sonraki ikilinin bahse konu süreçleri tekrarlaması ile son ikili kontrol edilene kadar devam eder. Burada her renk bir çevrimi ifade etmektedir. Bütün süreci özetleyen çevrimler boyunca hangi yöntemlerin kullanıldığı Şekil 4.7.'de sunulmuştur.



Şekil 4.7. Tüm görevlerin temel işleyiş mimarisi

4.4.1. ZKTP – İZKTP Karşılaştırma Testleri


Çizelge 4.10.'da her test iterasyonunun ilk satırı ZKTP ile, ikinci satırı ise İZKTP ile seçilen İHA'ları göstermektedir. Her görev seti için; seçilen İHA'ların Bölüm 4.3.'deki (33) numaralı formüle göre hesaplanan toplam yakıt ve zaman maliyetleri Çizelge 4.11.'de sunulmuştur. İyileştirilmiş KTP yaklaşımı ile jenerik KTP arasındaki zaman ve yakıt maliyeti anlamındaki kıyaslama Şekil 4.8.'de sunulmuştur. Yapılan testlerde dikkat çekici test sonuçları derlenerek sunulmuştur. Her iterasyonda yapılan değişikliklerin detayları sırayla anlatılmaktadır.

Çizelge 4.10. Görevlere atanan İHA'ların listesi

Görev	T_1	T_2	T_3	T_4	T_5	T_6	T_7	T_8	T_9	T_{10}
Test										
1	1	2	1	3	1	1	2	3	4	3
	1	5	3	4	5	1	2	5	3	4
2	1	2	1	3	1	1	1	1	1	3
	1	5	1	3	5	1	1	5	2	4
3	5	1	1	3	1	5	1	1	1	3
	5	3	1	5	5	5	5	5	5	3
4	5	1	1	4	1	3	1	1	1	3
	5	3	1	5	5	5	5	5	5	3
5	1	2	1	4	1	1	1	1	1	3
	1	2	3	4	2	3	2	2	2	3
6	1	3	1	1	1	1	3	2	4	1
	1	3	1	1	1	1	3	2	4	1
7	1	3	1	1	1	1	3	2	1	1
	1	3	1	1	1	1	3	2	4	1
8	1	3	1	1	1	1	3	2	1	1
	1	5	1	5	5	5	1	2	5	1
9	1	3	1	1	1	3	4	1	2	1
	1	6	4	6	6	6	4	1	6	1

Çizelge 4.11. Üretilen görev seti çözümlerinin yakıt ve zaman maliyetleri

İterasyon		$\dot{I}_1$	$\dot{I}_2$	$\dot{I}_3$	$\dot{I}_4$	$\dot{I}_5$	$\dot{I}_6$	$\dot{I}_7$	$\dot{I}_8$	$\dot{I}_9$
ZKTP	Zaman(dk.)	605.3	471.8	499.3	410.9	610.7	385.1	424.4	439.3	673.3
	Yakıt (lt)	315.6	211.3	400.4	437.7	370.3	316.2	381.3	390.4	675.2
İZKTP İlk İki İyiden Biri	Zaman(dk.)	561.3	489.9	554.4	641.5	765.6	382.6	421.3	429.4	542.7
	Yakıt (lt)	295.8	323.7	287.5	154.9	306.0	311.4	372.1	312.3	536.1
İZKTP En İyi Seçim	Zaman(dk.)	508.9	480.9	645.3	643.6	911.0	385.1	415.2	712.6	750.2
	Yakıt (lt)	232.0	188.6	87.1	110.8	273.9	316.2	354.1	230.8	159.8



Şekil 4.8. ZKTP ve İZKTP karşılaştırması

İlk iterasyon veri setlerinin orijinal haliyle çalıştırılmıştır. İkinci iterasyonda Çizelge 4.12.’deki gibi görevlerin başlama zamanları değiştirilmiştir.

Çizelge 4.12. Test kapsamında değiştirilen görev başlangıç saatleri

T_1	T_2	T_3	T_4	T_5	T_6	T_7	T_8	T_9	T_{10}
"13:30"	"14:10"	"15:50"	"16:00"	"16:35"	"18:00"	"20:05"	"21:00"	"21:40"	"22:25"

Üçüncü iterasyonda İHA’ların yakıt tüketimleri tüketim değerleri Çizelge 4.13.’de sunulduğu şekilde değiştirilmiştir.

Çizelge 4.13. Test kapsamında değiştirilen İHA yakıt tüketimleri

U_1	U_2	U_3	U_4	U_5	U_6	U_7
0.22 L/km	0.159 L/km	0.3 L/km	0.2 L/km	0.00159 L/km	0.4 L/km	0.2 L/km

Dördüncü test kapsamında görevlerin kapsamı ve İHA’ların faydalı yükleri ve İHA2’nin yakıt deposu boyutu değişiklikleri Çizelge 4.14.- 4.16. arasında sırayla sunulmuştur.

Çizelge 4.14. Test kapsamında değiştirilen görev başlangıç saatleri

Görev Nu.	Görev Kapsamı
1	Alanda Hareketlilik Takibi
2	Gerçek Zamanlı görüntü aktarım
3	Alanın Resimlenmesi
4	Alanda Hareketlilik Takibi
5	Gerçek Zamanlı görüntü aktarım
6	Alanın Resimlenmesi
7	Alanda Hareketlilik Takibi
8	Alanda Hareketlilik Takibi
9	Gerçek Zamanlı görüntü aktarım
10	Alanın Resimlenmesi

Çizelge 4.15. Test kapsamında değiştirilen görev yükleri

İHA Dinamik ID	Kalan Yakıt	İlk Yakıt	Yakıt Tankı	Konum	Yasaklı Alan	Yük 1	Yük 2	Yük 3
1	97.52 L	97.52 L	100 L	1	Evet	1	2	3
2	58.48 L	58.48 L	60 L	1	Hayır	1	2	3
3	140.23 L	140.23 L	150 L	1	Evet	1		3
4	47.12 L	47.12 L	60 L	1	Evet	1	2	
5	101.48 L	101.48 L	150 L	1	Hayır	1	2	3
6	101.48 L	101.48 L		1	Hayır	1		
7	58.15 L	58.15 L	60 L	1	Hayır	1		

Çizelge 4.16. Test kapsamında değiştirilen İHA yakıt tüketim ve hız değerleri

İHA ID	Hız Aralığı	İrtifa Aralığı	Yakıt Tüketimi	Tip	Kanat Tipi
3	210,790	0.8,10	0.13 L/km	3	1

Beşinci iterasyonda İHA'ların yakıt tüketim değerleri, görevlerin içerikleri İHA-2'nin yakıt deposu Çizelge 4.17. ve Çizelge 4.18.'da sırasıyla gösterildiği şekilde genişletilerek testlere devam edilmiştir.

Çizelge 4.17. Test kapsamında değiştirilen İHA yakıt tüketim değerleri

İHA_ID	Hız Aralığı	İrtifa Aralığı	Yakıt Tüketimi
1	90,610	0.3,6.5	'0.159 L/km'
2	90,200	0.3,6	'0.000159 L/km'
3	210,790	0.8,10	'0.2 L/km'
4	90,250	0.3,10	'0.272 L/km'
5	90,800	0.3,10	'0.9 L/km'
6	0,110	0.3,2	'0.455 L/km'
7	0,110	0.3,2	'0.455 L/km'

Çizelge 4.18. Test kapsamında değiştirilen İHA yakıt tüketim değerleri

İHA Dinamik ID	Kalan Yakıt	İlk Yakıt	Yakıt Tankı	Konu m	Yasaklı Alan	Yük 1	Yük 2	Yük 3	Yük 4
2	'158.48 L'	'158.48 L'	'160 L'	'1'	Hayır	1	2	3	7

Veri setlerinde yapılan değişiklikler altıncı iterasyona kadar kümülatif olarak yapılmıştır. Kümülatif olarak yapılan değişiklikler bir süre sonra test sonuçlarını yorumlamakta karmaşaya neden olduğu için veri seti altıncı iterasyon da orijinal haline çevrilmiştir. Altıncı iterasyonda ise İHA-1, 2 ve 5'in hız, irtifa ve yakıt tüketimi değerleri Çizelge 4.19.'da sunulduğu şekilde değiştirilmiştir. Ayrıca kullanılan matematiksel modelde havada bekleme süresinin azaltılması için Bölüm 4.3. de yer alan Denklem (33) de *GörevBeklerSüresi*'nin c katsayısı değiştirilmiştir.

Çizelge 4.19. Test kapsamında değiştirilen İHA yetenekleri

İHA_ID	Hız Aralığı	Yükseklik Aralığı	Yakıt Tüketimi	Tip	Kanat Tıps
1	300,910	0.3-9.9	0.1 L/km	2	1
2	300,910	0.3-9.9	0.159 L/km	2	1
5	90,900	0.3-10	0.59 L/km	2	1

Yedinci test kapsamında kullanılan koordinatlar Çizelge 4.20.'deki gibi değiştirilmiştir.

Çizelge 4.20. Test kapsamında değiştirilen koordinat bilgileri

Lokasyon	X	Y
6	'31.786465'	39.747955
7	'33.562893'	40.0828
8	'36.622185'	40.50884

Sekizinci iterasyonda tüm İHA'ların göreve başlamadan önce bulundukları konum bilgileri Çizelge 4.21.'de ve İHA-5 ve İHA-6'nın yetenekleri Çizelge 4.22.'de sunulan şekliyle değiştirilmiştir.

Çizelge 4.21. Test kapsamında değiştirilen koordinat bilgileri

İHA Dinamik ID	Kalan Yakıt	İlk Yakıt	Yakıt Tankı	Konum
1	97.52 L	97.52 L	100 L	10
2	58.48 L	58.48 L	60 L	9
3	140.23 L	140.23 L	150 L	9
4	47.12 L	47.12 L	60 L	10
5	101.48 L	101.48 L	150 L	7
6	101.48 L	101.48 L		7
7	58.15 L	58.15 L	60 L	7

Çizelge 4.22. Değiştirilen İHA yetenekleri


İHA_ID	Hız Aralığı	Yükseklik Aralığı	Yakıt Tüketimi	Tip
5	90,900	0.3,10	0.0059 L/km	2
6	0,910	0.3,2	0.00459 L/km	1

Son test adımında ise İHA'ların yetenekleri Çizelge 4.23.'te sunulduğu şekliyle değiştirilip gözlemlenmiştir.

Çizelge 4.23. Değiştirilen İHA yetenekleri

İHA_ID	Hız Aralığı	Yükseklik Aralığı	Yakıt Tüketimi
1	300,910	0.3,9.9	0.2L/km
4	90,750	0.3,10	0.0272 L/km
5	90,900	0.3,10	0.59 L/km
6	0,910	0.3,10	0.00459 L/km

Tüm test adımlarının yakıt tüketim ve toplam süre değerleri Çizelge 4.24.’de sunulmuştur. Burada DL olarak geçen ifade göreve atanan İHA’nın o görev sonrası inmediği ve bir sonraki göreve önceki görev sonrası devam ettiği anlamına gelen “Defined Later” ifadesinin kısaltması olarak kullanılmıştır. İZKTP yöntemiyle üretilen zaman ve yakıt değerleri incelendiğinde yakıt tüketimi anlamlı derecede düşmüş fakat havadaki İHA’ların inmeden başka görevlere gitmesi teşvik edildiği için havada geçen süre artmıştır. Altıncı iterasyonda havada bekleme süresi için kullanılan “c” katsayısı değiştirildiğinde yakıt üzerine etkileri görülmüştür. Yakıt tüketimi bu iterasyondan sonra artmış ve havada geçen süre benzer oranda düşmüştür. Matematiksel model bu kapsamda beklenen etkiyi göstermektedir. Şekil 4.9.’da özellikle altıncı iterasyon sonrası değişim görülmektedir. Ayrıca modelin ürettiği en iyi iki İHA’dan birinin seçilmesi ZKTP ve İZKTP’nin ürettiği sonuçların ortalaması şeklindedir. Bu durum matematiksel modelin doğru kurgulandığı ve sağlıklı çalıştığı şeklinde yorumlanabilir.



Şekil 4.9. ZKTP ve İZKTP varyasyonlarının test sonuçları karşılaştırması

Testler de İZKTP’nin en iyi performans gösterdiği 3. iterasyon verileri Çizelge 4.24.’de sunulmuştur.

Çizelge 4.24. İZKTP’de en etkili çözümü sunan birey

Görev	İHA	Kalkış	İniş	Biten Görev Konumu	Bitiş Zamanı	Gidiş Süresi	Havada Bekleme süresi	Başlama Zamanı	Görev Süresi	Dönüş Süresi	Toplam Süre	Toplam Yakıt
1	5	1	DL	6	13:55	30.5	0.0	13:30	25.0	0.0	55.5	0.7
2	3	1	10	4	15:15	0.6	0.0	14:10	65.0	0.3	65.9	49.0
3	1	1	7	8	16:00	10.5	0.0	15:50	10.0	6.9	27.4	26.0
4	5	6	DL	9	16:20	27.2	97.8	16:00	20.0	0.0	145.0	2.0
5	5	9	DL	7	17:10	6.6	8.4	16:35	35.0	0.0	50.0	1.0
6	5	7	DL	6	18:20	33.5	16.5	18:00	20.0	0.0	70.0	1.0
7	5	6	DL	5	20:45	30.6	74.4	20:05	40.0	0.0	145.0	2.0
8	5	5	DL	3	21:15	1.7	13.3	21:00	15.0	0.0	30.0	0.0
9	5	3	DL-10	2	22:05	1.6	23.4	21:40	25.0	0.1	50.1	1.0
10	3	10	DL-1	5	22:30	0.9	0.0	22:25	5.0	0.6	6.5	4.4

Çizelge 4.25. ZKTP’de en etkili çözümü sunan birey

Görev	İHA	Kalkış	İniş	Biten Görev Konumu	Bitiş Zamanı	Gidiş Süresi	Havada Bekleme süresi	Başlama Zamanı	Görev Süresi	Dönüş Süresi	Toplam Süre	Toplam Yakıt
1	1	1	9	6	13:55	38.7	0.0	13:30	25	34.5	98.2	41.2
2	2	1	10	4	15:15	0.6	0.0	14:10	65	0.3	65.9	25.0
3	1	9	7	8	16:00	9.4	0.0	15:50	10	0.0	8.0	15.0
4	3	1	9	9	16:20	14.5	0.0	16:00	20	0.0	34.5	19.3
5	1	8	7	7	17:10	7.0	0.0	16:35	35	0.0	42.0	50.7
6	1	7	9	6	18:20	42.6	0.0	18:00	20	34.5	97.1	37.1
7	1	9	1	5	20:45	6.4	0.0	20:05	40	0.2	46.6	27.1
8	1	1	10	3	21:15	2.2	0.0	21:00	15	2.0	32.0	17.3
9	1	10	DL-10	2	22:05	2.0	0.0	21:40	25	0.1	27.1	19.0
10	3	9	DL-1	5	22:30	14.8	0.0	22:25	5	0.6	20.4	10.3

Toplam 90 görev test sonuçlarında İHA’ların tümü incelendiğinde ZKTP yöntemiyle 90, iyileştirilmiş ZKTP’de ise 60 kez iniş kalkış yapıldığı görülmektedir. ZKTP’de 90 görevden 56’sı İHA-1’e verilmişken, İHA-5’e sadece 3 görev verilmiştir. İZKTP’de ise İHA-1’e 28, İHA-5’e 25 ve İHA-6’ya 8 görev verilmiştir. Toplam 30 göreve havadaki bir İHA atanarak %33 iniş/kalkış tasarrufu sağlanmıştır.

Yine İZKTP ile yaklaşık 5452,91 dakika 1953,23 litre yakıtla tamamlanan görev paketi ZKTP’de yaklaşık 4580,31 dakikada 3565,23 litre ile gerçekleştirilmiştir. İZKTP ile süre artışı gözlemlense de görev seti 3 ve 4’te İHA’nın hiç iniş yapmadan yedi farklı göreve kadar

planlandığı (Bknz: Çizelge 4.10) görülmektedir. Bir görev seti içerisinde İniş kalkış sayısının az olması havacılıkta riski önemli ölçüde azaltan bir durumdur (BOEING, 2023).

4.4.2. ZKTP – İZKTP İstatistiksel Analiz Sonuçları

Süre (T) kapsamında İZKTP, ZKTP'ye kıyasla ortalama +162.5 dk (+%37.7) daha uzun süre üretmiştir; bu fark anlamlıdır (Welch $t(15.99)=-2.33$, $p(\text{düz.})=0.033$). Etki büyüklüğü $g=1.05$ ile büyük düzeydedir. Bootstrap %95 GA [+37.5, +298.0] aralığında olup sıfırı içermediği için sonuç karardır; “üstünlük olasılığı” $P(B<A)=0.004$ olduğundan, süre açısından İZKTP'nin ZKTP'den daha iyi olma olasılığı düşüktür. Mann–Whitney U testi $p=0.070$ ile aynı yönü destekleyen ancak sınırda kalan bir bulgu vermiştir.

Yakıt (F) kapsamında İZKTP, ortalama -116.3 L (-%34.9) daha az yakıt tüketmiştir; fark anlamlıdır ($t(15.90)=+2.64$, $p(\text{düz.})=0.036$). Etki büyüklüğü $g=-1.19$ ile büyük ölçektir. Bootstrap %95 GA [-194.9, -31.8] ve $P(B<A)=0.996$ (İZKTP yakıtta neredeyse kesin üstün). Mann–Whitney $p=0.019$ ile bu sonucu güçlendirmektedir.

Operasyonel değerlendirme yönüyle karar kuralına göre (T, F birlikte): yakıt öncelikliyse İZKTP güçlü adaydır ($F\downarrow$); süre öncelikliyse ZKTP tercih edilebilir ($T\downarrow$). Görev gerekliliklerine bağlı seçim önerilir. Çizelge 4.26'da yöntemlerin ürettiği çıktıların istatistiki olarak anlamlılığını gösteren test sonuçları sunulmuştur.

Çizelge 4.26. ZKTP-İZKTP yöntem çıktılarının istatistiki değerlendirmesi

Ölçüt	Yöntem	n	Ort.	SS	%95 GA	Welch t (df)	p (Welch)	p (düz.)	p (M-W U)	Hedges' g	Bootstrap $\Delta(B-A)$ [GA]	p (Üstünlük)
Süre (dk)	ZKTP	9	430.63	145.73	[318.62, 542.65]	-2.33 (15.99)	0.033	0.033	0.070	1.046	+162.53 [+37.53, +298.01]	0.004
	İZKTP	9	592.72	149.42	[477.87, 707.57]							
Yakıt (L)	ZKTP	9	333.42	97.14	[258.76, 408.09]	+2.64 (15.90)	0.0179	0.0358	0.019	-1.185	-116.34 [-194.94, -31.82]	0.996
	İZKTP	9	217.02	89.81	[147.99, 286.05]							

4.4.3. ZKTP – İZKTP Modeli Karşılaştırma Test Yorumu

Uçak görev atama problemi; farklı türden kısıtların (uçanın teknik özellikleri, yakıt, bakım gereklilikleri, görev profili gibi) ve çok çeşitli amaç fonksiyonlarının (örneğin maliyet ve uçuş süresi minimizasyonu, kaynak kullanımının dengelenmesi, görevlerin zamanında tamamlanması)

aynı anda göz önünde bulundurulmasını gerektirir. ZKTP tabanlı modellenen bu problemde, bulunan çözüm optimize olmasa da tüm bu kısıtları tatmin edecek bir çözüm bulmak zorunludur. Bunun ötesinde İZKTP, yerel tuzaklardan kaçınma yöntemlerini geliştirmeyi amaçlasa da temel amacı yalnızca geçerli bir çözümü hedefleyen bir yöntem olan KTP üzerinde çalışmaktadır ve optimal veya yakın-optimal çözümlere ulaşmak güç olabilmektedir. Global optimumu bulma çabası için klasik lokal arama tekniklerinin ötesinde meta-sezgisel (metaheuristic) yaklaşımlara ihtiyaç duyulduğu görülmüştür. Bu nedenle, GA gibi global arama yöntemlerinin, kısıt tanım ve kontrol gücü yüksek bir modelle (KTP, ZKTP veya İZKTP) hibritlenmesi, çözümlerin kalitesini ciddi ölçüde iyileştirebilir.

Bu kapsamda, GA mantığından esinlenen adaptif mutasyon yönteminin de sürece entegre edilmesi önemlidir. Çünkü en iyi çözümün bulunamayacağı büyük çözüm uzayları içerisinde bulunan çözümlerin bulunma hızı ve amaçlara uygunluğunun kıyaslanabilmesi gerekir. Bu konu ve kıyaslama yöntemleri 4.5'te AMFR Modeli Uygulaması altında detaylı olarak incelenmiştir.

4.5. AMFR Modeli Uygulaması

İZKTP'nin karmaşık optimizasyon sürecine karşılık olarak, bu bölümde daha basit ancak tamamlayıcı bir alternatif olarak tasarlanan AMFR yaklaşımı sunulmaktadır.

Görev atama doğası gereği zaman serisi problemidir ve çözüm uzayı üssel olarak genişlemektedir. Bu nedenle evrimsel algoritmanın probleme özgü özelleştirilmesine ihtiyaç vardır. Probleme özgü evrimsel algoritma çözüm kalitesini artırırken hesaplama süresini dikkate değer oranda düşürebilir. Burada çaprazlama özelliğini kullanmak önceki hesaplamaların dışında takip edilemez sonuçlar çıkarabilmektedir. Bunun için elde edilen çözümlerin başarısına göre performansı yetersiz İHA'yı belirli kurallara göre mutasyona uğratmak etkin çözümleri daha az hesaplama gücü ve zaman tasarrufu ile doğru yerde aranmasına yardımcı olmaktadır.

AMFR yöntemi, ilk atamaları gerçekleştirmek üzere her bir görev için statik kısıtları (örneğin; irtifa, faydalı yük, uçuş izinleri gibi) ve görev bazında lokal olarak dinamik kısıtları (yakıt ve zaman gibi) kontrol ederek her göreve uygun İHA'lar kümesi etki alanlarını oluşturur. Ardından görevler arasında ortaya çıkan tutarsızlıklar varsa saptayarak yerel onarım yöntemiyle çözümler ve son aşamada genel iyileşme sağlamak amacıyla küresel restorasyon yöntemini uygular. Bu süreç üç temel aşamadan oluşmaktadır:

i) İHA'ların Görevlere Yüzeysel Atanması (Global Kaba Arama – Global Coarse Search)

- ii) Başarısız Atamaların Düzeltilmesi (Yerel Onarım: AMLR - Adaptive Mutation Local Repair)
- iii) Görev Zincirlerinin İyileştirilmesi (TCI – Küresel Restorasyon – Global Restoration)

i) İHA'ların Görevlere Yüzeysel Ataması

Bu aşamada İHA'ların görev setlerine ilk atamaları, sadece basit doğrulama kontrol adımları yapılarak gerçekleştirilir. Uygulanan operasyonel adımlar aşağıdaki başlıklar altında açıklanmaktadır:

Statik Kısıtların Kontrolü: İrtifa aralığı, faydalı yük kapasitesi ve uçuş yetkilendirmeleri gibi statik kısıtlar üzerinden basit bir "kaba arama" yapılır. Bu adımda hangi İHA'ların hangi görevleri üstlenebileceği tespit edilir.

Tek Görev Seviyesinde Dinamik Kontrol (Yüzeysel Seviye): Statik kısıtları sağlayan İHA'lar, yakıt ve zaman gibi dinamik kısıtlar açısından değerlendirilir; ancak bu değerlendirme yalnızca görev bazında gerçekleştirilir. Bu noktada İHA'nın önceki veya sonraki görevleri dikkate alınmaz; odak noktası sadece söz konusu tek görevdir. Yakıt veya zaman kısıtları nedeniyle uygun olmayan İHA'lar değerlendirme havuzundan çıkarılarak, her görev için uygulanabilir İHA adayları daraltılır.

Başlangıç Atamalarının Oluşturulması: Her görev için kalan uygulanabilir İHA listelerinden basit bir "seçim" mekanizması aracılığıyla ilk atamalar gerçekleştirilir. Bu aşamada, hesaplama yükünü azaltmak amacıyla ardışık görev zincirlerinin derinlemesine analizi yapılmaz ve çözüm bütünlüğünü bozabilecek potansiyel atamalar incelenmez. Bu nedenle bir İHA'nın aynı anda birden fazla göreve atanması veya ardışık görevlerde yakıt yetersizliği gibi tutarsızlıklar henüz tamamen çözülmemiştir; bu tür sorunlar bir sonraki aşama olan AMLR'da ele alınacaktır.

ii) Başarısız Atamaların Düzeltilmesi (Yerel Onarım: AMYO)

Uyarlanabilir Mutasyon Temelli Yerel Onarım (Adaptive Mutation-Based Local Repair – AMLR) sürecinde, ilk atamalardan kaynaklanan tutarsızlıklar tespit edilerek çözülür. İşlem adımları aşağıdaki şekildedir:

Uçuş Simülasyonu ile Zamansal Düzenleme: Tüm görevler zaman çizelgesi üzerinde sıralı ya da paralel şekilde düzenlenir. Bu simülasyon aracılığıyla aynı anda iki farklı göreve atanmış İHA'lar veya yetersiz yakıt-konum senaryoları gibi çakışmalar tespit edilir.

Uyarlanabilir Mutasyon: Bir İHA, başka bir göreve önceden atanmış olması sebebiyle (örneğin; yakıt yetersizliği ya da zamanında görev bölgesine ulaşamama durumu) mevcut görevi

tamamlayamıyorsa, o görevin uygulanabilir İHA havuzundan rastgele başka bir İHA seçilir. Yeni seçilen İHA'nın önceki görevleri, sonraki planları ve mevcut durumu (iniş/kalkış noktası, mevcut konumu, kalan yakıt miktarı vb.) amaç fonksiyon içerisinde değerlendirilir. Bu işlem, görevi başarıyla yerine getirebilecek bir İHA bulununcaya kadar tekrarlanır.

Navigasyon Metriklerinin Güncellenmesi: Her İHA'nın uçuş süresi, yakıt tüketimi ve iniş/kalkış noktası gibi verileri güncellenerek "havada olan İHA listesine (in-air list)" kaydedilir. Böylece, sonraki görevlerin atamaları bu güncel metrikler temel alınarak gerçekleştirilir. Her görev çiftinin etkileşimini ayrıntılı şekilde ele alan kapsamlı (İZKTP modeline kıyasla hesaplama yükü burada önemli ölçüde azaltılır) adaptif mutasyon yöntemleri hızlı yerel onarımlar sağlar.

Çizelge 4.27, adaptif mutasyon tabanlı yerel onarım algoritmasının sözde kodunu sunmaktadır. Bu kod, her görev için atanan İHA'nın uygulanabilirliğini doğrulama mantığını ve başlangıçta atanan İHA'nın başarısız olması durumunda alternatif İHA'ların denenmesini özetlemektedir. Başarılı bir atama sonrası halen havada bulunan İHA'ların durumları (örneğin yakıtı yetersiz kalanların durumu) güncellenerek iniş yapmaları sağlanır ve bir sonraki görev için gerekli düzenlemeler yapılır. Bu prosedür, tüm görevlerin İHA'lara başarıyla atanmasına kadar tekrar edilir.

Çizelge 4.27. Adaptif mutasyon tabanlı yerel onarım metodunun sözde kodu

```

FUNCTION check_and_assign_uav(gorevler, filtrenmis_iha, havadaki_iha_listesi):
    kullanan_adaylar <- empty list
    degistirilmis_birey <- empty list

    #Adım-1: Tüm görevleri sırayla kontrol et
    FOR gorev_idx IN 0 – (size(gorevler)-1):
        gorev <- gorevler[gorev_idx]
        atanmis_iha <- get_assigned_uav(gorev)
        adaylar <- filtrenmis_iha[gorev_idx]

        #Adım-1.1: Daha önce kullanılmamış atanmış İHA'yı kontrol et
        IF atanmis_iha NOT IN kullanan_adaylar:
            IF check_uav_feasibility(atanmis_iha, gorev, havadaki_iha_listesi) == TRUE:
                update_uav_in_air_list(atanmis_iha, gorev, havadaki_iha_listesi)
                add atanmis_iha TO degistirilmis_birey
                CONTINUE


        #Adım-1.2: Aday İHA'ları sırayla kontrol et
        FOR aday_iha IN adaylar:
            IF aday_iha NOT IN kullanan_adaylar:
                IF check_uav_feasibility(aday_iha, gorev, havadaki_iha_listesi) == TRUE:
                    update_uav_in_air_list(aday_iha, gorev, havadaki_iha_listesi)
                    add aday_iha TO degistirilmis_birey
                    BREAK
            add aday_iha TO kullanan_adaylar

        #Adım-1.3: Eğer hiçbir İHA atanamazsa, çözümü sıfırla
        IF gorev_idx == size(degistirilmis_birey):
            reset_individual(degistirilmis_birey)
            BREAK

    #Adım-2: Havada olan İHA'ların inişlerini güncelle
    FOR iha, detaylar IN havadaki_iha_listesi.items():
        IF detaylar IS NOT EMPTY:
            en_yakin_us <- en_yakin_us_bul(detaylar['location'])
            update_uav_landing(iha, en_yakin_us, havadaki_iha_listesi)
    RETURN degistirilmis_birey

```

Birbiriyle çelişmesine rağmen ardışık görevlerin aynı İHA'ya atandığı durumlarda ya da önceki görevinden dönen bir İHA'nın bir sonraki görev için yeterli yakıtı sahip olmadığı senaryolarda, AMFR yaklaşımı bu tür sorunları tespit ederek görevleri uygun alternatif İHA'lara yeniden atayarak çözüme kavuşturur. Bu süreci açıklayıcı bir örnek Şekil 4.10'da sunulmaktadır.



Şekil 4.10. Adaptif mutasyon tabanlı yerel onarım metodu çalışma prensibi

İlk aşamada n adet İHA, statik kısıtlara göre m adet görevle eşleştirilmekte ve böylece her bir görev için uygulanabilir İHA etki alanları (domain) oluşturulmaktadır (Şekil 4.10'da (1)). Bu sürecin ardından zamansal kısıtlar devreye alınarak, görevlerin atanacağı İHA'ların: (1) belirtilen zaman aralığında görev bölgesine ulaşabilmeleri, (2) sonraki görevlere geçiş yapmak ya da üsse dönmek için yeterli yakıt rezervine sahip olmaları ve (3) dinamik görev parametrelerine uymaları sağlanarak, atama alanları daha da daraltılır (Şekil 4.10'da (2)). Tüm görevlerin atamaları yapıldıktan sonra görevin tamamı simüle edilir. Bu simülasyon sırasında, herhangi bir İHA atandığı görevi kısıt ihlalleri nedeniyle tamamlayamazsa, Uyarlanabilir Mutasyon Temelli Yerel Onarım (AMYO) aşaması devreye girer. Bu aşamada, MIQP yöntemi, daraltılmış atama alanındaki aday İHA'ları değerlendirerek önceden belirlenmiş performans kriterlerine (örneğin yakıt verimliliği, yakınlık) göre optimal alternatifi seçer (Şekil 4.10'da (3)). Bu iteratif onarım mekanizması görev sürekliliğini ve operasyonel uygulanabilirliği garanti eder.

iii) Görev Zinciri İyileştirme -GZİ

AMYO aşamasının ardından uygulanan GZİ adımı, oluşturulan görev setlerinin genel performansını küresel bir optimizasyon yöntemiyle artırmayı hedefler. Bu süreç aşağıdaki şekilde özetlenebilir:

Zincirlerin Karşılaştırılması: Yerel onarım sonucunda elde edilen her bir görev setindeki (birey) İHA atamaları analiz edilir. Her İHA'nın oluşturduğu görev zincirleri, diğer bireylerdeki aynı İHA'ya ait zincirlerle karşılaştırılarak yakıt tüketimi, zaman ve risk gibi performans metrikleri değerlendirilir.


Üstün Zincirlerin Seçilmesi: Başka bir bireyde aynı İHA için daha optimal (örneğin, daha az yakıt tüketen, daha kısa süren veya daha düşük risk taşıyan) bir görev zinciri mevcutsa, mevcut zincir yerine bu üstün zincir kullanılır. Ardından, bu değişikliğin uygulanabilirliğini kontrol etmek için AMFR yeniden çalıştırılır.

Puanlama ve Değerlendirme: Yeni görev setlerinin uygulanabilirliği doğrulanarak, MIQP temelli bir fonksiyonla puanlanır. Eğer yeni görev seti önceki setten daha yüksek bir skor elde ederse, yeni standart çözüm olarak kabul edilir. Riskin azaltılması amacıyla, iniş yapmadan ardışık görevleri gerçekleştirebilen İHA'lar özellikle tercih edilir; bu bağlamda risk değerlendirmesi için kalan yakıtın maksimum yakıt oranı ve erişilebilir görev sayısı gibi metriklerden yararlanılır.

Bu küresel restorasyon aşaması, İZKTP kadar ayrıntılı olmayabilir, ancak adaptif mutasyon yaklaşımıyla bulunan çözümlerin küresel optimuma yakınsamasını kolaylaştırır. Şekil 4.11, farklı görev setlerinde daha iyi performans gösteren İHA zincirlerinin seçilerek birleştirilme sürecini göstermektedir. Bu süreç boyunca AMFR tarafından gerçekleştirilen doğrulamalar, belirli görevlerin İHA atamalarında değişikliklere yol açarak görevler arası zaman ve yakıt kısıtlarını karşılayan kapsamlı bir çözüm üretir.

Şekil 4.11'de, her görev setinde atanan İHA'lar görev numaralarının altında belirtilmiştir. Atanan her bir İHA için tüm görev setleri sırasıyla incelenir. Her İHA'ya ait görev zincirlerinin maliyetleri tüm görev setleri boyunca hesaplanarak karşılaştırılır. En düşük maliyetli zincir, restorasyon için incelenen görev setine entegre edilir. Örneğin 'de görev seti-1 analiz edilirken, İHA-1 için en uygun maliyetli zincirin görev seti-2'den 2 ve 5 numaralı görevlerden oluştuğu görülür. İHA-3 için ise optimal zincir görev seti-n (Mission-n)'den 1, 7 ve 9 numaralı görevlerden oluşmaktadır. Her iki zincir de görev seti-1 atamalarına dâhil edilerek, Şekil 4.11 içerisinde (1) no'lu çizelge de gösterilen yeni birey oluşturulur. Zincirlerin görev seti-1'e uygulanması sırasında

görev 6'ya atanmış İHA'nın İHA-2 olarak değiştirilmesi dikkat çekicidir. Bu düzenleme, AMFR doğrulama sürecinde atamaların uygulanabilirliğini sağlamak amacıyla gerçekleştirilmiştir. İHA-1, GZİ kapsamında görev 5'e atandığında zaman veya yakıt kısıtları nedeniyle görev 6'yı yerine getirememekte, bunun sonucunda görev 6'nın ataması İHA-2'ye yönlendirilmektedir.



Şekil 4.11. Adaptif mutasyon tabanlı görev zinciri iyileştirme çalışma prensibi

Adaptif mutasyon temelli GZİ yöntemi kullanılarak geliştirilen çözümler, zincir iyileştirme yaklaşımıyla çözüm uzayındaki küresel optimuma doğru yakınsar. Bu yöntemin sözde kodu Çizelge 4.28'de verilmiştir. İlk adımda (Adım 1), her bir birey (görev seti) için tüm İHA'ların görev zinciri maliyetleri hesaplanır. İkinci adımda (Adım 2), her bir bireyde bulunan İHA zinciri, potansiyel olarak daha düşük maliyetli zincirlerle karşılaştırılır; eğer başka bir görev setinde daha iyi bir zincir bulunur ve bu zincirin mevcut zincirle değiştirilmesi geçerli bir çözüm oluşturuyorsa, zincir değiştirilir. Bu yöntemle tüm atanmış İHA'lar incelenir ve sonuç olarak yeni görev setleri oluşturulur.

Çizelge 4.28. Adaptif mutasyon tabanlı görev zinciri iyileştirme yöntemi sözde kodu

```

FUNCTION optimize_chains(tam_gorev_listesi):
  zincir_maliyetleri <- empty dictionary
  #Adım-1: Her birey için tüm İHA'ların zincir maliyetlerini hesapla
  FOR gorev_idx IN 0..(size(tam_gorev_listesi)-1):
    gorev <- tam_gorev_listesi[gorev_idx]
    yerel_zincirler <- empty dictionary

    FOR iha IN iha_listesi:
      zincir_sonucu <- get_chain_cost(gorev, iha)
      IF zincir_sonucu['zincir_var'] == TRUE:
        yerel_zincirler[iha] <- zincir_sonucu

    zincir_maliyetleri[gorev_idx] <- yerel_zincirler
  optimize_edilmis_bireyler <- empty list

  #Adım-2: Her bireydeki İHA zincirlerini daha düşük maliyetli olası zincirlerle karşılaştır
  FOR gorev_idx IN zincir_maliyetleri.keys():
    yeni_gorev <- copy tam_gorev_listesi[gorev_idx]
    degisti <- FALSE

    FOR (iha, mevcut_zincir) IN zincir_maliyetleri[gorev_idx]:
      en_ iyi_zincir <- mevcut_zincir
      en_ iyi_maliyet <- mevcut_zincir['toplam_maliyet']
      en_ iyi_kaynak <- gorev_idx

      #Adım-2.1: Aynı İHA için diğer bireylerdeki daha düşük maliyetleri ara
      FOR diger_idx IN zincir_maliyetleri.keys():
        IF diger_idx != gorev_idx AND (iha IN zincir_maliyetleri[diger_idx]):
          aday_zincir <- zincir_maliyetleri[diger_idx][iha]
          IF aday_zincir['toplam_maliyet'] < en_ iyi_maliyet:
            en_ iyi_zincir <- aday_zincir
            en_ iyi_maliyet <- aday_zincir['toplam_maliyet']
            en_ iyi_kaynak <- diger_idx

      #Adım-2.2: Daha iyiyse, yeni_gorev içindeki ilgili görevleri değiştir
      IF en_ iyi_zincir != mevcut_zincir:
        FOR gorev_id IN mevcut_zincir['zincir_gorevleri']:
          yeni_gorev[gorev_id] <- copy tam_gorev_listesi[en_ iyi_kaynak][gorev_id]
        degisti <- TRUE

    IF degisti == TRUE:
      add yeni_gorev to optimize_edilmis_bireyler
  RETURN tam_gorev_listesi, optimize_edilmis_bireyler

```

4.5.1. AMYO – GZİ Karşılaştırma Testleri

Bu bölüm, gerçek dünyaya yakın senaryoları yansıtan kapsamlı simülasyonlar ve karşılaştırmalı testleri içermektedir. Bölümün yapısı, ilk olarak AMFR çerçevesi içinde önerilen AMYO ve GZİ yöntemlerini değerlendirmeyi, ardından İZKTP ve AMFR yöntemlerinin etkinlik ve verimliliğini bütüncül biçimde karşılaştırmayı hedeflemektedir. Deneysel tasarımda, sağlam ve

güvenilir performans analizlerinin yapılabilmesi amacıyla gerçekçi koşullar altında titiz doğrulama süreçleri önceliklendirilmiştir.

AMYO süreci, görev atama işlemi sırasında statik kısıtlar ile tekil görev bazındaki dinamik kısıtları karşılayan ancak görevler arası atama koordinasyonu yapılmadığı için görev seti seviyesinde geçersiz atamaları düzenler. İHA'ların görevi yapabilecek görev etki alanındaki diğer İHA'larla değişimini yani görev seti onarımını simülasyon test süreçlerinde sağlar. Bu aşamada çözüme engel olan görev ataması incelenmektedir. Atama yapılan görevler içerisinde simülasyonda amaç fonksiyonunu sağlamayan İHA'lar değiştirilir.

Çizelge 4.29'nın sol kısmı, hazırlık aşamasında yüzeysel biçimde oluşturulan ilk bireyleri göstermektedir. Çizelgenin sağ tarafında ise AMYO yöntemi ile onarılan bireyler sunulmaktadır. Bu yöntem, küresel düzeyde geçersiz olan İHA atamalarını, görev alanında uygun alternatif İHA'lar ile değiştirerek çözmektedir. Örneğin Birey-1'de başlangıçta hem Görev-1 hem de Görev-2'ye atanmış olan İHA-3, zaman bakımından çakışmayı önlemek amacıyla Görev-2'nin başarılabilmesi için İHA-2 ile değiştirilmiştir.

Çizelge 4.29. Adaptif mutasyon sonucu bireylerdeki değişim

Birey No	Lokal Amaç Fonksiyonu ile Filtrelenerek Seçilen Bireyler	AMYO Yöntemi ile Düzeltilen Bireyler
1	3, 3, 4, 5, 2, 3, 2, 2, 5, 4	3, 2, 4, 5, 2, 3, 2, 1, 5, 4
2	5, 2, 4, 3, 2, 1, 5, 2, 1, 4	5, 2, 4, 3, 2, 1, 5, 2, 3, 4
3	3, 2, 4, 4, 1, 1, 4, 4, 5, 3	3, 2, 4, 5, 1, 5, 4, 2, 5, 3
4	1, 1, 1, 4, 2, 1, 5, 5, 3, 4	1, 3, 1, 4, 2, 1, 5, 3, 4, 3
5	1, 1, 3, 5, 5, 3, 3, 4, 2, 4	1, 2, 3, 5, 5, 1, 3, 4, 2, 3
6	3, 2, 4, 3, 2, 1, 3, 4, 5, 3	3, 2, 4, 5, 2, 1, 3, 4, 5, 3
7	5, 2, 1, 4, 4, 3, 3, 3, 1, 3	5, 2, 1, 4, 2, 3, 5, 1, 2, 4
8	1, 3, 1, 4, 4, 5, 5, 3, 4, 3	1, 3, 1, 4, 2, 5, 3, 4, 5, 3
9	3, 3, 1, 4, 4, 5, 1, 3, 2, 3	3, 5, 1, 4, 5, 5, 1, 3, 2, 3
10	3, 3, 1, 3, 4, 5, 5, 2, 3, 3	3, 5, 1, 5, 4, 5, 2, 4, 3, 3

AMYO yöntemi sonrası bireylerin küresel optimuma yakınsamak için GZİ yöntemi kullanılır. Tüm bireylerde atanan her bir İHA için ilgili uçuş zincirlerinin maliyetleri hesaplanarak karşılaştırılır. Daha düşük maliyetli uçuş zincirleri, daha yüksek maliyetli zincirlerin yerine geçerek yeni bireyler oluşturulur. Her yeni birey, hedef fonksiyon aracılığıyla değerlendirilip

puanlanır. Eğer yeni birey yakıt ve zaman açısından daha üstün maliyet etkinliği sergiliyorsa, eski bireyin yerini alır.

Çizelge 4.30, Birey-1 için görev zinciri belirleme sürecini ve ilgili maliyetleri örneklendirmektedir. Birey-1 içerisindeki mevcut uçuş zincirleri maliyetleri Çizelge 4.30'un sol tarafında sunulurken, bu zincirlere ait hesaplanan yeni maliyetler (atanan her bir İHA için) çizelgenin sağ tarafında gösterilmektedir. Eğer bir İHA daha verimli bir zincir oluşturuyor ve amaç fonksiyonu karşılıyorsa, yeni oluşturulan birey orijinal bireyin yerini alır. Zincir maliyeti, yakıt tüketimi ve uçuş süresinin toplamı olarak tanımlanır.

Çizelge 4.30. Görev zinciri iyileştirme yöntemi işlem adımları

Görev No.	1	2	3	4	5	6	7	8	9	10	Görev No.	1	2	3	4	5	6	7	8	9	10
Birey 1	3	2	4	5	2	3	2	1	5	4	Birey 1	5	2	1	5	1	1	4	1	2	4
Mevcut Zincir İHA 2: [2, 5, 7] - Maliyet: 227.73											Yeni Zincir: [2, 8] - Maliyet: 124.77										
Mevcut Zincir İHA 3: [1, 6] - Maliyet: 519.61											Yeni Zincir: [4, 9] - Maliyet: 110.05										
Mevcut Zincir İHA 4: [3, 10] - Maliyet: 104.29											Yeni Zincir: [4, 10] - Maliyet: 89.74										
Mevcut Zincir İHA 5: [4, 9] - Maliyet: 346.46											Yeni Zincir: [4, 5] - Maliyet: 83.61										

Çizelge 4.31, AMYO yöntemi ile gerçekleştirilen bu işlemler sonucunda oluşturulan modifiye bireyleri ve bunların GZİ yöntemiyle elde edilmiş önceki versiyonlarını karşılaştırmalı olarak sunmaktadır.

Çizelge 4.31. AMYO ve GZİ yöntemleri ile üretilen bireyler

AMYO Yöntemi ile Üretilen Bireyler											GZİ Yöntemi ile Üretilen Bireyler										
Görev Seti	1	2	3	4	5	6	7	8	9	10	Görev Seti	1	2	3	4	5	6	7	8	9	10
Birey 1	3	2	4	5	2	3	2	1	5	4	Birey 1	5	2	1	5	1	1	4	1	2	4
Birey 2	5	2	4	3	2	1	5	2	3	4	Birey 2	1	2	1	3	1	1	3	2	3	4
Birey 3	3	2	4	5	1	5	4	2	3	3	Birey 3	5	2	1	5	1	1	5	2	3	4
Birey 4	1	3	1	4	2	1	5	3	4	3	Birey 4	5	2	1	4	2	3	5	2	2	4
Birey 5	1	2	3	5	5	1	3	4	2	3	Birey 5	5	2	4	5	5	3	5	4	3	4
Birey 6	3	2	4	5	2	1	3	4	5	3	Birey 6	5	2	1	5	1	1	5	1	2	4
Birey 7	5	2	1	4	2	3	5	1	2	4	Birey 7	1	2	1	4	1	3	3	1	3	4
Birey 8	1	3	1	4	2	5	3	4	1	3	Birey 8	5	2	1	4	2	5	5	1	2	4
Birey 9	3	5	1	4	5	5	1	3	2	3	Birey 9	5	2	1	4	5	1	5	2	2	4
Birey 10	3	5	1	5	4	5	2	4	3	3	Birey 10	5	2	1	5	2	1	2	1	3	4

Oluşturulan bireylerin İHA bazında ürettiği maliyetler Çizelge 4.32 ve 4.33'te sunulmaktadır. Sonuçların analizi, görev zinciri optimizasyon yönteminin yalnızca yakıt ve zaman

tüketimi metriklerini değil, aynı zamanda iniş ve kalkış oranlarını da önemli ölçüde değiştirdiğini göstermektedir. GZİ yöntemi, yakıt tüketiminde yaklaşık %31 (993,93 litre) ve zaman harcamasında %20 (1723,74 dakika) oranında üstün performans sağlamıştır. Bununla birlikte, toplam iniş sayısı GZİ yönteminde AMYO yöntemine göre %16,67 oranında artmıştır. Dikkat çekici biçimde, GZİ yöntemi yakıt ve zaman maliyetlerinde belirgin iyileştirmeler ortaya koymuştur. İniş sıklığındaki %16,7'lik artış her ne kadar riski artıran negatif bir metrik olsa da, uçuş süresindeki %20'lik azalma ve %14 daha az sayıda İHA tipinin kullanılması (toplamda 43 İHA) olumlu sonuçlar olarak değerlendirilmiştir.

Çizelge 4.32. AMYO yöntemiyle onarılan İHA'ların yakıt ve zaman maliyetleri

İHA	Toplam Yakıt	Toplam Süre	Toplam İniş Sayısı	Toplam Görev Rolü	Toplam Görev Seti Rolü
1	580.29	1002.05	15	17	10
2	351.25	913.89	19	19	10
3	1318.05	2765.56	19	26	10
4	459.89	598.16	18	18	10
5	515.63	3325.74	13	20	10
Toplam	3225.11	8605.4	84	100	50

Çizelge 4.33. GZİ yöntemiyle iyileştirilen İHA'ların yakıt ve zaman maliyetleri

İHA	Toplam Yakıt	Toplam Süre	Toplam İniş Sayısı	Toplam Görev Rolü	Toplam Görev Seti Rolü
1	748.38	1301.07	27	27	9
2	424.49	1104.41	23	23	10
3	340.98	876.45	11	11	6
4	310.03	407.15	17	17	10
5	407.3	3192.58	20	22	8
Toplam	2231.18	6881.66	98	100	43

AMYO yöntemi ile geçerliliği garanti edilen bireylerin oluşturduğu görev zincirlerine ilişkin yakıt ve zaman maliyetleri İHA bazlı olarak Çizelge 4.34'te ayrıntılı olarak sunulmaktadır. GZİ yöntemiyle gerçekleştirilen iyileştirmeler sonucu elde edilen İHA bazlı değerler ise Çizelge 4.35'te gösterilmektedir.

Çizelge 4.34. AMYO yöntemiyle onarılan görev setlerinde İHA'ların seyrüsefer metrikleri


Görev Seti	İHA	Görevler	Yakıt	Süre	Toplam Uçulan Görev Sayısı	İniş Sayısı
1	1	T8	10.1	20.93	1	1
	2	T2 → iniş → T5 → iniş → T7	63.22	164.51	3	3
	3	T1 → iniş → T6	151.63	367.98	2	2
	4	T3 → iniş → T10	45.18	59.11	2	2
	5	T4 → iniş → T9	36.54	309.92	2	2
2	1	T6	54.46	93.36	1	1
	2	T2 → iniş → T5 → iniş → T8	55.97	145.66	3	3
	3	T4 → iniş → T9	36.65	73.4	2	2
	4	T3 → iniş → T10	45.18	59.11	2	2
	5	T1 → iniş → T7	61.99	526.03	2	2
3	1	T5	23.22	39.8	1	1
	2	T2 → iniş → T8	34.64	90.13	2	2
	3	T1 → iniş → T9 → havada → T10	175.42	350.82	3	2
	4	T3 → iniş → T7	72.53	94.11	2	2
	5	T4 → havada → T6	71.54	345.43	2	1
4	1	T1 → havada → T3 → iniş → T6	141.55	242.65	3	2
	2	T5	17.91	46.6	1	1
	3	T2 → iniş → T8 → havada → T10	110.46	220.91	3	2
	4	T4 → iniş → T9	54	70.07	2	2
	5	T7	5.03	40.76	1	1
5	1	T1 → iniş → T6	109.37	187.49	2	2
	2	T2 → iniş → T9	35.08	91.22	2	2
	3	T3 → iniş → T7 → havada → T10	117.5	234.98	3	2
	4	T8	17.76	23.05	1	1
	5	T4 → havada → T5	8.82	74.79	2	1
6	1	T6	54.46	93.36	1	1
	2	T2 → iniş → T5	43.36	112.83	2	2
	3	T1 → iniş → T7 → havada → T10	193.16	386.31	3	2
	4	T3 → iniş → T8	57.3	74.34	2	2
	5	T4 → havada → T9	36.61	309.94	2	1
7	1	T3 → iniş → T8	27.63	51	2	2
	2	T2 → iniş → T5 → iniş → T9	57.56	149.79	3	3
	3	T6	58.48	181.69	1	1
	4	T4 → iniş → T10	38.85	50.89	2	2
	5	T1 → iniş → T7	61.99	526.03	2	2
8	1	T1 → havada → T3 → iniş → T9	102.33	175.44	3	2
	2	T5	17.91	46.6	1	1
	3	T2 → iniş → T7 → havada → T10	121.2	242.38	3	2
	4	T4 → iniş → T8	46.14	59.86	2	2
	5	T6	46.28	131.16	1	1
9	1	T3 → iniş → T7	41.66	71.43	2	2
	2	T9	9.77	25.37	1	1
	3	T1 → iniş → T8 → havada → T10	178.14	356.27	3	2
	4	T4	25.07	32.53	1	1
	5	T2 → havada → T5 → havada → T6	93.41	530.84	3	1
10	1	T3	15.51	26.59	1	1
	2	T7	15.83	41.18	1	1
	3	T1 → iniş → T9 → havada → T10	175.42	350.82	3	2
	4	T5 → iniş → T8	57.88	75.09	2	2
	5	T2 → havada → T4 → havada → T6	93.41	530.84	3	1

Çizelge 4.35. GZİ yöntemiyle onarılan görev setlerinde İHA'ların seyrüsefer metrikleri


Görev Seti	İHA	Görevler	Yakıt	Süre	Toplam Uçulan Görev Sayısı	İniş Sayısı
1	1	T3 → iniş → T5 → iniş → T6 → iniş → T8	103.29	180.68	4	4
	2	T2 → iniş → T9	35.08	91.22	2	2
	4	T7 → iniş → T10	52.29	68.33	2	2
	5	T1 → iniş → T4	9.47	80.31	2	2
2	1	T1 → iniş → T3 → iniş → T5 → iniş → T6	150.57	258.11	4	4
	2	T2 → iniş → T8	34.64	90.13	2	2
	3	T4 → iniş → T7 → iniş → T9	62.01	124.12	3	3
	4	T10	13.78	18.36	1	1
3	1	T3 → iniş → T5 → iniş → T6	90.72	155.52	3	3
	2	T2 → iniş → T8	34.64	90.13	2	2
	3	T9	19.55	39.2	1	1
	4	T10	11.16	14.97	1	1
	5	T1 → iniş → T4 → iniş → T7	64.91	550.82	3	3
4	1	T3	15.51	26.59	1	1
	2	T2 → iniş → T5 → iniş → T8 → iniş → T9	70.05	182.3	4	4
	3	T6	58.48	181.69	1	1
	4	T4 → iniş → T10	36.23	47.5	2	2
	5	T1 → iniş → T7	11.58	96.28	2	2
5	2	T2	25.33	65.91	1	1
	3	T6 → iniş → T9	78.02	220.76	2	2
	4	T3 → iniş → T8 → iniş → T10	62.94	82.16	3	3
	5	T1 → iniş → T4 → havada → T5 → iniş → T7	70.81	600.82	4	3
6	1	T3 → iniş → T5 → iniş → T6 → iniş → T8	105.31	184.16	4	4
	2	T2 → iniş → T9	35.08	91.22	2	2
	4	T10	11.16	14.97	1	1
	5	T1 → iniş → T4 → iniş → T7	64.91	550.82	3	3
7	1	T1 → iniş → T3 → iniş → T5 → iniş → T8	108.23	189.16	4	4
	2	T2	25.33	65.91	1	1
	3	T6 → iniş → T7 → iniş → T9	103.37	271.48	3	3
	4	T4 → iniş → T10	38.85	50.89	2	2
8	1	T3 → iniş → T8	27.63	51	2	2
	2	T2 → iniş → T5 → iniş → T9	57.44	149.47	3	3
	4	T4 → iniş → T10	36.23	47.5	2	2
	5	T1 → iniş → T6 → iniş → T7	108.27	657.19	3	3
9	1	T3 → iniş → T6	67.5	115.72	2	2
	2	T2 → iniş → T8 → iniş → T9	47.71	124.11	3	3
	4	T4 → iniş → T10	36.23	47.5	2	2
	5	T1 → havada → T5 → iniş → T7	67.89	576.03	3	2
10	1	T3 → iniş → T6 → iniş → T8	79.62	140.13	3	3
	2	T2 → iniş → T5 → iniş → T7	59.19	154.01	3	3
	3	T9	19.55	39.2	1	1
	4	T10	11.16	14.97	1	1
	5	T1 → iniş → T4	9.47	80.31	2	2

Şekil 4.12, 4.13 ve 4.15 GZİ yönteminin zaman ve yakıt maliyetleri açısından daha etkin değerler sağladığını göstermektedir. Şekil 4.14 ise, 10 farklı görev setinde (misyon) bulunan


toplam 100 görev boyunca İHA'ların toplam katılım sayılarını, iniş sayılarını ve atandıkları görev setlerini özetlemektedir.




Şekil 4.12. AMYO ve GZİ yöntemlerinin karşılaştırması



Şekil 4.13. İHA'lar bazında AMYO ve GZİ yöntemlerinin karşılaştırması



Şekil 4.14. AMYO ve GZİ yöntemlerinde İHA iniş sayılarının karşılaştırması



Şekil 4.15. GZİ ve AMYO yöntemleri ile üretilen bireylerin toplam yakıt ve süre karşılaştırması

4.5.2. AMYO – GZİ İstatistiksel Analiz Sonuçları

Süre (T) kapsamında GZİ ortalama -100.5 dk ($-\%12,7$) daha kısa süre üretse de fark anlamlı değildir ($t(15,88)=+1.23$, $p(\text{düz.})=0,236$). Etki büyüklüğü $g=-0.53$ ile orta; bootstrap %95 GA $[-251.7, +49.9]$ sıfırı içerir ve $P(B<A)=0.903$ ile GZİ lehine eğilim vardır. Mann–Whitney $p=0.241$ ile aynı sonuca gelmektedir.

Yakıt (F) yönünden GZİ ortalama -81.9 L ($-\%28,9$) daha az yakıt tüketmiştir; fark çok güçlü anlamlıdır ($t(17,58)=+5.66$, $p(\text{düz.})=<0,001$). Etki büyüklüğü $g=-2,43$ ile çok büyük; bootstrap %95 GA $[-109.0, -55.6]$ ve $P(B<A)=1.000$ (GZİ'yakıtta üstünlüğü pratik olarak kesindir). Mann–Whitney $p\approx 0,0006$ bu sonucu teyit eder.

İniş–Kalkış (İ/K_S) yönüyle GZİ iniş sayısı daha yüksektir (ort. 2.8 vs 1.5); Wilcoxon $p=0,034 \rightarrow$ GZİ emniyet/operasyon yükünü artırır (fazladan iniş-kalkış).

Operasyonel değerlendirme kapsamında eğer yakıt ekonomisi belirleyiciyse GZİ çok net üstün ($F\downarrow$). Emniyet/operasyon basitliği öncelikliyse, daha az iniş yapan AMYO rasyonel bir alternatiftir. Süredeki iyileşme eğilimi ($T\downarrow$) GZİ lehine olsa da istatistiksel kanıt düzeyi sınırlıdır. Çizelge 4.36'da yöntemlerin ürettiği çıktıların istatistiki olarak anlamlılığını gösteren test sonuçları paylaşılmıştır.

Çizelge 4.36. AMYO-GZİ yöntem çıktılarının istatistiki değerlendirilmesi

Ölçüt	Yöntem	n	Ort.	SS	%95 GA	Welch t (df)	P (Welch)	p (düz.)	p (M-W U)	Hedges g	Bootstrap $\Delta (B-A)$ [GA]	P (Üstünlük)
<i>Süre (dk)</i>	AMYO	10	790.19	147.48	[684.69, 895.70]	+1.23 (15.88)	0.236	0.236	0.241	-0.528	-100.51 [-251.66, +49.91]	0.903
	AMFR	10	688.16	209.54	[531.27, 845.06]							
<i>Yakıt (L)</i>	AMYO	10	283.40	31.00	[261.78, 305.01]	+5.66 (17.58)	<0.001	<0.001	0.0006	-2.425	-81.92 [-109.02, -55.57]	1.000
	AMFR	10	201.49	23.16	[184.58, 218.40]							
<i>İ/K_S (adet)</i>	AMYO	10	1.5	—	—	—	—	—	—	—	—	—
	AMFR	10	2.8	—	—	—	—	—	Wilcoxon p=0.034	—	—	—

4.5.3. AMYO – GZİ Karşılaştırma Test Yorumu

10 görev seti içerisinde yer alan toplam 100 görev de 7 farklı İHA değerlendirilmiştir. İHA-6 ve İHA-7, kriterlere uygunluk sağlamadığı için görev atamalarından çıkarılmıştır, döner kanatlı olan bu İHA'ların maliyet etkin olmadığı başarıyla fark edilerek uçuşlara dahil edilmediği gözlenmiştir. GZİ ve AMYO yöntemleri kapsamında kalan 5 İHA'nın yakıt ve zaman maliyetleri karşılaştırmalı olarak analiz edildiğinde, GZİ yönteminin yakıt tüketimi ve uçuş süresinde yaklaşık üçte birlik bir optimizasyon sağladığı belirlenmiştir. Ancak, bu verimlilik AMYO yöntemine kıyasla toplamda 14 ek iniş/kalkış (toplam 98 iniş) gerektirmiştir.

GZİ yöntemi kapsamında ortaya çıkan iniş/kalkış sayılarındaki artış, yöntemin yakıt ve zaman maliyetlerini azaltmaya yönelik önceliğiyle tutarlıdır. Önerilen model, görevlerin risk toleransına uygun biçimde düzenlenebilen müdahaleler yoluyla risk seviyesinin etkin olarak ayarlanabileceğini göstermektedir. Örneğin, uçuş sırasında İHA'ların yeniden görevlendirilmesinin teşvik edilmesi—yakıt ve zaman maliyetlerine kıyasla dengelenerek—maliyetlerin kontrollü biçimde ayarlanmasıyla risk azaltımına olanak tanımaktadır.

Görevlerin lokal olarak gereksinimlerini karşılayacak şekilde oluşturulan çözümlerin geçerli çözüm uzayında olmama ihtimalleri bulunsa da önerilen adaptif mutasyon yöntemiyle geçerli çözüm bulma oranı çok daha yüksektir. Üretilen çözümlerin global optimuma ne kadar yakın olduğu bilinmemektedir. Fakat İZKTP sürecinde üretilen bireyler ile kıyaslanarak çözüm kalitesi karşılaştırılabilir. Bu bölümde vurgulanması gereken diğer bir değer husus, İZKTP yaklaşımında geçerli bir çözümün bulunabilmesi amacıyla kullanılan hibrit ve kompleks

yöntemlerin karmaşıklığı $n^2 * \log n$ iken; adaptif mutasyonda ilgili problem, $n * \log n$ karmaşıklığında çözülebilmektedir. Zaman karmaşıklığı açısından önerilen adaptif mutasyon yaklaşımının tercih edilebileceği görülmektedir. İZKTP ve AMFR yöntemlerinin ayrıntılı incelemesi 4.6’da sunulmuştur.

4.6. İZKTP ve AMFR Karşılaştırma Testleri

İZKTP ve AMFR yöntemleri, problemi farklı açılardan ele alan iki ayrı yaklaşımı temsil etmektedir. İZKTP, optimizasyon sırasında yerel perspektifi yatay biçimde genişletmeye odaklanan sıralı bir karar alma süreci önermektedir. Buna karşılık AMFR yöntemi, hızlı yerel karar almanın ardından çözümü düzeltip geliştirmek amacıyla küresel ölçekte iyileştirme gerçekleştirmeyi hedeflemektedir.

İZKTP yöntemiyle gerçekleştirilen simülasyon sonuçları, AMFR yönteminde olduğu gibi İHA temelli metriklerle özetlenmiş ve Çizelge 4.37 – 4.41’de sunulmuştur. Çizelge 4.37, 10 görev setinde her bir İHA’ya atanan görevleri, iniş/kalkış sayılarını ve toplam görev katılım sayılarını ayrıntılı olarak içermektedir.

Çizelge 4.37. İZKTP ile üretilen İHA bazlı uçuş metrikleri

Görev Seti	İHA	Görevler	Yakıt	Süre	Toplam Uçulan Görev Sayısı	İniş Sayısı
1	1	T1 →hava→ T3 →iniş→ T5 →iniş→ T6 →iniş	158.45	277.79	4	3
	3	T2 →iniş→ T8 →hava→ T10 →iniş	110.29	221.04	3	2
	4	T4 →iniş→ T9 →iniş	54.78	70.56	2	2
	5	T7 →iniş	5.02	40.38	1	1
2	1	T2 →iniş→ T8 →iniş	49.14	84.29	2	2
	3	T4 →iniş→ T6 →iniş	147.55	215.56	2	2
	4	T3 →iniş→ T5 →iniş→ T9 →iniş→ T10 →iniş	137.56	122.55	4	4
	5	T1 →iniş→ T7 →iniş	11.58	127.8	2	2
3	1	T3 →iniş	12	27.4	1	1
	2	T8 →iniş	8.23	24.64	1	1
	3	T2 →iniş→ T7 →iniş	53.29	107.4	2	2
	4	T9 →iniş→ T10 →iniş	23.78	31.64	2	2
	5	T1 →hava→ T4 →hava→ T5 →hava→ T6 →iniş	61.74	527.61	4	1
4	1	T1 →iniş→ T5 →iniş→ T6 →iniş	119.45	238.7	3	3
	2	T7 →iniş	16.23	41.19	1	1
	3	T2 →iniş→ T8 →iniş	45.28	90.02	2	2
	4	T3 →iniş→ T9 →iniş→ T10 →iniş	55.78	87.55	3	3
	5	T4 →iniş	3	24.87	1	1
5	1	T1 →iniş→ T5 →iniş→ T6 →iniş	119.45	238.7	3	3
	2	T7 →iniş	16.23	41.19	1	1
	3	T8 →iniş	12.28	24.32	1	1
	4	T3 →iniş→ T9 →iniş→ T10 →iniş	55.78	87.55	3	3
	5	T2 →hava→ T4 →iniş	25	210.21	2	1
6	1	T1 →iniş→ T5 →iniş→ T6 →iniş	119.45	238.7	3	3
	3	T4 →iniş→ T7 →hava→ T10 →iniş	112.57	224.86	3	2
	4	T3 →iniş→ T9 →iniş	51.39	81.22	2	2
	5	T2 →iniş→ T8 →iniş	10.36	83.38	2	2
7	1	T1 →iniş→ T5 →iniş→ T6 →iniş	119.45	238.7	3	3
	2	T7 →iniş	16.23	41.19	1	1
	3	T4 →iniş→ T9 →iniş	37.36	73.96	2	2
	4	T3 →iniş→ T10 →iniş	35.39	61	2	2
	5	T2 →iniş→ T8 →iniş	10.36	83.38	2	2
8	1	T1 →iniş→ T5 →iniş→ T7 →iniş	108.45	186.51	3	3
	2	T8 →iniş	8.23	24.64	1	1
	3	T3 →iniş	17	50.6	1	1
	4	T4 →iniş→ T9 →iniş→ T10 →iniş	59.17	76.88	3	3
	5	T2 →hava→ T6 →iniş	33.2	282.36	2	1
9	1	T1 →iniş→ T5 →iniş→ T6 →iniş	119.45	238.7	3	3
	2	T7 →iniş	16.23	41.19	1	1
	3	T4 →iniş	17.29	34.46	1	1
	4	T3 →iniş→ T9 →iniş→ T10 →iniş	55.78	87.55	3	3
	5	T2 →iniş→ T8 →iniş	10.36	83.38	2	2
10	1	T1 →iniş→ T5 →iniş→ T6 →iniş	119.45	238.7	3	3
	2	T7 →iniş	16.23	41.19	1	1
	3	T4 →iniş	17.29	34.46	1	1
	4	T3 →iniş→ T9 →iniş→ T10 →iniş	55.78	87.55	3	3
	5	T2 →iniş→ T8 →iniş	10.36	83.38	2	2

İZKTP ve AMFR yöntemlerinin zaman karmaşıklığı, Bölüm 4.6.1.'de ayrıntılı olarak incelenmiştir. AMFR yönteminde hesaplama yükünü azaltmak üzere karmaşıklığın sınırlandırılması, iniş/kalkış sayılarını artırmakta ve risk metriklerinin optimal olmayan değerler almasına neden olmaktadır. Hesaplama karmaşıklığının artmasının kabul edilebilir olduğu durumlarda hibrit bir yaklaşım tercih edilebilir.

AMFR ile karşılaştırıldığında, İZKTP'de gerçekleşen önemli ölçüde daha az iniş kalkış, risk azaltımı açısından önemli kazanımlar sağlandığını göstermektedir. Örneğin, GZİ (AMFR yönteminin son aşaması olan ve Çizelge 4.35'te GZİ adıyla sunulan değerler) ve İZKTP (Çizelge 4.37'de sunulan değerler) sonuçları karşılaştırıldığında İZKTP'nin 300 lt fazla yakıt dezavantajı varken 19 daha az iniş yapması ve toplam ~819 dk daha az havada kalması risk değerlendirmesi açısından İZKTP lehine bir avantaj sağlamaktadır. Çizelge 4.38'de İZKTP ve AMFR yöntemleri arasındaki fark özet şekliyle görülebilmektedir.

Çizelge 4.38. AMFR ve İZKTP ile üretilen bireyler

Gösterge	AMFR	İZKTP	Fark (İZKTP– AMFR)
Toplam yakıt tüketimi (L)	2 231	2 531	+300
İniş/kalkış sayısı	98	79	– 19
Toplam uçuş süresi (dk)	6 881,7	6 063	– 818,7

Elde edilen bu sonuçlar operasyonel önceliklerle tutarlıdır; zira kazaların büyük çoğunluğu iniş ve kalkış safhalarında gerçekleşmektedir. Dolayısıyla iniş sıklığının azalması, bakım maliyetlerinin ve risklerin düşürülmesini sağlar. Bu durumda, daha az iniş/kalkış için daha fazla yakıt tüketimi yapılması, kaynak verimliliği ile risk azaltımı arasında kritik bir denge oluşturmakta ve tercih edilebilir bir ödünleşme (trade-off) olarak değerlendirilmektedir.

Çizelge 4.39'te, her iki yöntemle oluşturulan bireylerde görev ataması yapılan İHA'lar gösterilmiştir. Çizelge 4.40, farklı iterasyonlar boyunca bireylere ilişkin yakıt ve zaman maliyetlerini sunmaktadır. Çizelge 4.41'de İZKTP yöntemiyle üretilen 10 görev setlik uçuşta görev alan her İHA'nın maliyet istatistikleri yer almaktadır. Şekil 4.16 ise, her iki yönteme ait bireylerin yakıt ve zaman maliyetlerini 10 görev seti genelinde karşılaştırmaktadır. Elde edilen sonuçlar, İZKTP yönteminin toplam görev süresi bakımından maliyet etkin olduğunu, ancak daha yüksek yakıt tüketimi sergilediğini göstermektedir.

Çizelge 4.39 AMFR ve İZKTP ile üretilen bireyler

AMFR Yöntemi ile Üretilen Bireyler										
Görev No.	1	2	3	4	5	6	7	8	9	10
Birey 1	5	2	1	5	1	1	4	1	2	4
Birey 2	1	2	1	3	1	1	3	2	3	4
Birey 3	5	2	1	5	1	1	5	2	3	4
Birey 4	5	2	1	4	2	3	5	2	2	4
Birey 5	5	2	4	5	5	3	5	4	3	4
Birey 6	5	2	1	5	1	1	5	1	2	4
Birey 7	1	2	1	4	1	3	3	1	3	4
Birey 8	5	2	1	4	2	5	5	1	2	4
Birey 9	5	2	1	4	5	1	5	2	2	4
Birey 10	5	2	1	5	2	1	2	1	3	4


İZKTP Yöntemi ile Üretilen Bireyler										
Görev No.	1	2	3	4	5	6	7	8	9	10
Birey 1	5	1	3	5	1	5	1	3	2	3
Birey 2	1	3	1	4	1	1	5	3	4	3
Birey 3	5	1	4	3	4	3	5	1	4	4
Birey 4	5	3	1	5	5	5	3	2	4	4
Birey 5	1	3	4	5	1	1	2	3	4	4
Birey 6	1	5	4	5	1	1	2	3	4	4
Birey 7	1	5	4	3	1	1	3	5	4	3
Birey 8	1	5	4	3	1	1	2	5	3	4
Birey 9	1	5	3	4	1	5	1	2	4	4
Birey 10	1	5	4	3	1	1	2	5	4	4

Çizelge 4.40. AMFR ve İZKTP ile üretilen bireylerin yakıt ve süre metrikleri

Toplam İterasyon		İ ₁	İ ₂	İ ₃	İ ₄	İ ₅	İ ₆	İ ₇	İ ₈	İ ₉	İ ₁₀	Toplam
İZKTP	Süre (dk.)	867.3	609.76	550.19	718.69	482.32	601.96	628.15	498.22	620.98	485.27	6062.92
	Yakıt (lt)	271.3	328.53	345.83	159.03	239.73	228.73	293.77	218.78	226.04	219.10	2530.94
AMFR	Süre (dk.)	420.54	490.72	850.64	534.36	969.65	841.17	577.44	905.16	863.36	428.62	6881.66
	Yakıt (lt)	200.13	260.99	220.98	191.84	237.09	216.46	275.78	229.56	219.32	178.99	2231.18


Çizelge 4.41. İZKTP yöntemiyle üretilen 10 görev setlik İHA uçuş metrikleri

İHA	Toplam Yakıt	Toplam Süre	Toplam İniş Sayısı	Toplam Görev Sayısı	Görev Setlerinde Kullanılma Sayısı
1	1,032.54	1,919.85	24	28	10
2	91.43	239.40	5	7	7
3	651.19	1,256.22	15	20	10
4	529.41	706.50	19	24	9
5	226.38	1,940.96	16	21	10
Toplam	2,530.95	6,062.93	79	100	43




Şekil 4.16. AMFR ve İZKTP ile üretilen bireylerin yakıt ve süre metrikleri

Şekil 4.17 ve Şekil 4.18 de sırasıyla AMFR ve İZKTP yöntemleri ile 10 görev seti boyunca kullanılan İHA'ların ısı haritası yer almaktadır. Isı haritaları iki algoritmanın İHA tahsisinde nasıl farklı davrandığını açıkça gösterir. AMFR, görevlerin büyük bölümünde “farklı İHA seçme” eğilimindedir: aynı göreve bazen düşük (1) bazen yüksek (5) puan alan araçlar atamıştır, dolayısıyla görev-görev seçim deseninin çeşitliliği yüksektir. Bunu istatistikte “Shannon entropisi” adı verilen –seçimlerin ne kadar dağınık olduğunu ölçen– gösterge ile de doğruluyoruz: değer yükseldikçe algoritmanın değişik seçenekler kullandığı anlaşılır. Buna karşılık İZKTP, on görevden sekizinde en sık görülen puanın 4 veya 5 olduğunu, yani çoğu kez aynı (ve göreve yüksek puan veren) araçları tekrar tekrar seçtiğini gösterir. Her iki yöntem de Görev 1 ve 4'te aynı İHA'yı seçerek bu görevlerin kısıtlarının en belirleyici faktör olduğunu göstermektedir. Diğer taraftan AMFR rasgelelik yaklaşımının etkileri gözlemlenirken İZKTP'nin kurallara sıkı sıkıya bağlı olduğu ortaya konmaktadır.



Şekil 4.17. AMFR ile üretilen bireylerde kullanılan İHA'ların görevlere göre kullanım sıklığı



Şekil 4.18. İZKTP ile üretilen bireylerde kullanılan İHA'ların görevlere göre kullanım sıklığı

Özetle, AMFR görevler arasında İHA kullanımını çeşitlendirerek arızalara veya beklenmedik durumlara karşı esneklik sağlar; ancak koordinasyon çabası artabilir. İZKTP ise dar bir İHA grubuna yoğunlaşarak bakım ve hazırlık sürelerini kısaltır, fakat aynı hava araçlarını sürekli yüklendiği için tekil arızalara karşı daha hassas hâle gelir. Bu nedenle, görevin önceliği

dayanıklılık ve yük dengeleme ise AMFR, hızlı lojistik ve zaman kazancı ise İZKTP tercih edilmelidir.

Çerçeve, ölçülebilir risk etkisi ve uyarlanabilirliği başarılı şekilde göstermiş; saha özelindeki parametrelerin modele kolayca entegre edilebileceği ortaya koyulmuştur. İZKTP ve AMFR yöntemlerinin karşılaştırmalı analizinde, performans açısından belirgin bir değiş tokuş (trade-off) gözlenmiştir: İZKTP yöntemi, toplamda 2,530 litre yakıt tüketimi, 6,063 dakika uçuş süresi ve 92 iniş gerçekleştirmiştir; AMFR yöntemi ise 2,230 litre yakıt tüketimi, 6,880 dakika uçuş süresi ve 98 inişle görevleri tamamlamıştır. Özellikle, İZKTP'nin AMFR'ye göre 300 litre daha fazla yakıt tüketmesine rağmen, uçuş süresini 800 dakika ve iniş sayısını 6 azaltması, operasyonel riski belirgin biçimde düşürmüştür. Bu avantaj, iniş sırasında kaza riskinin yüksek olması sebebiyle kritik önem taşımaktadır. Hesaplama karmaşıklığı açısından bakıldığında, AMFR yöntemi verimliliği önceliklendirerek kaynak kısıtı olan ortamlar için uygun bir yöntem olarak öne çıkarken; İZKTP yöntemi ise problemi daha derinlemesine optimize ederek, donanım kısıtlarının bulunmadığı geniş ölçekli senaryolar için daha uygun olmaktadır.

4.6.1. İZKTP – AMFR İstatistiksel Analiz Sonuçları

Süre (T) yönüyle AMFR, İZKTP'ye kıyasla ortalama +82.4 dk (+%14,5) daha uzun görünmektedir; fark anlamlı değildir ($t(13,96)=-1,05$, $p(\text{düz.})=0,311$). Etki büyüklüğü $g=+0,45$ (küçük-orta); bootstrap %95 GA $[-63.7, +221.1]$ sıfırı içerir, $P(B<A)=0.135$ (AMFR'nin daha hızlı olma olasılığı düşük). Mann–Whitney $p\approx 0,678$ ile uyumludur.

Yakıt (F) yönüyle AMFR'nin yakıtı ortalama -30.2 L ($-\%11,9$) daha düşük yönde eğilim gösterse de fark anlamlı değildir ($t(13,60)=+1.48$, $p(\text{düz.})=0.323$). Etki büyüklüğü $g=-0,63$ (orta); bootstrap %95 GA $[-68.3, +7.7]$ ve $P(B<A)=0.943$ ile AMFR lehine eğilim mevcuttur. Mann–Whitney $p\approx 0,064$ sınırdan ama $0,05$ 'i geçer.

İniş–Kalkış (İ/K_S) yönüyle ortalama değerler neredeyse eşit (İZKTP 2.7, AMFR 2.8); Wilcoxon $p=0.855$ değerleri fark yoktur olarak yorumlanabilir.

Operasyonel değerlendirme de bu çiftte istatistiksel eşdeğerlik hakimdir: $T \approx, F \approx, İ/K_S \approx$. Saha/lojistik kısıtlarına (ör. Yakıt ikmal tankeri mevcudiyeti, pist doygunluğu, görev penceresi) göre her iki yöntem de kabul edilebilir; yakıt odaklı sahalarda AMFR'nin hafif avantaj eğilimi not edilebilir. Çizelge 4.42'de yöntemlerin ürettiği çıktıların istatistiki olarak anlamlılığını gösteren test sonuçları paylaşılmıştır.

Çizelge 4.42. İZKTP-AMFR yöntem çıktılarının istatistiki değerlendirmesi

Ölçüt Yöntem	n	Ort.	SS	%95 GA	Welch t (df)	p (Welch)	p (düz.)	p (M-W U)	Hedges g	Bootstrap Δ (B-A) [GA]	p (Üstünlük)	
Süre (dk)	İZKTP	10	567.42	157.36	[447.63, 687.22]	-1.05 (13.96)	0.311	0.311	0.678	+0.450	+82.38 [-63.65, +221.06]	0.135
	AMFR	10	688.16	209.54	[531.27, 845.06]							
Yakıt (L)	İZKTP	10	253.09	56.73	[212.51, 293.68]	+1.48 (13.60)	0.162	0.323	—	-0.634	-30.20 [-68.27, +7.65]	0.943
	AMFR	10	223.12	29.74	[201.84, 244.40]							
i/K_S (adet)	İZKTP	10	2.7	—	—	—	—	—	—	—	—	—
	AMFR	10	2.8	—	—	—	—	—	Wilcoxon p=0.855	—	—	—

4.6.2. İZKTP – AMFR Karşılaştırma Test Yorumu

Model Basitliği: İZKTP modeli, görev çiftleri ve bunların karşılıklı bağımlılıklarını CSP yöntemleri kullanarak derinlemesine analiz eder ve her bir görevin sonraki görevler üzerindeki etkisini kapsamlı biçimde optimize eder. Buna karşılık AMFR modeli, daha basit fakat etkileşimli bir yaklaşım benimseyerek, uygulanabilirliği görev bazında kontrol eder; dinamik kısıt uyumsuzluklarını yerel onarımlarla çözer ve son olarak küresel bir restorasyon aşaması gerçekleştirir.

Hesaplama Maliyeti: İZKTP, büyük bir çözüm uzayında (çok sayıda görev ve İHA içeren durumlarda) GT, YT ve İK süreçlerinin hibritlenerek kullanılmasını gerektirir. Diğer taraftan AMFR, kısıtları daha yerel ve modüler biçimde kontrol ederek daha düşük zaman ve bellek maliyetleriyle çalışır.

Optimumluk: AMFR, küresel optimumu garanti etmese de, büyük ölçekli problemler için kabul edilebilir kalitedeki çözümlere daha hızlı şekilde ulaşır, sürpriz etkisi yaratan local optimum'dan kaçabilen sonuçlar elde edilebilir. İZKTP teorik olarak yerel optimum sağlayan daha kesin sonuçlar elde edebilir; ancak hesaplama maliyetleri ve çalışma süreleri açısından pratik güçlükler oluşturabilir.

AMFR algoritmasının temel iş akışının zaman karmaşıklığı, parametrelere bağlı olarak yaklaşık olarak $O(M \times T \times A^2)$ veya $O(M \times T \times A)$ olarak ifade edilebilir:

- T: Görev sayısı
- A: İHA (uçak) sayısı

- D: Görevler için uygun atama alanının boyutu (domain büyüklüğü)
- M: Değerlendirilen görev seti (senaryo) sayısı

Burada A^2 , İHA atama çakışmalarını kontrol eden iç döngülerden kaynaklanabilirken, $M \times T \times A$ ise optimizasyon fonksiyonlarının karmaşıklığını göstermektedir. Tek seferlik raporlama maliyeti ise $O(A) - O(A^2)$ arasında kalmaktadır.

İZKTP yönteminde ise süreç, atamanın kısıtlarla uyumluluğunun kontrol edilmesini içerir; eğer uyumluysa bir sonraki göreve geçilir, değilse Gİ ile farklı atamalar denenir. Bu kontroller genellikle sabit $O(1)$ ya da $O(T)$ zamanda gerçekleştirilir. En kötü durumda, saf Gİ ile CSP aramasının karmaşıklığı tüm değişkenlerde tekrar tekrar Gİ uygulanması durumunda ortaya çıkan $O(D^T)$ 'dir. Bu yöntemdeki tek seferlik raporlama maliyeti ise $O(T)$ ve $O(D^T)$ arasındadır.

Önerilen İZKTP yönteminin hesaplama karmaşıklığı analiz edildiğinde, görev ve İHA sayısı ile birlikte zaman karmaşıklığının üstel biçimde arttığı ortaya çıkmıştır; bu durum, büyük ölçekli simülasyonları (örneğin 1000 iterasyon) hesaplama açısından uygulanamaz hâle getirmektedir. Bu nedenle deneysel doğrulama çalışmaları, hesaplanabilirliği garanti etmek amacıyla 10 görev seti (100 görev) ile sınırlanmıştır.

5. ARAŞTIRMA SONUÇLARI VE ÖNERİLER

Kısıt Tatmin Problemi'ne (KTP) ait mevcut model, herhangi bir hazır çözücü (solver) kullanmaksızın yeniden yazılmış ve giderek artan bir ihtiyaç olan uçuş görev planlaması problemine başarıyla uyarlanabilmiştir. KTP yaklaşımının bu probleme entegre edilmesi, hem klasik KTP tanımının (değişkenlerin belirli kısıtları tatmin etmesi) ötesinde tatmin edenlerden en iyisinin seçimi hem de operasyonel açıdan İHA görev dağılımlarına özgü çok sayıda kısıtın bir model çatısı altında ele alınmasını sağlamıştır. KTP'nin zengin kısıt tanımlama yapısı, gerçek dünya kurgularında dahi makul çözümler üretebilmeyi kolaylaştırmıştır.

Bu çalışmada önerilen İyileştirilmiş ZKTP yaklaşımı, görev planlamasını bir Kısıt Tatmin Problemi (KTP) olarak formüle etmiş ve kısıt tatmin tekniklerini hibritleyerek çözmüştür. Ancak, gerçek dünya problemlerine daha yakın bir modelleme yapıldığında ve kısıtlar arttığında, çözüm maliyeti NP-zor bir problem olması sebebiyle üstel karmaşıklık göstermektedir. Bu noktada, tam yöntemler (complete methods) olarak ifade edilebilecek KTP yöntemlerinin metasezgisel yöntemler ile hibritlenmesi, karmaşıklığı azaltmak ve geniş çözüm uzayında etkili çözümlere ulaşmak için kaçınılmaz hale gelmektedir. Önerilen İZKTP'de bulunan çözümler ve çözüm uzayı taranırken ulaşılan loglar, metasezgisel algoritmaların arama kapasitesini artırarak çözüm uzayında daha başarılı sonuçlara ulaşmayı sağlamaktadır. Bu amaçla, ZKTP modeli iyileştirilmiş ve geliştirilen AMFR gibi metasezgisel algoritmanın arama yönünü belirlemek için hedefler tanımlanmış, böylece arama uzayı daraltılmıştır. Bu çalışmada, etkili çıktılar elde edebilmek amacıyla önerilen Gİ yöntemi, yalnızca kısıtları tatmin eden seçenekleri değil, aynı zamanda göreve atanabilecek en uygun seçeneği bulmak için kullanılmıştır. ZKTP'ye entegre edilmek üzere geliştirilen matematiksel model, yakıt ve süre maliyetlerini düşürmek, riskleri minimize etmek amacıyla başarılı bir şekilde test edilmiştir. Ayrıca, hibrit yaklaşım ile dinamik etki alanı yöntemi, İK ve YT yöntemleri birleştirilerek ZKTP'ye entegre edilmiştir. Böylece, ardışıl görevlerde iniş yapmadan sıradaki görev(ler)in yerine getirilmesi ZKTP'ye adapte edilmiştir. Farklı İHA tiplerinin yakıt depoları ve tüketimleri göz önünde bulundurularak, İHA tiplerinin görev uygunlukları etkili bir şekilde değerlendirilmiştir. Ayrıca, havadaki İHA'ların iniş yapmadan ikinci bir göreve atanmasının risk azaltıcı yönü, formülde teşvik edici bir katsayı ile tanımlanmıştır.

Çalışma hem operasyonel maliyetlerin düşürülmesi hem de zaman tasarrufu ve risk minimizasyonu açısından İZKTP'nin etkinliğini ortaya koymaktadır. Diğer yandan ZKTP

modeline entegre edilen hibrit yöntem ile ardışıl görevleri havadaki en uygun İHA'nın yapabilmesi olası çözüm uzayını genişletmiştir, çünkü İHA'nın nereye ineceği artık sadece tamamlanan görev konumuyla bağlantılı değil aynı zamanda atanabileceği yeni görevler ile yakından ilintilidir. Görevler bağımsız kabul edilmekle birlikte, İHA'nın mevcut görevini tamamlamış olması ve dinamik kısıtları sağlaması (yakıt, zaman, faydalı yük vb.) sonraki görevlere atanabilmesi için gerekli ön kısıtları ifade eder. Bu kısıtlar, bağımsız görevleri temsil eden çözüm uzayı üzerinde dinamik bir filtreleme etkisi yapar. Bu duruma göreve atanan İHA'ların sonraki diğer n adet göreve planlanabilmesi ya da m adet havaalanına iniş/kalkış yapabilmesi durumu olasılık uzayına eklenirse çözüm uzayı devasa boyutlara (örneğin, trilyonlarca) sahip olabilir. Böylesine bir problemde tüm seçeneklerin kaba kuvvetle denenemeyeceği gibi gerekçelerle geniş çözüm uzayı olan problemlerde meta sezgisel yaklaşımın probleme adaptasyonu kaçınılmazdır.

İstatistiksel analizler bölümünde detaylıca ele alınan elde edilen sonuçlarla deneysel gözlemler arasındaki kısmi farklılıkların temel nedeni, kullanılan yöntemlerin doğası ve problem yapısındaki varyasyonlardır. Örneğin Welch t-testi ve Mann-Whitney U testleri, dağılım varsayımlarına farklı düzeylerde duyarlıdır; normal dağılım varsayımının sağlanmadığı veya varyansların homojen olmadığı senaryolarda parametrik ve parametrik olmayan yöntemlerin ürettiği p-değerleri arasında kaymalar gözlenmesi olağandır. Benzer şekilde, Hedges' g ile hesaplanan etki büyüklüğü istatistiksel anlamlılıktan bağımsız olarak pratik önem derecesini vurgulamakta, bu da küçük ama sistematik performans farklarının gözlemlerle uyumlu biçimde ortaya çıkmasını sağlamaktadır. Bootstrap güven aralıklarının bazı durumlarda test sonuçlarından daha geniş varyasyon göstermesi ise, senaryo bazlı rastgelelik ve görev zinciri değişimlerinin uçakların yakıt/zaman dengesine getirdiği oynaklıktan kaynaklanmaktadır. Dolayısıyla, yöntemler arasında ortaya çıkan farklılıklar bir çelişki değil, aksine analizlerin tamamlayıcı yönlerini göstermektedir; bu durum bulguların daha sağlam ve genellenebilir olduğunu desteklemektedir.

Bu gerekçelere istinaden gelecekteki çalışmalar kapsamında yakıt, faydalı yük, havada kalma süresi gibi maliyetlerin yanı sıra risk faktörlerinin entegrasyonuna yönelik görev içeriğinin riski (bölge hava durumu, engebeli arazi vb.), zamanlama ya da kaynak optimizasyonu gibi faktörlerin çok amaçlı optimizasyon ve pekiştirmeli öğrenme yöntemleriyle çeşitlendirilmesi tasarlanmaktadır. Gerçek dünya problemlerine yakınsamaya yönelik İHA'ların manevra yetenekleri, engebeli arazi koşulları, sinyalizasyon ve kullanıcı etkilerinin modele dahil edilmesi çalışmalarının yürütülmesi planlanmaktadır. Gerçek zamanlı uygulama desteği sağlama, görev

atamalarının önceliklendirmesini de dikkate alarak modellenmesi ve zorunlu ya da opsiyonel görevlerin ağırlıklandırılması konuları da gelecekte yapılması planlanan çalışmalardandır. Ayrıca, operasyonel iyileştirmelere yönelik hava üslerinin yeteneklerine göre iniş planlaması, havadaki yakıt ikmali yeteneklerinin eklenmesi, ses altı (subsonic) ve ses üstü (supersonic) ayrımlarına göre İHA atamaları, eşzamanlı ve gerçek zamanlı planlama mekanizmalarının geliştirilmesi hususları da mevcut modelin gerçek dünya koşullarına yakınsamasını sağlayacak ve daha karmaşık senaryolarda etkin çözümler sunulmasına olanak tanınacaktır.

Öneriler

Büyük ölçekli problemlerde İHA görev atama problemi, farklı görev tipleri (taarruz, keşif, lojistik vb.), farklı İHA filoları ve değişen operasyonel kısıtlar ile kolaylıkla boyut olarak büyüyebilir. İZKTP'nin yanı sıra adaptif mutasyon temelli yaklaşımın büyük veri üzerinde performans analizi yapılmalıdır.

Lokal optimum'dan kaçınma yöntemleri kapsamında İHA'ların etki alanında olduğu görevler konum ve başlama zamanlarına göre sıralanır ve hangi görevlerde daha etkin oldukları diğer İHA'larla kıyaslanabilir. Karşılaştırma sonucu önerilen matematiksel modele seçim yapma kriteri olarak eklenebilir. Lokal optimumdan kaçınmayı sağlaması açısından buna benzer birçok örnek etkin bir şekilde denenebilecek bir altyapı sağlanmıştır.

Gelecek çalışmalar hususunda Çok Amaçlı Optimizasyon (Multi-objective) kapsamında mevcut çalışmada sınırlı sayıda amaç fonksiyonuna odaklanılmış olabilir. Çok amaçlı optimizasyon yaklaşımlarıyla, maliyet, süre ve risk minimizasyonu gibi kriterlerin yanı sıra görev başarımları benzeri kriterler eklenerek aynı anda değerlendirilebilir. Gerçek zamanlı uygulama (Online Optimization) yönüyle İHA görev planlaması gerçek zamanlı değişikliklere (örneğin hava durumu, acil görevler, arıza vb.) karşı dinamik bir uyarlama gerektirebilir. Bu nedenle, geliştirilen modelin gerçek zamanlı veya yarı-gerçek zamanlı çalışabilmesi için uyarlamaların nasıl yapılacağı tartışılmalıdır. Hibrit yöntemlerin iyileştirilmesi kapsamında GA ile birlikte bölgesel arama (local search), tabu arama (tabu search) veya karınca kolonisi (ant colony) gibi farklı meta-sezgisel yöntemlerle hibrit yaklaşımlar denenebilir.

Sonuç olarak, KTP modelini İHA görev atama problemine entegre etme serüveninde; iyileştirilmiş kısıt tatmin modelleri sayesinde önce geçerli çözümler üretilmiş, ardından global optimuma doğru genişleyen bir iyileştirme aşaması kurgulanmıştır. Bu süreçte, GA'dan esinlenerek uygulanan adaptif mutasyon temelli AMFR yöntemi, lokal optimum engellerini aşma

konusunda önemli bir katkı sağlamıştır. KTP problemine adapte edilerek İHA görev atama problemi gibi karmaşık ve dinamik problemler için konseptin ispatı olarak geliştirilen İZKTP yönteminin yanı sıra evrimsel temelli AMFR uygulaması, ilerleyen çalışmalarda çok amaçlı, gerçek zamanlı ve büyük ölçekli senaryoları yönetme potansiyeline de sahip literatüre kazandırılan etkin yöntemler olarak değerlendirilmektedir.



KAYNAKÇA

- Abdulrahman, G. A., Qasem, N. A., Abdelrahman, W. G., & Abdallah, A. M. (2025). A review of powering unmanned aerial vehicles by clean and renewable energy technologies. *Sustainable Energy Technologies and Assessments*, 73, 104150.
- Achtelik, M. C., Stumpf, J., Gurdan, D., & Doth, K. M. (2011, 10). Design of a flexible high performance quadcopter platform breaking the MAV endurance record with laser power beaming. *. IEEE/RSJ International Conference on Intelligent Robots*, 5166-5172.
- Adbelhafiz, M., Mostafa, A., & Girard, A. (2010). Vehicle routing problem instances: Application to multi-uav mission planning. *AIAA Guidance, Navigation, and Control Conference*,
- Aggarwal, S., & Kumar, N. (2020). Path planning techniques for unmanned aerial vehicles: A review, solutions, and challenges. *Computer communications*, 149, 270-299.
- Alighanbari, M. B., Luca & How, Jonathan. (2004). Filter-Embedded UAV Task Assignment Algorithms for Dynamic Environments. In *(Doctoral dissertation)Task Assignment Algorithms for Teams of UAVs in Dynamic Environments* (pp. 5). Massachusetts Institute of Technology, Department of Aeronautics and Astronautics,.
- Alqudsi, Y., & Makaraci, M. (2025). UAV swarms: research, challenges, and future directions. *Journal of Engineering and Applied Science*, 72(1), 12.
- Amukele, T. (2022). Using drones to deliver blood products in Rwanda. *The Lancet Global Health*, 10(4), e463-e464.
- Atencia, C. R., Del Ser, J., & Camacho, D. (2019). Weighted strategies to guide a multi-objective evolutionary algorithm for multi-UAV mission planning. *Swarm and evolutionary computation*, 44, 480-495.
- Ayvaz, E., Atay, Y., & Babaoğlu, I. (2025a). Çoklu İHA'larla kısıt tatmin problemi temelli çok amaçlı görev planlaması. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 40(3), 1673-1688. <https://doi.org/10.17341/gazimmfd.1517020>
- Ayvaz, E., Atay, Y., & Babaoğlu, İ. (2025b). A Cutting-Edge Approach to Multi-UAV Mission Planning Using Enhanced Constraint Satisfaction. *Journal of Intelligent & Robotic Systems*, 111(3), 95.
- B. Bethke, M. V. a. J. P. H. (2008, 3). UAV Task Assignment. *IEEE Robotics & Automation Magazine*, vol. 15, no. 1., 39-44.
- Bayerlein, H., Theile, M., Caccamo, M., & Gesbert, D. (2021). Multi-UAV path planning for wireless data harvesting with deep reinforcement learning. *IEEE Open Journal of the Communications Society*, 2, 1171-1187.

- BOEING. (2023). *Statistical Summary of Commercial Jet Airplane Accidents – Worldwide Operations Boeing 2023*. <https://www.boeing.com/>. Retrieved January 11, from https://www.boeing.com/content/dam/boeing/boeingdotcom/company/about_bca/pdf/statsum.pdf
- Buşoniu, L., De Bruin, T., Tolić, D., Kober, J., & Palunko, I. (2018). Reinforcement learning for control: Performance, stability, and deep approximators. *Annual Reviews in Control*, 46, 8-28.
- Byung Duk Song, K. P., Jonghoe Kim. (2018). Persistent UAV delivery logistics: MILP formulation and efficient heuristic. *Computers & Industrial Engineering, Volume: 120*, 418-428.
- C Schumacher, P. C., M Pachter et al. (2003). UAV Task Assignment with Timing Constraints. *AIAA Guidance, Navigation, and Control Conference and Exhibit*, 5664.
- C. Ramirez-Atencia, G. B.-O., M. D. R-Moreno and D. Camacho,. (2014, 8 11). A simple CSP-based model for Unmanned Air Vehicle Mission Planning. *IEEE International Symposium on Innovations in Intelligent Systems and Applications (INISTA) Proceedings Alberobello, Italy*, 146-153.
- Cabreira, T. M., Brisolara, L. B., & Paulo R, F. J. (2019). Survey on coverage path planning with unmanned aerial vehicles. *Drones*, 3(1), 4.
- Chen, Y., Yang, D., & Yu, J. (2018). Multi-UAV task assignment with parameter and time-sensitive uncertainties using modified two-part wolf pack search algorithm. *IEEE Transactions on Aerospace and Electronic Systems*, 54(6), 2853-2872.
- De Almeida, D. R. A., Broadbent, E. N., Ferreira, M. P., Meli, P., Zambrano, A. M. A., Gorgens, E. B., Resende, A. F., de Almeida, C. T., Amaral, C. H. D., Corte, A. P. D., & al., e. (2021). Monitoring restored tropical forest diversity and structure through UAV-borne hyperspectral and lidar fusion. *Remote Sensing of Environment Vol:264*, 112582.
- Doherty, J. K. o., and F. Heintz. (2009, 12). A temporal logic-based planning and execution monitoring framework for Unmanned Aircraft Systems. *Autonomous Agents and Multi-Agent Systems*, vol. 19, no. 3, 332–377.
- Dorling, K., Heinrichs, J., Messier, G. G., & Magierowski, S. (2016). Vehicle routing problems for drone delivery. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 47(1), 70-85.
- Edison E, S. T. (2011). Integrated task assignment and path optimization for cooperating uninhabited aerial vehicles using genetic algorithms. *Computers & Operations Research* 38(1), 340–356.

- Eskandaripour, H., & Boldsai Khan, E. (2023). Last-mile drone delivery: Past, present, and future. *Drones*, 7(2), 77.
- Fargier, H., & Lang, J. (1993, 11). Uncertainty in constraint satisfaction problems: a probabilistic approach. *European Conference on Symbolic and Quantitative Approaches to Reasoning and Uncertainty*, 97-104.
- Floreano, D., & Wood, R. J. (2015). Science, technology and the future of small autonomous drones. *nature*, 521(7553), 460-466.
- Gao, H., Feng, J., Xiao, Y., Zhang, B., & Wang, W. (2022). A UAV-assisted multi-task allocation method for mobile crowd sensing. *IEEE Transactions on Mobile Computing*, 22(7), 3790-3804.
- Gao, S., Wu, J., & Ai, J. (2021). Multi-UAV reconnaissance task allocation for heterogeneous targets using grouping ant colony optimization algorithm. *Soft Computing, Vol:25*, 7155-7167.
- Geng, L., Zhang, Y., Wang, J., Fuh, J. Y., & Teo, S. (2014). Cooperative mission planning with multiple UAVs in realistic environments. *Unmanned Systems*, 2(01), 73-86.
- Geng, N., Chen, Z., Nguyen, Q. A., & Gong, D. (2021). Particle swarm optimization algorithm for the optimization of rescue task allocation with uncertain time constraints. *Complex Intell. Syst.*, 873-890.
- Ghambari, S., Golabi, M., Lepagnot, J., Bréviliers, M., Jourdan, L., & Idoumghar, L. (2020). An enhanced NSGA-II for multiobjective UAV path planning in urban environments. 2020 IEEE 32nd international conference on tools with artificial intelligence (ICTAI),
- Ghauri, S. A., Sarfraz, M., Qamar, R. A., Sohail, M. F., & Khan, S. A. (2024). A Review of Multi-UAV Task Allocation Algorithms for a Search and Rescue Scenario. *Journal of Sensor and Actuator Networks*, 13(5), 47.
- Haralick, R. M., & Elliott, G. L. (1980). Increasing tree search efficiency for constraint satisfaction problems. *Artificial intelligence*, 14(3), 263-313.
- Hiebert, B., Nouvet, E., Jeyabalan, V., & Donelle, L. (2020). The application of drones in healthcare and health-related services in north america: A scoping review. *Drones*, 4(3), 30.
- Hillier, F. S. (2001). *Introduction to operations research*. McGrawHill.
- Huang H, Z. T. (2019). Multi-model cooperative task assignment and path planning of multiple UCAV formation. . *Multimedia Tools and Applications* 78(1), 415-436.

- J. Gaowei, W. J., W. Peng, C. Qingyang and W. Yujie. (2019). Using Multi-layer Coding Genetic Algorithm to Solve Time-Critical Task Assignment of Heterogeneous UAV Teaming. International Conference on Control, Automation and Diagnosis (ICCAD, Grenoble, France.
- J. Turner, Q. M., G. Schaefer, A. Whitbrook and A. Soltoggio. (2018, 09). Distributed Task Rescheduling With Time Constraints for the Optimization of Total Task Allocations in a Multirobot System. *IEEE Transactions on Cybernetics* vol. 48, no. 9, 2583-2597.
- JF, A. (1983). Maintaining knowledge about temporal intervals. . *Commun ACM* 26(11), 832–843.
- Ji, X., & Zhao, Y. (2019, 8). Architecture Design for Unmanned Aerial Vehicle Mission Planning System. *2019 International Conference on Modeling, Simulation and Big Data Analysis*, 419-424.
- Jiang, M., Rocktäschel, T., & Grefenstette, E. (2023). General intelligence requires rethinking exploration. *Royal Society Open Science*, 10(6), 230539.
- Johannessen, K.-A., Comtet, H., & Fosse, E. (2021). A drone logistic model for transporting the complete analytic volume of a large-scale university laboratory. *International Journal of Environmental Research and Public Health*, 18(9), 4580.
- Jung, M., & Oh, H. (2022). Heterogeneous mission planning for a single unmanned aerial vehicle (UAV) with attention-based deep reinforcement learning. *PeerJ Computer Science*, 8, e1119.
- Jussien, N., Rochart, G., & Lorca, X. (2008). Choco: an open source java constraint programming library. *CPAIOR'08 Workshop on Open-Source Software for Integer and Constraint Programming* 1-10.
- Kong, X., Zhou, Y., Li, Z., & Wang, S. (2024). Multi-UAV simultaneous target assignment and path planning based on deep reinforcement learning in dynamic multiple obstacles environments. *Frontiers in Neurorobotics*, 17, 1302898.
- Li, J. T., Zhang, S., Zheng, Z., Xing, L. N., & He, R. J. (2017). Research on multi-UAV loading multi-type sensors cooperative reconnaissance task planning based on genetic algorithm. 13th International Intelligent Computing Theories and Application, Liverpool-UK.
- Li, M., Wang, Z., Li, K., Liao, X., Hone, K., & Liu, X. (2021). Task allocation on layered multiagent systems: When evolutionary many-objective optimization meets deep Q-learning. *IEEE Transactions on Evolutionary Computation*, 25(5), 842-855.
- Liu, D., Dou, L., Zhang, R., Zhang, X., & Zong, Q. (2022). Multi-Agent Reinforcement Learning-Based Coordinated Dynamic Task Allocation for Heterogenous UAVs. *IEEE Transactions on Vehicular Technology*, 1-12.

- Liu, J., Wang, W., Li, X., Wang, T., Bai, S., & Wang, Y. (2018). Solving a multi-objective mission planning problem for UAV swarms with an improved NSGA-III algorithm. *International Journal of Computational Intelligence Systems*, 11(1), 1067-1081.
- Low, A. M. (1916). The Pilotless Aircraft. *Flight*, 1916.
- Luo, W., Lü, J., Liu, K., & Chen, L. (2021). Learning-based policy optimization for adversarial missile-target assignment. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 52(7), 4426-4437.
- Ma, Y., Li, B., Huang, W., & Fan, Q. (2023). An improved NSGA-II based on multi-task optimization for multi-uav maritime search and rescue under severe weather. *J Marine Sci Eng* 11 (4): 781. In.
- Maw, A. A., Tyan, M., Nguyen, T. A., & Lee, J.-W. (2021). iADA*-RL: Anytime graph-based path planning with deep reinforcement learning for an autonomous UAV. *Applied Sciences*, 11(9), 3948.
- McGetrick, R. J. (1963). The Ryan Firebee. *Proceedings of the IEEE*.
- Meng, W., Zhang, X., Zhou, L., Guo, H., & Hu, X. (2025). Advances in UAV Path Planning: A Comprehensive Review of Methods, Challenges, and Future Directions. *Drones* (2504-446X), 9(5).
- Mills-Tettey, G. A., Stentz, A., & Dias, M. B. (2007). *The Dynamic Hungarian Algorithm for the Assignment Problem with Changing Costs*.
- Mohsan SAH, K. M., Noor F, Ullah I, Alsharif MH. (2022, 6). Towards the Unmanned Aerial Vehicles (UAVs): A Comprehensive Review. . *Drones* 6(6), 147.
- Nethercote, N., Stuckey, P. J., Becket, R., Brand, S., Duck, G. J., & Tack, G. (2007, 9). MiniZinc: Towards a standard CP modelling language. *In International Conference on Principles and Practice of Constraint Programming*, 529-543.
- P. E. Hart, N. J. N. a. B. R. (1968, July). A Formal Basis for the Heuristic Determination of Minimum Cost Paths," in *IEEE Transactions on Systems Science and Cybernetics*. *IEEE Transactions on Systems Science and Cybernetics Volume: 4, Issue: 2*, 100-107.
- P. Fabiani, V. F., A. Piquereau, R. Mampey, and F. TeichteilKonigsbuch. (2007). Autonomous flight and navigation of {VTOL} UAVs: from autonomy demonstrations to out-of-sight flights. *Aerospace Science and Technology*, vol. 11, no. 2-3, 183 – 193.
- P. Laroche, F. C., and R. Schott. (1999). Mobile robotics planning using abstract markov decision processes in Tools with Artificial Intelligence. 11th IEEE International Conference,

- Ramirez-Atencia, C., Bello-Orgaz, G., R-Moreno, M. D., & Camacho, D. (2017). Solving complex multi-UAV mission planning problems using multi-objective genetic algorithms. *Soft Computing*, 21, 4883-4900.
- Ramirez-Atencia, C., Bello-Orgaz, G., R-Moreno, M. D., & Camacho, D. (2015, 7). A hybrid MOGA-CSP for multi-UAV mission planning. *Proceedings of the Companion Publication of the 2015 Annual Conference on Genetic and Evolutionary Computation* 120.
- Richoux, F., Uriarte, A., & Baffier, J. F. (2016). Ghost: A combinatorial optimization framework for real-time problems. *IEEE Transactions on Computational Intelligence and AI in games* 8(4), 377-388.
- S. Yi, Z. L. a. J. L. (2019). Task Assignment of Heterogeneous UAV for Anti-radar Mission Using CTAP Models. *IEEE International Conference on Mechatronics and Automation (ICMA)*, Tianjin, China, 1980-1985.
- Secrest, B. (2001). Travelling salesman problem for surveillance mission using particle swarm optimization. In (pp. 3300-3307). *Biblioscholar*.
- Shakhatreh, H., Sawalmeh, A. H., Al-Fuqaha, A., Dou, Z., Almaita, E., Khalil, I., Othman, N. S., Khreishah, A., & Guizani, M. (2019). Unmanned aerial vehicles (UAVs): A survey on civil applications and key research challenges. *Ieee Access*, 7, 48572-48634.
- Shakoor, S., Kaleem, Z., Baig, M. I., Chughtai, O., Duong, T. Q., & Nguyen, L. D. (2019, 7 140665). Role of UAVs in Public Safety Communications Energy Efficiency Perspective. *. IEEE Access* 140679.
- Shin, J., Badgwell, T. A., Liu, K. H., & Lee, J. H. (2019). Reinforcement learning—overview of recent progress and implications for process control. *Computers & Chemical Engineering*, 127, 282-294.
- Shrestha, R., Bajracharya, R., & Kim, S. (2021, 9). 6G enabled unmanned aerial vehicle traffic management: A perspective. *IEEE Access* 9119-91136.
- Singh, M. K., Choudhary, A., Gulia, S., & Verma, A. (2023). Multi-objective NSGA-II optimization framework for UAV path planning in an UAV-assisted WSN. *The Journal of Supercomputing*, 79(1), 832-866.
- Song, B. D., Park, H., & Park, K. (2022). Toward flexible and persistent UAV service: Multi-period and multi-objective system design with task assignment for disaster management. *Expert Systems with Applications*, 206.
- Song J, Z. K., Liu Y. (2023). Survey on Mission Planning of Multiple Unmanned Aerial Vehicles. *Aerospace* 10(3), 208.

- Steven R. LaValle, J.-C. L. (1995). An Approach to Mission Planning for Unmanned Aerial Vehicles. *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*.
- Sullivan, C. J., & Bosanac, N. (2020). Using multi-objective deep reinforcement learning to uncover a pareto front in multi-body trajectory design. AAS/AIAA Astrodynamics Specialist Conference,
- T Shima, S. R., AG Sparks et al. (2006). Multiple task assignments for cooperating uninhabited aerial vehicles using genetic algorithms. *Computers & Operations Research*, vol. 33, no. 11. , 3252-3269.
- Theile, M., Bayerlein, H., Nai, R., Gesbert, D., & Caccamo, M. (2021). UAV path planning using global and local map information with deep reinforcement learning. 2021 20th International Conference on Advanced Robotics (ICAR),
- van Lieshout, M., & Friedewald, M. (2018). Drones—dull, dirty or dangerous?: The social construction of privacy and security technologies. In *Socially Responsible Innovation in Security* (pp. 25-43). Routledge.
- Vashisth, A., Patel, D., Conover, D., & Bera, A. (2024). Multi-Robot Informative Path Planning for Efficient Target Mapping using Deep Reinforcement Learning. *arXiv e-prints*, arXiv: 2409.16967.
- WALLACE, R. J., & FREUDER, E. C. (1998). Stable solutions for dynamic constraint satisfaction problems. *International Conference on Principles and Practice of Constraint Programming. Springer Berlin Heidelberg*, 447-461.
- Wang, X., Wang, H., Zhang, H., Wang, M., Wang, L., Cui, K., ... & Ding, Y. (2023). A mini review on UAV mission planning 19(5). *Journal of Industrial & Management Optimization*.
- Westheider, J., Rückin, J., & Popović, M. (2023). Multi-uav adaptive path planning using deep reinforcement learning. 2023 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS),
- X. Wu, Y. Y., L. Xu, X. Wu, F. Meng and R. Zhen. (2021). MULTI-UAV Task Allocation Based on Improved Genetic Algorithm. *IEEE Access*, vol. 9, 100369-100379.
- Xu G, L. T., Wang Z et al. (2020). Xu G, Long T, Wang Z et al (2020) Target-bundled genetic algorithm for multi-unmanned aerial vehicle cooperative task assignment considering precedence constraints. *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering* 234(3), 760–773.
- Xu, Y., Wei, Y., Jiang, K., Wang, D., & Deng, H. (2023). Multiple UAVs path planning based on deep reinforcement learning in communication denial environment. *Mathematics*, 11(2), 405.

- Yan, P., & Tan, B. (2013 6). Evolutionary group theoretic tabu search approach to task allocation of autonomous unmanned aerial vehicles. *10th IEEE International Conference on Control and Automation (ICCA)*, 687-692.
- Ye, F. C., Jie & Sun, Qian & Tian, Yuan & Jiang, Tao. (2021, 1). Decentralized task allocation for heterogeneous multi-UAV system with task coupling constraints. *The Journal of Supercomputing*, 77-86.
- Yu, S., & Dingcheng, D. (2023). Multi-Objective Mission Planning for UAV Swarm Based on Deep Reinforcement Learning. 2023 IEEE International Conference on Unmanned Systems (ICUS),
- Yue, L., Yang, R., Zhang, Y., Yu, L., & Wang, Z. (2022). Deep reinforcement learning for UAV intelligent mission planning. *Complexity*, 2022(1), 3551508.
- Zhang, C., & Kovacs, J. M. (2012). The application of small unmanned aerial systems for precision agriculture: a review. *Precision agriculture*, 13, 693-712.
- Zhang, X., & Chen, X. (2021). UAV task allocation based on clone selection algorithm. . *Wireless Communications and Mobile Computing*, 1-9.
- Zhao, X., Zong, Q., Tian, B., Zhang, B., & You, M. (2019). Fast task allocation for heterogeneous unmanned aerial vehicles through reinforcement learning. *Aerospace Science and Technology*, 92, 588-594.
- Zhenyue Jia, J. Y., Xiaolin Ai, Xuan Xu, Di Yang,. (2018). Cooperative multiple task assignment problem with stochastic velocities and time windows for heterogeneous unmanned aerial vehicles using a genetic algorithm. *Aerospace Science and Technology Vol:76*, 112-125.
- Zuo, L., Gao, S., Li, Y., Li, L., Li, M., & Lu, X. (2022). A fast and robust algorithm with reinforcement learning for large UAV cluster mission planning. *Remote Sensing*, 14(6), 1304.