

T.C.
BİTLİS EREN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

İHA DESTEKLİ İOT AĞLARINDA DERİN PEKİŞTİRMELİ
ÖĞRENME YOLUYLA AKILLI YANSITICI YÜZEY
DESTEKLİ VERİM MAKSİMİZASYONU

YÜKSEK LİSANS TEZİ

İDRİS ERTAŞ

DANIŞMAN

Dr. Öğr. Üyesi Halil YETGİN

OCAK 2024

BİTLİS

T.C.
BİTLİS EREN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

İHA DESTEKLİ İOT AĞLARINDA DERİN PEKİŞTİRMELİ
ÖĞRENME YOLUYLA AKILLI YANSITICI YÜZEY
DESTEKLİ VERİM MAKSİMİZASYONU

YÜKSEK LİSANS TEZİ

İDRİS ERTAŞ

ORCID: 0009-0007-2113-1412

DANIŞMAN

Dr. Öğr. Üyesi Halil YETGİN

OCAK 2024

BİTLİS

T.C.

BİTLİS EREN ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZ ÇALIŞMASI

ETİK BEYANI

Lisansüstü Eğitim Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı Yüksek Lisans öğrencisiyim. Hazırlamış olduğum “İHA Destekli IoT Ağlarında Derin Pekiştirmeli Öğrenme Yoluyla Akıllı Yansıtıcı Yüzey Destekli Verim Maksimizasyonu” başlıklı tezde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi; tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu; tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi; kullanılan verilerde herhangi bir değişiklik yapmadığımı; bu tezde sunduğum çalışmanın özgün olduğunu bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

...../...../20.....

İmza

İdris ERTAŞ

T.C.

BİTLİS EREN ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

TEZ YAZIM KILAVUZU UYGUNLUK BEYANI

“İHA Destekli IoT Ağlarında Derin Pekiştirmeli Öğrenme Yoluyla Akıllı Yansıtıcı Yüzey Destekli Verim Maksimizasyonu” başlıklı yüksek lisans Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kılavuzuna uygun olarak hazırlanmıştır.
...../...../20.....

Tezi Hazırlayan

İmza

İdris ERTAŞ

Danışman

İmza

Dr. Öğr. Üyesi Halil YETGİN

Elektrik Elektronik Mühendisliği Anabilim Dalı Başkanı

İmza

Prof. Dr. Sabir RÜSTEMLİ

T.C.
BİTLİS EREN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
TEZ ONAY SAYFASI

Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı öğrencisi İdris ERTAŞ tarafından hazırlanan “İHA Destekli IoT Ağlarında Derin Pekiştirmeli Öğrenme Yoluyla Akıllı Yansıtıcı Yüzey Destekli Verim Maksimizasyonu” adlı Yüksek Lisans Tezi ile ilgili tez savunma sınavı, 07/01/2024 tarihinde yapılmış ve tezin oy birliği ile kabul edilmesine karar verilmiştir.

JÜRİ:

İMZA

Danışman: Dr. Öğr. Üyesi Halil YETGİN

(Bitlis Eren Üniversitesi)

Üye: Dr. Öğr. Üyesi Emrullah SONUÇ

(Karabük Üniversitesi)

Üye: Dr. Öğr. Üyesi Erdal AKIN

(Bitlis Eren Üniversitesi)

Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü Yönetim Kurulunun tarih ve sayılı kararıyla jüri tarafından kabul edilmiş bu çalışmanın yüksek lisans tezi olarak kabulü onaylanmıştır.

..../...../2024

Doç. Dr. Mehmet Bakır ŞENGÜL

Enstitü Müdürü

T.C.

Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü

Elektrik Elektronik Mühendisliği

Anabilim Dalı

**İHA DESTEKLİ İOT AĞLARINDA DERİN PEKİŞTİRMELİ ÖĞRENME
YOLUYLA AKILLI YANSITICI YÜZEY DESTEKLİ VERİM
MAKSİMİZASYONU**

Yüksek Lisans Tezi

İdris ERTAŞ

Danışman: Dr. Öğr. Üyesi Halil YETGİN

OCAK 2024

ÖZET

Bu yüksek lisans tezi, Akıllı Yansıtıcı Yüzeyler (RIS) kullanılarak, Derin Pekıştirmeli Öğrenme yöntemiyle, İnsansız Hava Araçları (İHA) destekli Nesnelerin İnterneti (IoT) ağlarında verimliliği maksimize etmeyi ele almaktadır. Bu çalışmanın temel amacı, bir bölgedeki IoT cihazlarından veri toplayan bir İHA'nın, bu cihazlardan maksimum veriyi toplayabilmesini, enerji verimliliğini artırmasını ve hedef bölgeye güvenli bir şekilde inmesini sağlamaktır. Bu amaçla, çeşitli IoT cihazlarından veri toplamak için bir İHA görevlendirildi ve bu İHA farklı çevresel koşullar için eğitildi. Çalışma iki aşamadan oluşmaktadır. Aşama-1'de İHA'nın yön kapasitesini ve keşif kabiliyetini arttırmak için bir algoritma oluşturuldu. Aşama-2'de ise sisteme RIS dahil edilerek RIS'in etkisi incelendi.

RIS teknolojisi, IoT cihazları ile İHA arasındaki iletişimin güvenilirliğini, güvenliğini, kapasitesini ve kapsama alanını artırmak için kullanılmaktadır. Özellikle bir IoT cihazı ile İHA arasında doğrudan görüş olmadığı veya aralarında bir engel (bina, ağaç, vb.) bulunduğu, RIS, bir IoT cihazından gelen sinyalleri İHA'ya daha iyi iletmeye yardımcı olabilir. Bu çalışmada, RIS teknolojisinin kullanımının, IoT cihazları ile İHA arasındaki iletişimi geliştirdiğini ve enerji verimliliğini koruyarak toplanan veri miktarını artırdığını gösteriyoruz.

Simülasyon sonuçları, İHA'nın yön kapasitesi ve keşif kabiliyeti artırıldığında veri toplama performansını %8,18 ve birim enerji başına toplayabildiği veri miktarında %6,91 oranında artış sağladığı görülmektedir. Sisteme RIS teknolojisi dahil edildiğinde

de veri toplama performansını %10,7, birim enerji başına toplanan veri miktarını ise %22,64 artırdığını göstermektedir. Ayrıca, derin pekiştirmeli öğrenme algoritmalarından biri olan Double Deep Q-Network (DDQN) algoritması kullanılarak eğitilen İHA, IoT cihazlarından veri toplamak için en uygun rotayı belirledi ve başarıyla iniş yapabildi.

Sonuç olarak, bu çalışma, RIS teknolojisinin İHA destekli IoT ağlarında veri toplama ve enerji verimliliği açısından büyük potansiyele sahip olduğunu ortaya koymaktadır. Bu çalışmanın sonuçları, gelecekteki İHA destekli IoT uygulamalarının geliştirilmesi ve optimize edilmesi için kullanılabilir.

Anahtar Kelimeler: Akıllı Yansıtıcı Yüzey, İHA, Derin Pekiştirmeli Öğrenme, Nesnelerin İnterneti



Republic of Türkiye

Bitlis Eren University Graduate School

Department of Electrical and Electronics Engineering

**RECONFIGURABLE INTELLIGENT SURFACE (RIS) ASSISTED
THROUGHPUT MAXIMIZATION VIA DEEP REINFORCEMENT
LEARNING IN UAV-POWERED IOT NETWORKS**

Master's Thesis

İdris ERTAŞ

Supervisor: Asst. Prof. Halil YETGİN

JANUARY 2024

ABSTRACT

This master thesis deals with maximizing throughput using Reconfigurable Intelligent Surfaces (RIS) through Deep Reinforcement Learning in Unmanned Aerial Vehicle (UAV)-powered Internet of Things (IoT) networks. The main purpose of this study is to ensure that a UAV collecting data from IoT devices positioned in a region can collect maximum data from these devices, as well as increase energy efficiency and land safely in the target area. For this purpose, a UAV was deployed to collect data from various IoT devices more effectively and this UAV was trained for different environmental conditions. The study consists of two phases. In phase 1, an algorithm was developed to increase the directional capacity and reconnaissance capability of the UAV. In phase 2, the RIS was integrated into the system and the effect of the RIS was analysed.

RIS technology is used to improve the reliability, safety, capacity and coverage of communication between IoT devices and UAV. In particular, when there is no direct line of sight between an IoT device and the UAV or when there is an obstacle (building, tree, etc.) between them, RIS can help to better transmit the signals from an IoT device to the UAV. In this study, we show that the use of RIS technology improves the communication between IoT devices and the UAV and increases the amount of data collected while maintaining energy efficiency.

The simulation results show that increasing the directional capacity and reconnaissance capability of the UAV increases the data collection performance by

8,18% and the amount of data it can collect per unit of energy by 6,91%. Leveraging RIS technology also improves the performance of data collection by 10,7% and the performance of collected data per unit energy by 22,64%. In addition, the UAV, which was trained with the Double Deep Q-Network (DDQN) algorithm, one of the deep reinforcement learning algorithms, determined the most suitable route for collecting data from IoT devices and was able to land successfully.

As a result, this study revealed that the use of RIS technology in UAV-powered IoT networks has great potential in terms of improved data collection and energy efficiency. The results of this study can be used for the development and optimisation of future UAV-powered IoT applications.

Keywords: Reconfigurable intelligent surface, UAV, deep reinforcement learning, internet of things

TEŐEKKÜR

Bu tezin hazırlanmasında bana yüzlerce saat vakit ayırarak emek veren, bilgi ve deneyimi ile bana rehberlik eden, desteęini hiçbir zaman esirgemeyen, saygıdeęer hocam Sayın Dr. Öğretim Üyesi Halil YETGİN'e sonsuz teşekkür ederim.

Ayrıca Tez süresince her zaman bana destek olan eşim ve çocuklarıma teşekkürü bir borç bilirim.



İÇİNDEKİLER

ÖZET	I
ABSTRACT	III
TEŞEKKÜR.....	V
İÇİNDEKİLER.....	VI
ÇİZELGELER DİZİNİ	IX
ŞEKİLLER DİZİNİ.....	X
KISALTMALAR.....	XII
SİMGELER	XIII
1. GİRİŞ	1
2. GENEL BİLGİLER.....	3
2.1. Literatür Taraması.....	3
2.2. Nesnelerin İnterneti (IoT)	5
2.2.1. IoT Ağlarının Mevcut Durumu	5
2.2.2. IoT Ağlarının Yapı Taşları	5
2.2.2.1. Nesneler.....	6
2.2.2.2. Ağ Geçitleri	6
2.2.2.3. Ağ Altyapısı	6
2.2.2.4. Bulut Altyapısı	6
2.2.3 IoT Protokolleri ve İletişim Teknolojileri	6
2.2.3.1. IoT Protokolleri	7
2.2.3.2. İletişim Teknolojileri	8
2.2.4. IoT Güvenliği	8
2.2.5. IoT Ağlarının Karşılaştığı Zorluklar	9
2.3. Pekiştirmeli Öğrenme.....	10
2.3.1. Derin Pekiştirmeli Öğrenme.....	13
2.3.1.1. Deep Q-Network (DQN) ve Double DQN (DDQN) Algoritmaları	13
2.4. İnsansız Hava Araçları (İHA)	14

2.4.1. İHA’larda Kullanılan Teknolojiler ve Yardımcı Bileşenler	15
2.4.1.1. Görüntüleme Kameraları.....	15
2.4.1.2. Termal Kameralar.....	15
2.4.1.3. Lidar (Hafif Algılama ve Uzak Ölçüm)	15
2.4.1.4. GPS (Küresel Konumlandırma Sistemi).....	16
2.4.1.5. Hava Durumu Sensörleri	16
2.4.1.6. İletişim Modülleri	16
2.4.2. İHA Kullanım Alanları.....	17
2.5. Akıllı Yansıtıcı Yüzeyler (RIS)	18
2.5.1. Akıllı Yansıtıcı Yüzeylerin Yapısı	19
2.5.2. Akıllı Yansıtıcı Yüzeylerin Çalışma Prensibi.....	20
2.5.2.1. RIS Yansıtıcı Birimlerinin Fonksiyonu	20
2.5.2.2. Faz Kayması İlkesi	21
2.5.2.3. Amplitüd Kontrolü	21
2.5.3. Akıllı Yansıtıcı Yüzeylerin Uygulama Alanları	21
2.5.3.1. Kablosuz İletişim Sistemleri.....	21
2.5.3.2. 5G ve Sonraki Nesil İletişim	21
2.5.3.3. Güvenlik ve Gizlilik	21
2.5.3.4. Uzay İletişimi	22
2.5.3.5. Yeraltı İletişim	22
2.6. Tezin Aşamaları ve Başarım Oranları.....	22
3. MATERYAL VE YÖNTEM	24
3.1. Sistem Modeli	24
3.1.1. Ortam ve Koordinat Sistemi.....	24
3.1.2. Görev Zaman Dilimi ve Konum	24
3.1.3. İletişim Modeli	25
3.1.4 İHA’nın Veri Toplama Modeli.....	25
3.1.5. İHA Eğitimi.....	26

3.1.6. Ortam ve Kullanılan Semboller.....	27
3.1.7. Simülasyonun Ham Verileri	29
3.2. Yöntem.....	29
3.2.1 Aşama-1: Rastgele Keşif Yöntemi ve Yön Kapasite Arttırımı	29
3.2.2. Aşama-2: RIS'in Sisteme Dahil Edilmesi	31
3.2.2.1. RIS'in Enerji Verimliliği	31
3.2.2.2. Öğrenme Parametrelerinin Belirlenmesi.....	34
4. BULGULAR VE TARTIŞMA	39
4.1. Aşama-1	39
4.1.1. İHA'nın Yeniden Eğitilmesi	39
4.1.2. İHA'nın Yön Kapasitesi Testi.....	39
4.1.3. Manuel Senaryo Testleri.....	40
4.1.3.1. Senaryo-1: Keşif Kabiliyeti	41
4.1.3.2. Senaryo-2: Düşük Miktarlı Veri Toplama Testi	42
4.1.3.3. Senaryo-3: Uçuşa Yasak Bölgeden Veri Toplama Testi.....	43
4.1.4. Rastgele Senaryolarla Sistemin Genel Performansının Ölçülmesi	45
4.2. Aşama-2	47
4.2.1. Sisteme RIS'in Dahil Edilmesi.....	47
5. SONUÇ.....	51
KAYNAKLAR.....	53

ÇİZELGELER DİZİNİ

Çizelge 3.1. Simülasyonda kullanılan semboller ve sembollerin açıklamaları	28
Çizelge 3.2. 1000 adet denemenin her birinde parametrelerin değerleri Monte Carlo yöntemi ile rastgele bir aralıktan seçilmiştir ve ortalama değer elde edilmiştir	29
Çizelge 3.3: Veri iletim hızına göre enerji verimliliği karşılaştırması.....	35
Çizelge 3.4: Simülasyon parametreleri ve parametrelerin değerleri.....	38
Çizelge 4.1. Simülasyon sonuçlarının karşılaştırılması (RIS dahil edilmeden).....	46
Çizelge 4.2. Simülasyon sonuçlarının karşılaştırılması (RIS dahil edildiğinde)	49



ŞEKİLLER DİZİNİ

Şekil 2.1. IOT Ağlarının Yapı Taşları	5
Şekil 2.2. İletişim merkezli bir IoT referans modeli	7
Şekil 2.3. Pekiştirmeli Öğrenme unsurları.....	10
Şekil 2.4. Q-Learning ve Deep Q-Learning karşılaştırması	14
Şekil 2.5. Akıllı Yansıtıcı Yüzey (RIS) destekli iletişim	19
Şekil 2.6. Akıllı Yansıtıcı Yüzeyin (RIS) Yapısı.....	20
Şekil 2.7. Tezin aşamaları ve elde edilen başarı oranları	23
Şekil 3.1. İHA'nın öğrenerek veri toplama işlemini gerçekleştirdiği ortam modeli.....	28
Şekil 3.2. Rastgele Keşif Yöntemi akış şeması.....	30
Şekil 3.3. Farklı algoritmalarla Pmax'a (Maksimum Güç) karşı enerji verimliliği.....	31
Şekil 3.4. N elemanlı IoT cihazlarının enerji verimliliği üzerindeki etkisi	32
Şekil 3.5. M yansıtıcı birimli RIS cihazının enerji verimliliği üzerindeki etkisi	33
Şekil 3.6. Enerji verimliliği ile veri iletim hızı arasındaki ilişki.....	34
Şekil 3.7. İHA ile RIS destekli veri toplama sistemi (Temsili gösterim)	37
Şekil 4.1. 2 Milyon iterasyonla eğitilen İHA'nın başarı grafiği (Eğitim ilerlemesinde elde edilen maksimum başarı değerleri baz alınarak oluşturulmuştur.).....	39
Şekil 4.2. İHA'nın 4 yöne hareket edebildiği rotası ve toplanan veri	40
Şekil 4.3. İHA'nın 8 yöne hareket edebildiği rotası ve toplanan veri	40
Şekil 4.4. İHA'nın cihazları algılayamadığı durum	41
Şekil 4.5. Yeni paramaterlere göre tekrar eğitilen İHA'nın hareketi	41
Şekil 4.6. [14]'teki modele göre eğitilen İHA'nın performansı.....	42
Şekil 4.7. Yeni parametreler ile (Rastgele keşif yöntemi algoritması) eğitilmiş İHA'nın performansı	43
Şekil 4.8. Girilmesi Yasak Bölge senaryosu.....	44
Şekil 4.9. Girilmesi Yasak Bölge senaryosu (Rastgele keşif yöntemi ile eğitildikten sonra) ..	44
Şekil 4.10. Sistem Konfigürasyon Parametreleri	45

Şekil 4.11. Simülasyon sonuçlarının RIS dahil edilmeden önce başarılı iniş ve veri toplama oranı açısından karşılaştırılması.....	46
Şekil 4.12. Simülasyon sonuçlarının RIS dahil edilmeden önce birim enerji başına toplanan veri miktarı açısından karşılaştırılması.....	47
Şekil 4.13. İHA yeşil(green) IoT cihazından veri alamadığı senaryo	48
Şekil 4.14. İHA'nın veri alamadığı IoT cihazından RIS sayesinde veri alması (Temsili üç boyutlu gösterim).....	48
Şekil 4.15. Simülasyon sonuçlarının “Başarılı İniş” ve “Veri Toplama Oranı” karşılaştırma grafiği.....	49
Şekil 4.16. Simülasyon sonuçlarının “Birim Enerji Başına Toplanan Veri Miktarı” bakımından karşılaştırması	50

KISALTMALAR

BILP	: Binary Tamsayılı Lineer Programlama
BLE	: Bluetooth ve Bluetooth Low Energy
CoAP	: Constrained Application Protocol
DDQN	: Double Deep Q-Network
DRL	: Derin Pekiştirmeli Öğrenme (Deep Reinforcement Learning)
DQL	: Deep Q-Learning
GIS	: Haritalama ve Coğrafi Bilgi Sistemi
GPS	: Küresel Konumlandırma Sistemi
HTTP	: Hiper-Metin Transfer Protokolü
HTTPS	: Güvenli Hiper-Metin Transfer Protokolü
IoT	: Nesnelerin İnterneti (Internet of Things)
İHA	: İnsansız Hava Aracı
LoRaWAN	: Uzun Menzilli Geniş Alan Ağı
MDP	: Markov Karar Süreçleri
MIMO	: Çoklu Giriş-Çıkış (Multiple-Input and Multiple-Output)
MQTT	: Message Queuing Telemetry Transport
NFC	: Yakın Alan İletişim Teknolojisi
RC	: Uzaktan Kumanda İletişimi
RFID	: Radyo Frekansı ile Tanımlama
RIS	: Akıllı Yansıtıcı Yüzey (Reconfigurable Intelligent Surface)
SAC	: Soft Actor-Critic
SNR	: Sinyal-Gürültü Oranı
Wi-Fi	: Kablosuz Bağlantı Alanı
Zigbee	: Zonal Intercommunication Global-Standard
Z-Wave	: Kablosuz İletişim Protokolü
3D	: 3 Boyutlu Ortam
4G	: 4. Nesil İletişim Teknolojisi
5G	: 5. Nesil İletişim Teknolojisi
6G	: 6. Nesil İletişim Teknolojisi

SİMGELER

α	: Öğrenme oranı
γ	: İndirme katsayısı
A	: Aksiyon
S	: Durum
R	: Ödül
Q	: Q öğrenme
t	: t birim zamanda
c_k	: k. sensörün konumu
x	: koordinat düzleminde x eksen
y	: koordinat düzleminde y eksen
T	: İHA'nın görev süresi
N	: Yansıtıcı birim eleman sayısı
u_{konum}	: İHA'nın konumu
h	: İHA'nın yüksekliği
r	: Veri iletim hızı
P	: Güç
σ	: Gürültünün gücü
d_k	: İHA ile k. sensör arasındaki uzaklık
α	: Yol kaybı üstel değeri
η	: Gürültü Gauss rassal değişkeni
C	: Elde edilebilir toplam veri miktarı
δ	: İletişim zaman kesiti
n	: Her bir iletişim zaman kesiti indeksi
K	: Toplam sensör sayısı
q	: Sensörün veri transferi için aktif olup olmadığını gösteren değer. (0 veya 1)
β	: Kanal kazancı

1. GİRİŞ

Günümüzde kablosuz iletişim teknolojilerindeki hızlı ilerlemeler, Nesnelerin İnterneti (IoT) ve İnsansız Hava Araçları (İHA) gibi alanlarda önemli fırsatlar sunmaktadır. IoT ağları, milyarlarca cihazın birbirine bağlanarak veri paylaşımını ve etkileşimi mümkün kıldığı bir iletişim ağıdır [1]. Bu ağlar, sağlık, enerji, tarım, endüstriyel otomasyon gibi birçok sektörde uygulanmaktadır ve hayatımızın birçok yönünü etkilemektedir [2].

Ancak, IoT ağlarının performansı, sınırlı kaynaklara ve ağıdaki cihazların enerji tüketimi gibi zorluklara bağlı olarak sınırlı olabilmektedir [3]. Bu zorluklar, IoT ağlarının verimli bir şekilde yönetilmesini gerektirmekte ve ağ performansının iyileştirilmesi için yenilikçi çözümler arayışını beraberinde getirmektedir.

İHA'lar, IoT ağlarının performansını artırmak ve verimliliğini optimize etmek için önemli bir potansiyele sahiptir. Araştırmalar, İHA'ların IoT ağlarında veri toplama, yönlendirme ve iletişim gücünü artırma gibi görevler için ideal bir çözüm sunduğunu ortaya koymaktadır [4]. İHA'lar, düşük maliyetli, hızlı konum değiştirme yeteneklerine sahip ve geniş kapsama alanı sunabilen cihazlardır. Bu özellikler, İHA'ları IoT ağlarında etkin bir şekilde kullanmayı mümkün kılmaktadır.

Bu tezde, İHA destekli IoT ağlarında derin pekiştirmeli öğrenme yöntemlerini kullanarak RIS'lerin verim maksimizasyonunda nasıl bir rol oynayabileceği araştırılmaktadır. RIS, sinyal yönlendirme ve güç kontrolü gibi görevlerde kullanılan, yansıtıcı özelliklere sahip özelleştirilebilir yüzeylerdir. Bu teknoloji sayesinde, iletişimde oluşan sinyal kayıpları azaltılabilir ve alıcı ve verici arasında daha güvenli bir iletişim sağlanabilir. Özellikle iletişim sinyalini zayıflatan bir engelin olduğu durumlarda, yani alıcı ve verici arasında direkt görüşün olmadığı durumlarda kullanımı avantaj sağlamaktadır [5]. Derin pekiştirmeli öğrenme ise yapay zeka alanında önemli bir yöntemdir ve öğrenme sürecini simüle ederek, deneyimlerden en iyi sonuçları elde etmek için çevreye tepkileri optimize etmeye odaklanır [6].

Bu tezde harita üzerinde rastgele dağılan IoT cihazlarından veri toplamak için Double Deep Q-Network (DDQN) aracılığıyla eğitilen İHA'nın maksimum veriyi toplamak üzere başlangıç noktasından hareket edip güvenli bir şekilde tekrar iniş istasyonuna inmesi gerekmektedir. Aynı zamanda İHA veriyi toplarken enerjisini verimli kullanmalı ve direkt görüş sağlayamadığı ve sinyal kalitesi düşük olan cihazlardan da uygun konumlara yerleştirilen RIS sayesinde maksimum veriyi alabilmelidir.

Bu alıřmanın sonuçları, IoT ađlarının daha verimli ve srdrlebilir hale getirilmesine ynelik gelecek alıřmalara yardımcı olacaktır. Ayrıca, İHA'ların IoT ađlarıyla entegrasyonunun ve RIS'in potansiyelini gstererek, verim maksimizasyonu alanında gelecekteki arařtırmalara katkı sađlayacaktır.

Bu tezin yapısı řu řekildedir: Blm 1'de, giriř ve tezde adı geen teknolojilerin tanımı; Blm 2'de literatre genel bir bakıř sađlanacak ve kullanılan teknolojiler anlatılacak; Blm 3'te, tezde kullanılan simlasyonun teknik ayrıntıları ve kullanılan yntem anlatılacak; Blm 4'te, simlasyon gerekleřtirmesi ve testler yapılacaktır, elde edilen bulguların analizi sunulacaktır; Blm 5'te, tezin sonuçları ve gelecekteki arařtırmalar iin neriler yer alacaktır.

Bu tez, İHA destekli IoT ađlarında derin pekiřtirmeli đrenme yoluyla RIS destekli verim maksimizasyonunu arařtırarak yeni bir veri toplama metodunu literatre kazandırmayı hedeflemektedir.

2. GENEL BİLGİLER

Bu bölümde, literatüre genel bir bakış sunulacak ve çalışmada adı geçen teknolojilerin genel bir tanımı yapılacaktır.

2.1. Literatür Taraması

Literatür dikkatle incelendiğinde, bu konu ile ilgili sınırlı sayıda çalışmanın yapıldığı ve çalışmaların yoğunluğu günümüze yaklaştıkça arttığı görülecektir. Bu konudaki bazı önemli çalışmalar şu şekildedir;

Mei H. ve diğerleri [7]'deki çalışmada, İHA ile yer terminalleri arasındaki iletişimi iyileştirmek için RIS teknolojisi kullanılmaktadır. RIS, İHA ve yer terminali arasındaki sinyalleri sadece ilgili kullanıcıya yönlendirerek (odaklayarak) iletişim kalitesini artırmaktadır. Çalışmada, İHA'nın 3D konumunu ve RIS'in faz kaydırmasını optimize etmek için derin pekiştirmeli öğrenme (DRL) kullanılmış olup sonuçlar, DRL'nin RIS destekli İHA sistemlerinin enerji verimliliğini önemli ölçüde artırabileceğini göstermektedir.

Cao C. ve diğerleri [8]'deki çalışmada, İHA'ya uygulanan RIS'lerin çoklu giriş - çoklu çıkış (MIMO) kanallarında kullanılan durağan olmayan bir geometri tabanlı kanal modeli önermektedirler. RIS'in ayarlanabilir yansıma fazları, alınan sinyalin gücüne bağlı olarak optimize edilmiştir. Yapılan çalışmalar, RIS yansıtıcı birimlerinin sayısı, geometrik alanı ve İHA'nın hızının kanal istatistikleri üzerindeki etkisini de incelemektedir. Sonuçlar, RIS'ten yansıyan sinyallerin fazlarının optimize edilmesiyle alınan sinyal gücünü artırabileceğini ve çoklu yol sönümlenmesi etkisini azaltabileceğini göstermektedir. Ayrıca, RIS yansıtıcı birimlerinin sayısının artmasıyla mekânsal korelasyonun önemli ölçüde azaldığı belirlenmiştir.

Lian Z ve diğerleri [9]'daki çalışmada, RIS kullanarak İHA iletişim sistemlerinin performansını artırmak için yeni bir kanal modeli önermektedirler. Önerilen modelde, RIS yansıtıcı birimlerinin geometrisi ve yayılım özellikleri dikkate alınmıştır. Ayrıca, RIS yansıtıcı birimlerinin sayısı ve boyutunun kanal özellikleri üzerindeki etkisi incelenmiştir. Sonuçlar, RIS'in, yansıtıcı birimlerinin sayı ve boyutlarının artırılmasıyla iletişim performansını iyileştirebileceğini göstermektedir.

Wang F. ve Zhang X. [10]'daki çalışmada, İHA tabanlı iletişim sistemlerinde enerji tüketimini en aza indirmek için yeni bir yaklaşım önermektedirler. Aktif RIS teknolojileri kullanılarak, İHA ve yer kullanıcıları arasındaki iletişim sinyallerinin gücü etkili bir şekilde artırılmaktadır. Çok katmanlı bir optimizasyon yöntemi olan hiyerarşik derin pekiştirmeli öğrenme (DRL) kullanılarak, İHA'nın enerji tüketimi ve yer kullanıcılarının enerji tüketimi

eşzamanlı olarak en aza indirgenmektedir. Yapılan simülasyonlar, aktif RIS kullanımının, RIS üzerindeki termal gürültü gücünün İHA ve yer kullanıcıları termal gürültü gücünden önemli ölçüde daha düşük olduğu durumlarda, İHA ve yer kullanıcılarının enerji tüketiminin önemli ölçüde azaltılabileceğini göstermektedir.

Al-Jarrah M. Ve diğerleri [11]'deki çalışmada, İHA iletişimi için kullanılan RIS'lerin sistem kapasitesine etkisini analiz etmektedirler. İncelenen sistemde, bazı İHA'lar üzerinde bulunan RIS panelleri, alıcı İHA'ya yansıtılmadan önce gelen dalgaların fazını belirli şekillerde değiştirir. Ancak, bu faz değişimlerindeki hataların kapasite üzerindeki etkisi de dikkate alınmaktadır. Analiz sonuçları, faz hatalarının kapasiteyi etkilediğini göstermektedir, ancak yüksek sinyal-gürültü oranı (SNR) ve belirli bir eşik değerinin üzerinde faz hatalarının ihmal edilebilir hale geldiğini ortaya koymaktadır.

Park Y. Ve diğerleri [12]'deki çalışmada, akıllı demiryolu sistemlerinde trenlere kesintisiz kablesiz iletişim sağlamak için yeni bir yöntem önermişlerdir. Önerilen yöntemde, RIS destekli İHA kullanılarak görüş hattı ile iletişim sağlanmaktadır. İHA'nın yörüngesi ve RIS'in faz-kaydırması optimize edilerek trenlerin en yüksek hızda bile yüksek veri iletim hızına ulaşması hedeflenmektedir. Çözüm için Binary Tamsayılı Lineer Programlama (BILP) ve Soft Actor-Critic (SAC) yöntemleri kullanılmaktadır. Yapılan sayısal analizler, önerilen yöntemin etkinliğini göstermektedir.

Pogaku A. ve diğerleri [13]'deki çalışmada, RIS'in çeşitli yeni teknolojilerle nasıl entegre edilebileceğini ve bu entegrasyonun özellikle İHA gibi alanlarda nasıl bir etki yaratabileceğini incelemişlerdir. İHA'lar, topluma fayda sağlayan bir dizi hizmette bulunsada, bazı kısıtlamalara sahiptir. Bu noktada, RIS'in İHA'ları destekleyerek performanslarını artırma potansiyeli vurgulanmaktadır.

Bayerlein H. ve diğerlerinin [14]'deki çalışması, İHA destekli IoT ağlarında derin pekiştirmeli öğrenme kullanarak yol planlaması ve veri toplama konusunu ele almaktadır. Özellikle, sınırlı uçuş süresi ve engel önleme gibi zorlukları içeren bir senaryoda, Double Deep Q-Network (DDQN) ve deneyim tekrarı kullanılarak öğrenilen kontrol politikası, senaryo parametrelerindeki değişikliklere geniş bir şekilde adapte olabilme yeteneği ile dikkat çekmektedir. Bayerlein H. ve diğerlerinin [14]'deki çalışmasında, veri toplama modelinin özellikle bazı durumlarda etkin çalışmadığını gözlemledik. Dolayısıyla, bu tezde bu soruna çözüm bulunması hedeflenmektedir. Ayrıca, bu sisteme RIS entegrasyonunu gerçekleştirerek, RIS'in sistemin genel veri toplama ve enerji verimliliği performansları üzerindeki etkileri araştırılacaktır. Bu bağlamda, mevcut yöntemi temel alarak RIS'in

eklenmesiyle elde edilecek sonuçlar, IoT ve İHA entegrasyonunda veri toplama süreçlerini optimize etme konusunda önemli bir katkı sağlayacaktır.

2.2. Nesnelerin İnterneti (IoT)

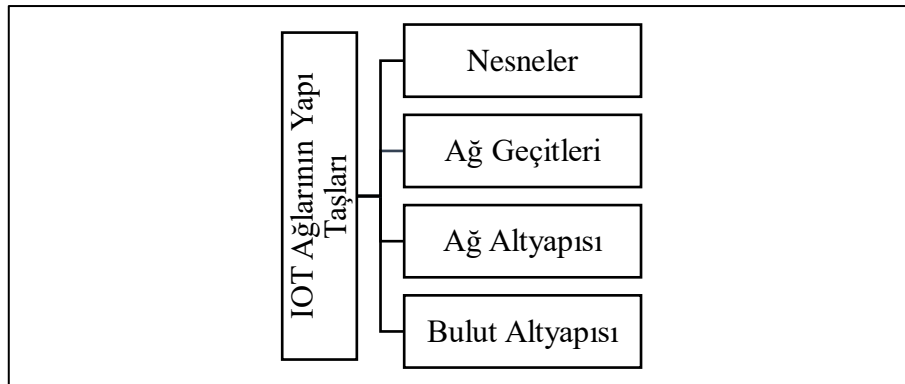
IoT, fiziksel nesnelerin internet üzerinden diğer cihaz ve sistemlerle veri bağlantısı ve paylaşımı amacıyla sensörler, yazılımlar ve diğer teknolojilerle gömülü olduğu bir ağdır. IoT ağlarında kullanılan sensörler genel olarak kısıtlı enerjiye sahip, maliyeti düşük ve kısa menzilde veri iletimini gerçekleştiren cihazlardır [15]. IoT, günlük hayatımızın her alanında giderek daha fazla kullanılmaktadır. IoT ağlarının kullanımı, teknolojinin hızlı gelişmesi ile beraber her geçen gün artmaya da devam edecektir. Akıllı evler, akıllı şehirler, akıllı sağlık, akıllı tarım, akıllı ulaşım sistemi, fabrika otomasyonları ve endüstri 4.0, çevresel izleme, altyapı izleme, akıllı perakende satışları, akıllı güç ve şebeke sistemleri gibi uygulamalar, IoT ağlarının yaygınlaşması ile mümkün olmaktadır [16].

2.2.1. IoT Ağlarının Mevcut Durumu

IoT teknolojisi, cihazların, nesnelerin ve sensörlerin internet üzerinden birbiriyle iletişim kurmasına olanak tanır [2]. Bu iletişim, büyük miktarda veri üretimi ve akışı anlamına gelir ve IoT ağlarının mevcut durumu, bu teknolojinin gelişimini anlamak için önemlidir.

2.2.2. IoT Ağlarının Yapı Taşları

IoT, dört temel bileşeni içeren karmaşık bir sistem oluşturur ve bu bileşenler, IoT ekosistemini oluşturan temel yapı taşlarıdır. Bu bileşenler, Şekil 2.1'de görüldüğü gibi, nesneler, ağ geçitleri, ağ altyapısı ve bulut altyapısıdır.



Şekil 2.1. IOT Ağlarının Yapı Taşları

2.2.2.1. Nesnelere

IoT'nin temelini oluşturan şey nesnelere dir. Bunlar, çeşitli yerlerde bulunan cihazlar, sensörler ve ya aktüatörler gibi fiziksel varlıklardır. Bu nesnelere, çevrelerindeki bilgileri algılayabilirler ve bu bilgileri işleyerek veri üretebilirler.

2.2.2.2. Ağ Geçitleri

Ağ geçitleri, nesnelere ile daha büyük ağlar arasında köprü görevi görürler. Bu cihazlar, nesnelere den gelen veriyi toplarlar ve bu veriyi ağa ileterek nesnelere nin birbirleriyle veya uzak sunucularla iletişim kurmalarını sağlarlar.

2.2.2.3. Ağ Altyapısı

Ağ altyapısı, IoT sisteminin omurgasını oluşturur. Bu altyapı, verilerin güvenli ve hızlı bir şekilde iletilmesini sağlar. Ayrıca, verilerin işlenmesi ve depolanması için gerekli olan kaynakları temin eder.

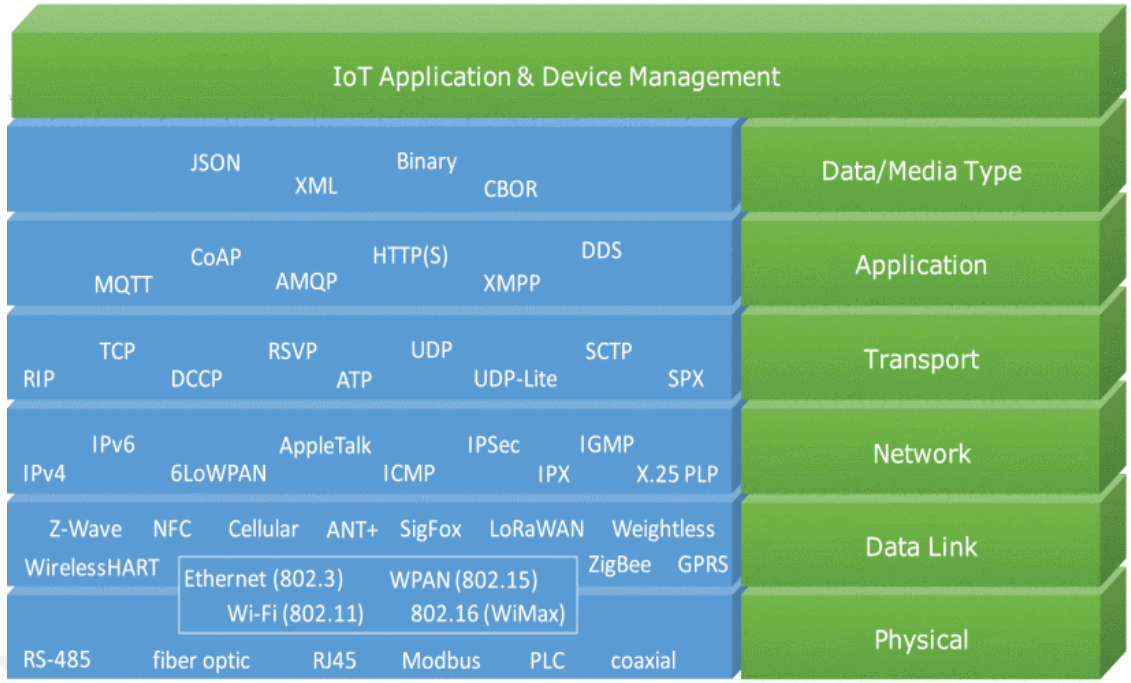
2.2.2.4. Bulut Altyapısı

Bulut altyapısı, IoT'nin veri yönetimi ve analizini destekler. Bu bileşen, büyük miktarda verinin depolanması, işlenmesi ve analiz edilmesi için gerekli olan kaynakları sunar. Bu sayede, nesnelere den gelen verilerden anlam çıkarılabilir ve uzaktan erişim sağlanabilir.

Bu dört temel bileşen, IoT'yi oluşturan önemli yapı taşlarıdır. Her biri, IoT ekosistemini daha işlevsel ve verimli hale getirmeye yardımcı olurken, aynı zamanda IoT'nin potansiyelini daha da genişletir.

2.2.3 IoT Protokolleri ve İletişim Teknolojileri

IoT protokolleri ve iletişim teknolojileri, IoT cihazlarının ve nesnelere nin birbiriyle ve ağlarla iletişim kurmasını sağlayan temel bileşenlerdir. Şekil 2.2'de iletişim merkezli bir IoT referans modeline ve her bir katmanda kullanılacak protokollere ve uygulamalara yer verilmiştir.



Şekil 2.2. İletişim merkezli bir IoT referans modeli [17]

2.2.3.1. IoT Protokolleri

IoT cihazlarının birbirleriyle ve ağlarla iletişim kurabilmesi için belirli kurallar ve standartlar gereklidir. Bu kurallar ve standartlar, IoT protokolleri olarak adlandırılır ve farklı kullanım senaryolarına ve ihtiyaçlara göre farklı protokoller geliştirilmiştir. Bazı popüler IoT protokolleri şunlardır;

- **MQTT (Message Queuing Telemetry Transport):** Hafif bir mesajlaşma protokolü olan MQTT, düşük bant genişliği ve enerji tüketimi gerektiren IoT cihazları için uygundur. Verileri düşük gecikme süreleriyle iletebilir ve yayımlayabilir.
- **CoAP (Constrained Application Protocol):** CoAP, kaynak kısıtlı cihazlar için tasarlanmış bir iletişim protokolüdür. Özellikle IoT cihazlarının enerji tüketimini minimize etmek istendiği durumlarda kullanılır.
- **HTTP/HTTPS:** Standart web iletişim protokolleri olan HTTP ve güvenli sürümü HTTPS, IoT cihazlarının internet üzerinden veri iletimi için kullanılabilir. Ancak, enerji tüketimi ve veri boyutu konularında bazı kısıtlamaları vardır.
- **LoRaWAN:** Uzun menzilli geniş alan ağı (LPWAN) teknolojilerinden biri olan LoRaWAN, uzak bölgelerdeki IoT cihazları ile iletişim kurmak için kullanılır. Uzun menzili ve enerji tasarrufu sağlar.

- **Bluetooth ve Bluetooth Low Energy (BLE):** Bluetooth, kısa menzilli kablosuz iletişim için kullanılır. BLE ise düşük güç tüketimi gerektiren IoT cihazları için uygundur.

2.2.3.2. İletişim Teknolojileri

IoT cihazları verilerini iletmek için farklı iletişim teknolojilerini kullanabilirler. Bu teknolojiler, cihazların fiziksel olarak nasıl iletişim kurduklarını ve hangi ağları kullanacaklarını belirler. Bazı yaygın IoT iletişim teknolojileri şunlardır;

- **Wi-Fi:** İnternet erişimine sahip olan IoT cihazları için yaygın olarak kullanılır. Yüksek hızlı veri iletimi sağlar, ancak enerji tüketimi daha yüksektir.
- **Cellular (4G/5G):** Mobil ağlar, geniş alanlar ve hareket halindeki IoT cihazları için uygundur. 5G, daha yüksek hızlar ve düşük gecikme süreleri sunar.
- **RFID (Radio-Frequency Identification):** RFID, nesnelerin kimliklerini algılamak için kullanılır ve envanter yönetimi gibi uygulamalarda yaygın olarak kullanılır.
- **NFC (Near Field Communication):** NFC, yakın mesafelerde hızlı veri iletimi sağlar ve özellikle ödeme sistemleri ve kimlik doğrulama için kullanılır.
- **Zigbee ve Z-Wave:** Bu düşük güçlü kablosuz iletişim teknolojileri, akıllı ev cihazları gibi düşük güç tüketimi gerektiren IoT uygulamaları için uygundur.

2.2.4. IoT Güvenliği

IoT ağlarının güvenliği, veri güvenliği ve gizliliği konusunda önemli bir endişe kaynağıdır. Kimlik doğrulama, veri şifreleme ve güvenli iletişim protokolleri gibi güvenlik önlemleri, IoT güvenliğini sağlamak için kullanılır [3].

Bu bağlamda, ağ katmanının güvenliği de önemlidir. Kounavis ve diğerleri tarafından önerilen bir yaklaşıma göre [18], son yıllarda kriptografik algoritmaların geliştirilmesi, genel amaçlı işlemcilerin yüksek hızda paketleri şifreleyebilme yeteneğini artırmıştır. Ancak bu algoritmaların IoT için uyarlanması zorlu olabilir. Çünkü IoT cihazları genellikle düşük iletim hızlarına sahiptir ve bağlantılar sıklıkla kesintilidir.

IoT güvenliği, IoT ekosisteminin karmaşıklığı ve çeşitliliği göz önüne alındığında hayati bir öneme sahiptir. Güvenliğin sağlanması için bazı temel unsurlar vardır. Birincisi, IoT cihazlarının fiziksel güvenliği önemlidir. Cihazların fiziksel erişimini kısıtlamak, yetkisiz müdahaleleri engellemeye yardımcı olur. İkincisi, yazılım güvenliği, IoT cihazlarının güvenlik bütünlüğünü sağlamada kritik bir rol oynar. Güçlü kimlik doğrulama ve yetkilendirme, IoT ağlarındaki cihazların güvenliğini sağlama açısından önemlidir. Bu

nedenle, her kullanıcının veya cihazın kimlik doğrulama ve yetkilendirme süreçlerini geçmesi gereklidir. Veri güvenliği, IoT cihazları arasındaki veri iletişimi ve depolama güvenliği açısından önemlidir. Verilerin şifrenmesi ve erişim kontrolü sağlanması gereklidir [19].

2.2.5. IoT Ağlarının Karşılaştığı Zorluklar

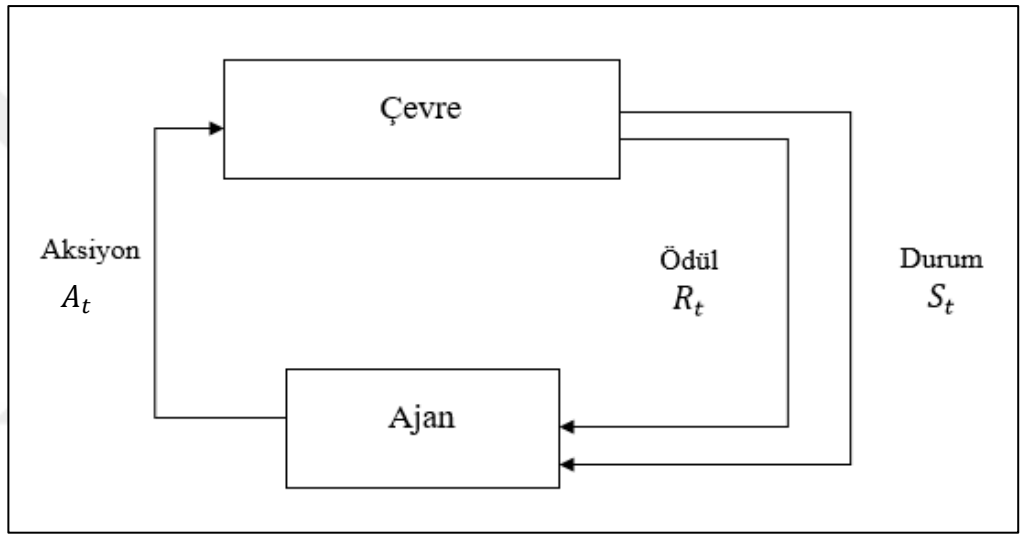
IoT ağları, büyük ölçekli dağıtılmış sistemler olarak tasarlandıkları için bir dizi zorlukla karşı karşıyadır. Bu zorluklar, IoT ağlarının güvenilirlik, ölçeklenebilirlik, güvenlik ve verimlilik gibi temel gereksinimlerini etkileyebilir. Aşağıda, IoT ağlarının karşılaştığı temel zorluklar ele alınmıştır [3], [20], [21]:

- **Düşük Güç Tüketimi ve Kaynak Kısıtları:** Birçok IoT cihazı, enerji kaynaklarının sınırlı olduğu pil ve pil benzeri enerji kaynakları kullanır. Bu nedenle, IoT cihazlarının düşük güç tüketimi tasarımı, pil ömrünün uzun olmasını sağlamak için kritiktir.
- **Ölçeklenebilirlik Sorunları:** IoT uygulamaları genellikle büyük ölçekli dağıtılmış sistemleri içerir ve milyonlarca cihazı kapsayabilir. Bu nedenle, ağların ve veri yönetiminin ölçeklenebilir olması zorunludur.
- **Veri Güvenliği ve Gizliliği:** IoT cihazları arasında veri iletimi ve depolama güvenli olmalıdır. Ayrıca, kullanıcıların kişisel verilerinin gizliliği korunmalıdır.
- **Standartlaşma ve Uyumsuzluk:** Farklı üreticilerden gelen IoT cihazları ve protokoller, standartlaşma eksikliği ve uyumsuzluk sorunlarına yol açabilir. Bu, cihazların birlikte çalışabilirliğini ve entegrasyonunu zorlaştırabilir.
- **Ağ Yoğunluğu:** Büyük IoT ağları, veri yoğunluğu sorunlarına neden olabilir ve iletişim kesintilerine yol açabilir. Veri iletiminin düzenlenmesi ve optimize edilmesi önemlidir.
- **Güncelleme ve Yönetim Zorlukları:** IoT cihazlarının güncel yazılımlara sahip olmaları önemlidir. Ancak cihazların güncellenmesi ve yönetimi, büyük ölçekli IoT ağlarında karmaşık bir görev olabilir.
- **Düşük Maliyet ve Maliyet Etkinliği:** IoT uygulamaları genellikle düşük maliyetli olmalıdır. Bu, cihazların uygun maliyetli bir şekilde üretilmesi ve işletilmesi gerektiği anlamına gelir.

Bu zorluklar, IoT ağlarının planlanması, dağıtılması ve yönetilmesi sırasında göz önünde bulundurulması gereken temel faktörlerdir. IoT teknolojilerinin ve uygulamalarının başarısı için bu zorluklara karşı etkili çözümler bulunması önemlidir.

2.3. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, ajanın çevresiyle etkileşime girerek ve çevresinden gelen geri bildirimlere dayanarak öğrenmesini sağlayan bir öğrenme paradigmasıdır. Ajan, belirli bir durumda bulunur, bir eylem seçer ve ardından çevresel tepkisine göre ödül veya ceza alır. Amaç, uzun vadede en yüksek toplam ödülü maksimize etmek için en iyi eylem stratejisini öğrenmektir. Ajan bu eyleme Şekil 2.3'te görülen, Markov Karar Süreçleri (MDP) [22] olarak bilinen modele göre karar verir.



Şekil 2.3. Pekiştirmeli Öğrenme unsurları

- **Durum (State, S_t):** Derin pekiştirmeli öğrenme sürecinde, "durum" (state), ajanın veya sistemin anlık çevresel koşullarını temsil eden kritik bir kavramdır. Durum, ajanın mevcut konumu, hızı, çevresel nesnelerin konumu ve diğer önemli değişkenleri içeren bir vektör veya tensör biçiminde ifade edilir [23], [24]. Durum, ajanın kararlarını almasında temel bir rol oynar. Ajan, mevcut duruma bağlı olarak en iyi eylemi seçmek için durum bilgilerini kullanır. Örneğin, otonom bir araç için durum bilgileri, aracın hızı, çevresindeki trafik, yol şartları ve daha fazlasını içerebilir [25]. Derin pekiştirmeli öğrenme problemlerinde, durumların etkili bir şekilde temsil edilmesi önemlidir. Bazı durumlar, basit ve düşük boyutlu olabilirken, diğerleri yüksek boyutlu ve otomatik olarak algılanan verileri içerebilir. Bu, ajanın öğrenme sürecini ve görevi nasıl gerçekleştireceğini büyük ölçüde etkiler [26].
- **Eylem (Action, A_t):** Derin pekiştirmeli öğrenme kavramlarından biri olan "eylem" (action), bir ajanın durumu değiştirmek veya belirli bir görevi gerçekleştirmek için

gerçekleştirdiği işlemleri temsil eder. Eylemler, genellikle bir aksiyon uzayında tanımlanır ve ajan, bu uzaydan bir eylem seçerek çevresiyle etkileşimde bulunur [27]. Eylemlerin seçimi, ajanın mevcut durumunu ve hedefini dikkate alarak yapılır. Bu kararlar, ajanın öğrenme sürecinin temelini oluşturur ve genellikle bir hedef fonksiyonunu maksimize etme amacını taşır [28]. Derin pekiştirmeli öğrenme sistemlerinde, ajan, durumlarına ve hedefine bağlı olarak en uygun eylemi seçmek için öğrenme süreci yürütür. Bu süreç, genellikle Q-değerleri veya politika ağırlıkları gibi öğrenme parametreleri aracılığıyla gerçekleştirilir [29], [30].

- **Ödül (Reward, R_t):** Ödül (reward), bir ajanın belirli bir eylemi gerçekleştirdiğinde veya belirli bir duruma ulaştığında alınan anlık geri bildirimdir. Ödüller, ajanın amaçlarına ulaşmasına veya belirli bir hedefi başarmasına yardımcı olacak şekilde tasarlanır [29]. Ajan, ödülleri maksimize etmeye çalışarak en iyi eylemi seçmeye yönlendirilir. Bu, ajanın öğrenme sürecinde temel bir rehberlik sağlar ve genellikle bir hedef fonksiyonu ile ilişkilidir [31]. Ödüllerin doğru bir şekilde tasarlanması, ajanın istenen davranışları öğrenmesini sağlar. İyi düşünülmüş bir ödül sistemi, ajanın belirli görevleri başarmasını teşvik ederken, istenmeyen davranışları engelleyebilir [32].
- **Q-Değer Fonksiyonu:** Q-değer fonksiyonu, derin pekiştirmeli öğrenme sürecinde önemli bir kavramdır ve bir ajanın belirli bir durumda belirli bir eylemi gerçekleştirdiğinde beklenen toplam ödülü tahmin eden bir fonksiyonu temsil eder [30]. Q-değer fonksiyonu genellikle bir durum-eylem çifti için $Q(s, a)$ olarak gösterilir, burada "s" durumu, "a" ise alınan eylemi temsil eder. Q-değerleri, ajanın öğrenme sürecinde kullanılır ve genellikle Şekil 2.4'te gösterilen Q-değer tablosu veya Q-değer ağı gibi yapılar aracılığıyla temsil edilir [29], [33]. Ajan, Q-değer fonksiyonunu kullanarak, mevcut durumu ve mümkün olan eylemleri dikkate alarak en iyi eylemi seçmeye çalışır. Q-değer fonksiyonu, ajanın kararlarını optimize etme ve en yüksek toplam ödülü elde etme amacını taşır [34].
- **Politika (Policy):** Politika, bir ajanın belirli bir durumda hangi eylemi seçeceğini belirleyen bir stratejiyi ifade eder [33]. Genellikle $\pi(a|s)$ şeklinde gösterilen politika, durum "s" altında eylem "a" seçme olasılığını belirtir. Politika, ajanın öğrenme sürecinde temel bir rol oynar çünkü ajanın hedef fonksiyonu doğrultusunda en iyi eylemi seçmesine rehberlik eder [35]. Politika genellikle doğrudan belirli bir durum ve eylem kombinasyonunu belirleme amacını taşır. Derin pekiştirmeli öğrenme sistemlerinde, politikalar genellikle parametrik bir formda temsil edilir ve bu parametreler, ajanın öğrenme süreci boyunca güncellenir [23]. Politika iyileştikçe,

ajanın hedefe daha etkili bir şekilde ulaşabilmesi için eylem seçimindeki olasılıkları ayarlar.

- **Hedef Fonksiyonu:** Hedef fonksiyonu, bir ajanın veya sistemimizin amaçlarını matematiksel olarak ifade eden bir fonksiyondur. Bu fonksiyon, genellikle ajanın toplam ödülü maksimize etme amacını taşır [31]. Hedef fonksiyonu, ajanın öğrenme sürecinde rehberlik eder ve ajanın davranışını yönlendiren temel bir kriter olarak hizmet eder. Bu fonksiyon, ajanın belirli bir durumu veya durum dizisini alır ve bu durumu optimize ederek en iyi eylemi seçmeye çalışır [36]. Derin pekiştirmeli öğrenme problemlerinde, hedef fonksiyonu genellikle belirli bir görevin başarıldığını ifade eden özel bir formülasyonu içerir. Bu formülasyon, ajanın hedefe ulaşmasını teşvik eder ve istenmeyen davranışları engeller.

Ayrıca, pekiştirmeli öğrenmede önemli bir yere sahip Q-Learning olarak bilinen bir politika dışı Zamansal-Fark (Temporal Different) kontrol algoritmasının formülü “Denklem 2.1”de gösterilmiştir.

$$Q(S_t, A_t) = Q(S_t, A_t) + \alpha \left(R_{t+1} + \gamma \max_a Q(S_{t+1}, A_t) - Q(S_t, A_t) \right) \quad (2.1)$$

Burada:

- $Q(S_t, A_t)$: Durum S_t ve eylem A_t için mevcut Q-değeri.
- α : Öğrenme hızı, her güncelleme adımında Q-değerlerinin ne kadar değişeceğini kontrol eden bir parametredir.
- R_{t+1} : Anlık ödül, mevcut durumda alınan eylemden sonra hemen elde edilen ödüldür.
- γ : İndirim faktörü, gelecekteki ödüllerin mevcut değere göre nasıl indirgeneceğini kontrol eden bir faktördür.
- \max_a : Bu, bir sonraki durumda mevcut en iyi eylemi seçmeyi ifade eder.
- $Q(S_{t+1}, A_t)$: Bir sonraki durum S_{t+1} ve mevcut eylem A_t için tahmini Q-değeridir.

Bu denklem, ajanın her adımda ödül ve gelecekteki durumlarını dikkate alarak Q değerlerini güncellediği temel bir öğrenme sürecini tanımlar.

2.3.1. Derin Pekiştirmeli Öğrenme

Derin Pekiştirmeli Öğrenme, yapay zeka ve makine öğrenme alanlarında büyük bir dönüşüm yaratan önemli bir öğrenme paradigmasıdır. Bu yaklaşım, özellikle "Reinforcement Learning: An Introduction" adlı kitapta [33] tanımlanan takviyeli öğrenme ya da diğer adıyla pekiştirmeli öğrenme konseptinin, derin öğrenme teknikleri ile birleşmesiyle şekillenmiştir.

Derin Pekiştirmeli Öğrenme, derin sinir ağlarının güçlü temsil yeteneklerini kullanarak bu tür görevleri çözmek için geliştirilmiştir [37]. Özellikle büyük veri setlerini işlemek ve karmaşık özellikleri otomatik olarak çıkarmak için derin öğrenme mimarileri kullanılır

Bu alandaki ilerlemelerde, derin öğrenme ile pekiştirmeli öğrenme arasındaki bağlantıyı keşfeden ve derin sinir ağlarının pekiştirmeli öğrenme problemlerini nasıl ele alabileceğini gösteren "Human-level control through deep reinforcement learning" gibi çalışmalar büyük bir rol oynamıştır [29]. Ayrıca, Q-öğrenme gibi temel pekiştirmeli öğrenme algoritmalarının derin öğrenme ile birleştirilerek daha etkili hale getirilmesi üzerine yapılan araştırmalar da önemlidir [30]. Bu bağlamda, sonraki bölümde Deep Q-Network (DQN) ve Double Deep Q-Network (DDQN) algoritmalarını inceleyeceğiz.

2.3.1.1. Deep Q-Network (DQN) ve Double DQN (DDQN) Algoritmaları

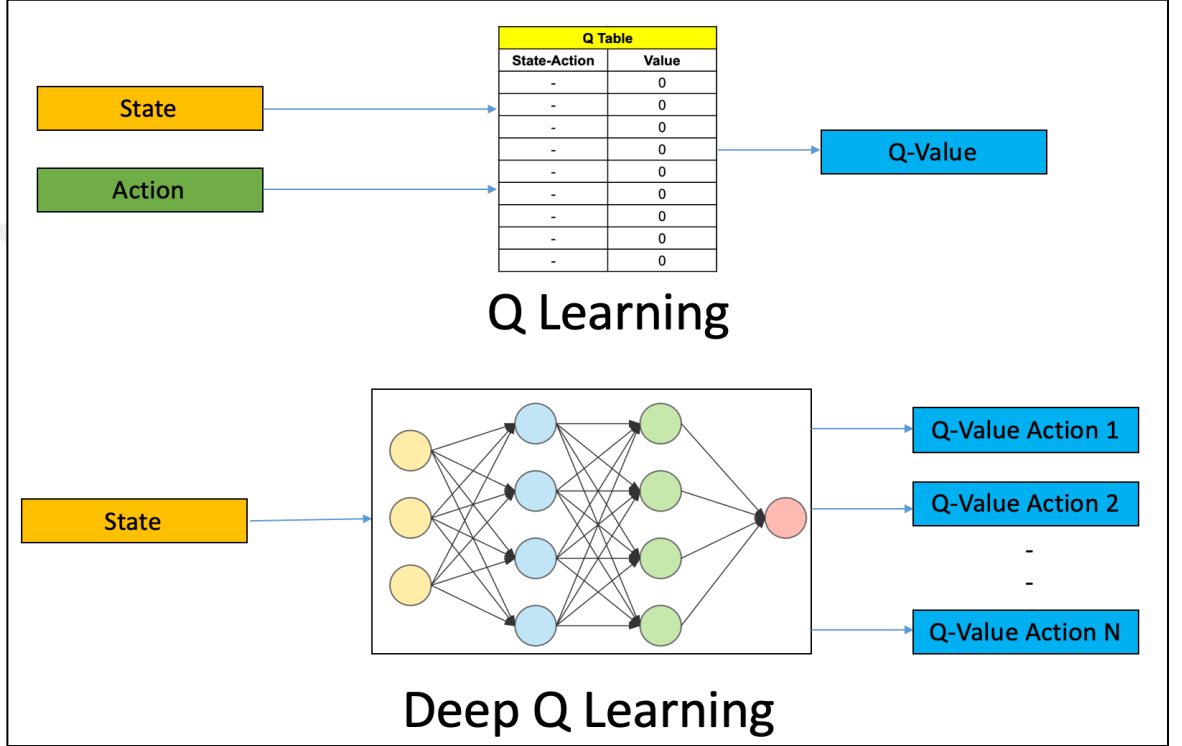
Deep Q-Network (DQN) ya da Deep Q-Learning (DQL), derin öğrenme yöntemlerini kullanarak Q-öğrenme algoritmasını genişleten bir yapay zeka öğrenme modelidir. Bu iki terim genellikle birbirini yerine kullanılmaktadır, çünkü DQN, Deep Q-Learning'in belirli bir uygulamasını ifade eder. DQN, özellikle oyun kontrol problemlerinde etkili bir şekilde kullanılmıştır ve çeşitli ödül tabanlı ortamlarda karmaşık stratejilerin öğrenilmesinde başarı göstermiştir [29].

Bu algoritmanın temel özelliklerinden biri, deneyim tekrarı ve hedef ağı kullanımınıdır [29], [38]. Deneyim tekrarı, ajanın geçmiş deneyimlerini bellekte saklayarak, daha sonra bu deneyimlerden rastgele seçerek öğrenmeyi iyileştirmesine dayanır. Hedef ağı ise, ajanın hedef Q değerlerini öngörmek için kullanılan ağıdır. Bu ağın ağırlıkları, belirli aralıklarla ana ağı güncelleyerek kararlılık sağlar [29].

DQN'nin matematiksel temeli Bellman denklemleriyle ilişkilidir ve eğitim sırasında Q değerlerini optimize etmek amacıyla kayıp fonksiyonları kullanır [29], [30]. Bu optimizasyon süreci, ağın parametrelerini güncelleyerek ve hedef Q değerlerini gerçek Q

değerlerine yaklaştırarak gerçekleştirir [29]. DQN'nin başarısı, çeşitli oyunlarda ve problem alanlarında gösterdiği çıkışlarıyla kanıtlanmıştır [29], [38].

DQN, Q-Değer fonksiyonunu hesaplamak için bir sinir ağı kullanır. Bu süreçte, giriş olarak durumu alır ve çıkış olarak tüm olası eylemlerin Q-değerini üretir. Diğer bir deyişle, bu yöntem, karmaşık öğrenme süreçlerini daha etkili bir şekilde modellemek için gelişmiş bir sinir ağı yaklaşımını benimser. Şekil 2.4'te DQL ve Q-Learning farkı detaylı bir şekilde gösterilmektedir.



Şekil 2.4. Q-Learning ve Deep Q-Learning karşılaştırması [39]

DDQN ise; derin öğrenme ve pekiştirmeli öğrenme alanlarındaki ilerlemeleri birleştirerek, ajanların öğrenme süreçlerini optimize etmeye yönelik kritik bir algoritmadır [40]. DDQN, özellikle Q-öğrenme tabanlı yaklaşımlarda ortaya çıkan aşırı tahmin hatası sorununu ele alarak, ajanların daha tutarlı ve etkili bir şekilde öğrenmelerini sağlar. Double Q-Learning'den yola çıkan DDQN, Derin Q-Ağı (DQN) ve Hedef Ağı (Target Network) olmak üzere iki farklı Derin Sinir Ağı kullanır.

2.4. İnsansız Hava Araçları (İHA)

İnsan müdahalesi olmadan uçabilen ve çeşitli teknolojik bileşenlerle donatılmış araçlar olan İHA'ların kullanımı bir dizi sivil uygulama alanında hızla artmaktadır. Bu alanlar arasında gerçek zamanlı izleme, kablosuz kapsama alanı sağlama, uzaktan algılama, arama kurtarma, ürün teslimatı, güvenlik ve gözetim, hassas tarım ve sivil altyapı denetimi

gibi birçok farklı uygulama alanı bulunmaktadır [41]. Uygulama alanlarında sık kullanılma nedeni, pratiklik, kolayca sahaya sürülebilmeleri, düşük bakım maliyetleri, yüksek manevra kabiliyeti ve sabit konumda kalabilme yetenekleri gibi avantajlarıdır [42].

İHA'ların, günümüzdeki en önemli kullanım alanlarından biri de IoT cihazlarıyla veri iletimini sağlamaktır. İHA'lar zorlu coğrafyalarda konuşlanmış IoT cihazlarından veri toplayabilir ve bu verileri işlenmek üzere bir merkeze aktarabilirler. Bu bölümde, İHA teknolojisinin ana hatlarına odaklanacak ve İHA'larda kullanılan teknolojiler ve yardımcı bileşenler hakkında genel bilgiler sunulacaktır.

2.4.1. İHA'larda Kullanılan Teknolojiler ve Yardımcı Bileşenler

2.4.1.1. Görüntüleme Kameraları

Görüntüleme kameraları, İHA'ların çevresini görsel olarak incelemelerini ve bilgi toplamalarını sağlar. Bu kameralar genellikle yüksek çözünürlüklü sensörlerdir ve aşağıdaki görevlerde kullanılırlar:

- **Görüntü ve Video Kaydı:** İHA, çektiği görüntüleri veya videoları kaydedebilir. Bu, çeşitli uygulamalarda kullanılabilir, örneğin haritalama, gözetim veya güvenlik.
- **Nesne Tanıma:** Görüntü işleme algoritmaları sayesinde, İHA'lar nesneleri tanıyabilirler. Bu, otomatik pilot sistemlerinin kullanılması veya belirli nesnelerin izlenmesi gibi görevlerde önemlidir.

2.4.1.2. Termal Kameralar

Termal kameralar, sıcaklık farklarını algılayarak nesnelere ve ortamı termal görüntülerle gösterirler. İHA'lar için şu şekilde kullanılırlar:

- **Gece ve Zorlu Hava Koşulları Gözlemi:** Termal kameralar, gece veya düşük görüş koşullarında çevreyi gözlemlemek için kullanılır. Ayrıca yoğun duman ve sis gibi zorlu hava koşullarında da etkilidirler.
- **Ateş ve Isı Kaynaklarının Tespiti:** İHA'lar, yangınlar veya enerji sızıntıları gibi ısı kaynaklarını tespit etmek için termal kameraları kullanabilirler.

2.4.1.3. Lidar (Hafif Algılama ve Uzak Ölçüm)

Lidar sistemleri, lazer ışınlarını kullanarak çevrelerini 3D haritalar halinde tararlar. İHA'lar için şu şekilde kullanılırlar:

- **Hassas Navigasyon:** Lidar, İHA'nın hassas bir şekilde konumunu belirlemesine yardımcı olur, özellikle iç mekanlarda veya dar alanlarda.

- **Nesne Algılama ve Engelden Kaçınma:** Lidar, İHA'ların önlerindeki nesnelere algılayarak çarpışmaları önler ve otomatik kaçınma sistemlerine destek sağlar.

2.4.1.4. GPS (Küresel Konumlandırma Sistemi)

GPS alıcıları, İHA'nın dünya üzerindeki konumunu belirlemek için uydu sinyallerini kullanır. İHA'lar için şu şekilde kullanılırlar:

- **Navigasyon:** GPS, İHA'nın hedeflere yönelik doğru bir şekilde seyahat etmesini sağlar.
- **Haritalama ve Coğrafi Bilgi Sistemi (GIS) Uygulamaları:** GPS verileri, haritalama ve yerel bilgi sistemleri uygulamaları için kullanılır.

2.4.1.5. Hava Durumu Sensörleri

Hava durumu sensörleri, İHA'nın uçuş sırasında çevresel koşulları izlemesine yardımcı olur. Bu sensörler şunları içerebilir:

- **Rüzgar Hızı ve Yönü Sensörleri:** Rüzgar koşullarını ölçerek İHA'nın uçuş güvenliğini sağlar.
- **Sıcaklık ve Nem Sensörleri:** Bu sensörler, hava koşullarını izlemek ve sıcaklık veya nem değişikliklerini algılamak için kullanılır.
- **Basınç Sensörleri:** Basınç değişikliklerini ölçerek İHA'nın yükseklik bilgisini sağlar ve deniz seviyesine göre konumunu belirler.

Bu sensörler, İHA'ların çeşitli görevleri gerçekleştirmesine ve farklı koşullarda güvenli bir şekilde uçmasına yardımcı olur.

2.4.1.6. İletişim Modülleri

İHA'lar, birçok farklı türde ve amaç için kullanılan teknolojik cihazlardır. İletişim modülleri, İHA'ların kontrol edilmesi, görevlerini gerçekleştirmesi ve veri toplaması için kritik bir rol oynar. İHA'ların iletişim modülleri şunlardır:

- **Uzaktan Kumanda (RC) İletişimi:** İHA'lar genellikle bir uzaktan kumanda cihazı veya pilot tarafından kontrol edilir. Uzaktan kumanda cihazı, radyo frekansı (RF) veya diğer kablosuz teknolojiler aracılığıyla İHA ile iletişim kurar. Bu iletişim, İHA'nın temel uçuş kontrollerini ve hareketlerini yönlendirir.
- **Telemetri ve Kontrol Linki:** Bu link, İHA'nın uçuş verilerini (hız, yükseklik, batarya durumu, GPS konumu vb.) uzaktan kontrol cihazına geri gönderir. Ayrıca,

pilot veya operatörün İHA'ya komutlar göndermesini sağlar. Bu bağlantı, İHA'nın güvenli bir şekilde kontrol edilmesini ve uçuşun izlenmesini sağlar.

- **Veri Bağlantısı ve Video Akışı:** İHA'lar, görevleri sırasında önemli verileri (örneğin, görüntüler, videolar, termal görüntüler) toplarlar ve bu verileri kontrol merkezine veya yer istasyonuna iletmek için bir veri bağlantısı kullanırlar. Genellikle bu bağlantı, yüksek bant genişliğine sahip kablosuz iletişim teknolojileri (örneğin, Wi-Fi, 4G, 5G) kullanılarak yapılır. Bu, gerçek zamanlı video izlemesi ve veri analizi için önemlidir.
- **Otonom Kontrol ve Uçuş Kontrol Sistemi İletişimi:** İHA'lar, uçuşlarını kontrol etmek için içerisinde bir dizi sensör (GPS, jiroskop, ivmeölçer, manyetometre, barometre vb.) bulundurlar. Bu sensörlerden alınan veriler, uçuş kontrol sistemine iletilir. Bu iletişim, İHA'nın stabil bir şekilde uçmasını sağlar ve çeşitli otonom görevleri gerçekleştirmesine yardımcı olur.
- **Uydu Bağlantısı:** İHA'lar, uzaktan alanlarda görev yaparken GPS gibi uydu tabanlı navigasyon sistemleri ile iletişim kurarlar. Bu, İHA'nın kesin konumunu belirlemesine ve uçuşunun güvenli bir şekilde planlanmasına yardımcı olur.
- **Kara İstasyonu İletişimi:** İHA'lar genellikle bir kara istasyonu veya kontrol merkezi ile iletişim kurarlar. Bu merkez, İHA'nın kontrolünü üstlenir, görevleri planlar, verileri toplar ve analiz eder. İHA ile kara istasyonu arasındaki iletişim, genellikle güvenli ve güçlü bir bağlantı gerektirir.

İHA'ların iletişim modülleri, güvenilir ve sürekli bir bağlantı sağlamak için gelişmiş teknolojilerle donatılmıştır. Bu modüller, İHA'ların çok çeşitli görevleri yerine getirmelerini ve veri toplamalarını mümkün kılarak, birçok farklı endüstri ve uygulama için vazgeçilmez bir araç haline gelmiştir.

2.4.2. İHA Kullanım Alanları

İHA'ların kullanımı, teknolojinin gelişmesi ve maliyetlerin düşmesiyle daha çok yaygınlaşmıştır. Birçok yerde kullanılan İHA'ların bazı kullanım alanları şunlardır [43];

- Harita Mühendisliği Uygulamaları
- Endüstriyel Uygulamalar
- İnşaat Mühendisliği Uygulamaları
- Madencilik Uygulamaları
- Hassas Tarım Uygulamaları

- Arkeolojik Uygulamalar
- Çevre ve Doğa Uygulamaları
- Emniyet ve Güvenlik Uygulamaları
- Doğal Afet Uygulamaları
- Lojistik Uygulamaları
- Ticari Uygulamalar
- Hobi ve Spor Uygulamaları
- İletişim Uygulamaları
- Adli Uygulamalar
- Askeri Uygulamalar

2.5. Akıllı Yansıtıcı Yüzeyler (RIS)

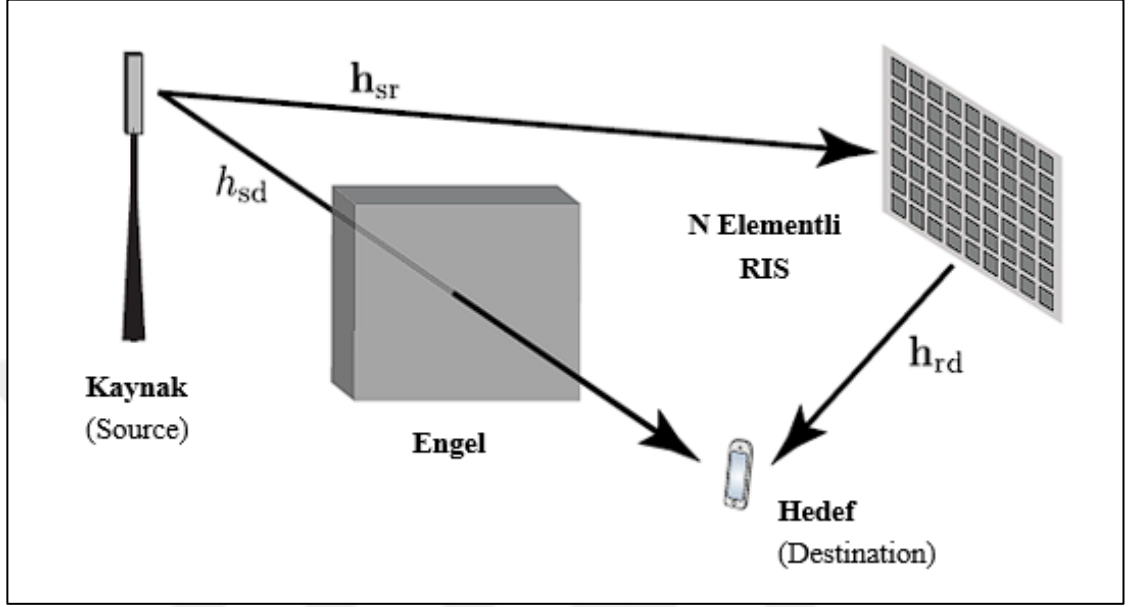
Kablosuz iletişim teknolojileri, günümüzün vazgeçilmez bir parçası haline gelmiştir ve bu teknolojilerin hızla evrimleşmesi, IoT cihazlarının, akıllı şehirlerin, kablosuz ağların ve İHA gibi gelişmiş uygulamaların daha etkili ve güvenilir hale gelmesine olanak tanımaktadır. Bu hızlı gelişmelere öncülük eden teknolojilerden biri, Akıllı Yansıtıcı Yüzeyler veya Reconfigurable Intelligent Surface (RIS) olarak adlandırılan yenilikçi bir kablosuz iletişim yaklaşımıdır [44].

Günümüzün hızla değişen iletişim dinamikleri, mevcut iletişim sistemlerinin gelecekte yetersiz hale geleceği gerçeğini ortaya koymaktadır. Bu bağlamda, daha gelişmiş kablosuz iletişim teknolojilerinin geliştirilmesi artık kaçınılmaz bir gereklilik halini almıştır. 6G, özellikle önceki nesillere göre veri hızını, güvenliği, kararlılığı ve mobiliteyi daha da yükseltmeye odaklanarak bu ihtiyaca cevap vermek için tasarlanmıştır. Gelecekteki iletişim taleplerini karşılayabilmek amacıyla, 6G kablosuz ağlarına yönelik birçok çalışma ve araştırma aktif bir şekilde yürütülmektedir [45]. RIS, 6G teknolojisinde kullanılması planlanan önemli bir teknolojidir.

Avrupa Telekomünikasyon Standartları Enstitüsü (ETSI), RIS için standartlar geliştirmek üzere bir Endüstri Spesifikasyonları Grubu (ISG) kurdu. ISG, RIS'in kullanım durumlarını belirleme ve standartlaştırma sürecindeki boşlukları doldurma amacını taşıyan bir çerçeve oluşturacak şekilde çalışmaktadır [46].

RIS teknolojisi, elektromanyetik dalgaların yansıtılması ve yönlendirilmesi yoluyla kablosuz iletişim sinyallerinin kontrolünü ve yönlendirilmesini sağlar. Geleneksel kablosuz iletişim sistemlerinde sinyaller doğrudan cihazlar arasında iletilir ve özellikle Şekil 2.5'te de görüldüğü gibi cihazlar arasında engeller mevcut ise bu durum sinyal zayıflamasına ve enerji

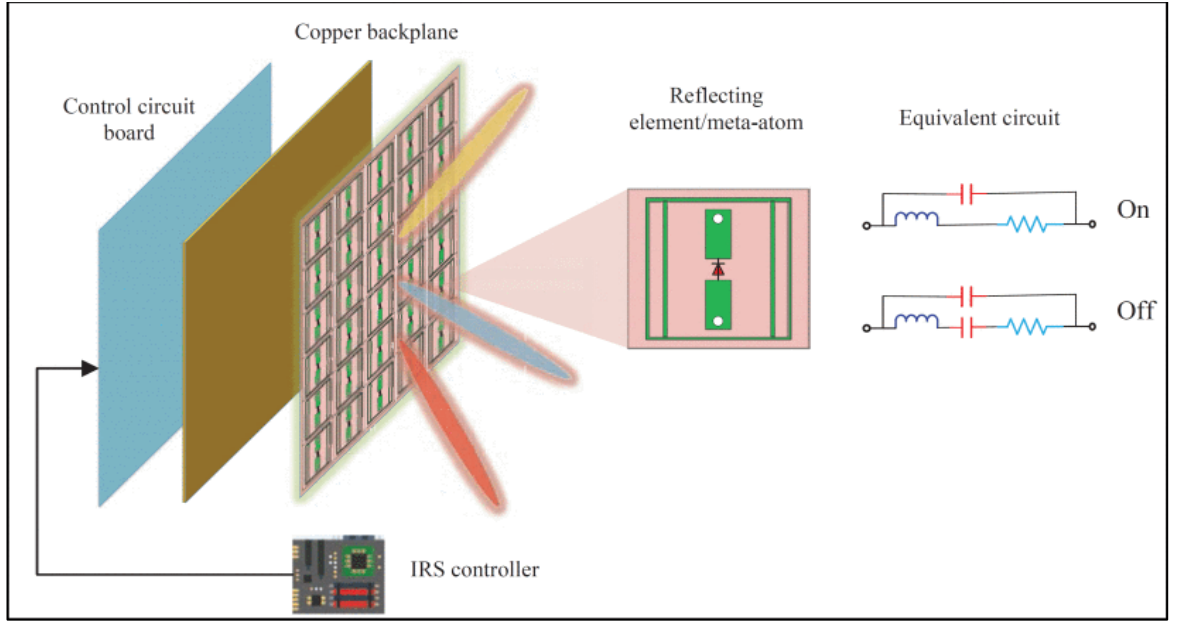
kayıplarına neden olabilir. RIS, bu sınırlamaları aşmak için tasarlanmıştır. RIS'ler, elektromanyetik dalgaları yansıtarak veya yönlendirerek, iletişim sinyallerinin kapsama alanını artırabilir, sinyal gücünü optimize edebilir ve enerji kayıplarını azaltabilir. Bu, kablosuz iletişimdeki verimliliği ve güvenilirliği artırmanın yanı sıra enerji tüketimini ve spektrum kullanımını optimize etmek için büyük bir potansiyel sunar.



Şekil 2.5. Akıllı Yansıtıcı Yüzey (RIS) destekli iletişim [47]

2.5.1. Akıllı Yansıtıcı Yüzeylerin Yapısı

Şekil 2.6'te RIS teknolojisinin yapısı gösterilmiştir. Tipik bir RIS yapısı üç katmandan ve bir denetleyiciden oluşur. Dış katman, doğrudan gelen sinyallerle etkileşime girmek için dielektrik bir zemin üzerine yerleştirilen çok sayıda metal elemandan oluşur. Bu katmanın arkasında, sinyal enerjisinin sızmasını önlemek amacıyla bir bakır levha bulunur. Son katman ise her bir elemanın yansıma şiddetini ve faz kaymasını ayarlamaktan sorumlu olan bir kontrol devre kartıdır. Bu ayarlamalar, RIS'e bağlı olan bir denetleyici tarafından tetiklenir [48].



Şekil 2.6. Akıllı Yansıtıcı Yüzeyin (IRS) Yapısı [48]

2.5.2. Akıllı Yansıtıcı Yüzeylerin Çalışma Prensibi

RIS, radyo iletişimde inovasyon sağlayan bir teknolojidir. Bu teknolojinin temel çalışma prensibi, Şekil 2.6’da da görüldüğü üzere, düzlemsel bir yapıya sahip yansıtıcı birimler aracılığıyla radyo dalgalarının fazını dinamik olarak düzenlemeye dayalıdır. Faz ayarı, elektromanyetik dalgaların yansıma açısını ve diğer özelliklerini kontrol ederek iletişim verimliliğini artırır. Gerçek zamanlı olarak kontrol edilen RIS, ağ yapılandırma sinyallerini kullanarak yansıtıcı birimleri yönlendirir ve iletişim kapsamını optimize eder. Esnek tasarımı, MIMO sistemleri, mikro-hücreler ve tekrarlayıcılar gibi farklı ağ yapılarına entegre edebilme yeteneği sunar. RIS, özellikle 6 GHz altı bantlarda karşılaşılan spektrum sıkışıklığını çözmek amacıyla tasarlanmış olup, radyo iletişim kapsamını genişleterek operatörlere daha etkili bir iletişim altyapısı sunma potansiyeli taşımaktadır [46].

2.5.2.1. RIS Yansıtıcı Birimlerinin Fonksiyonu

RIS yüzeyi, genellikle yüzlerce veya binlerce yansıtıcı biriminden oluşur ve bu birimler, elektromanyetik dalgaları yakalamak ve işlemek için kullanılır [48]. RIS yansıtıcı birimleri, genellikle antenler veya yükselticiler olarak tasarlanır ve aşağıdaki görevleri yerine getirir:

- **Sinyal Yakalama:** Yansıtıcı birimler, çevrelerinden gelen elektromanyetik dalgaları yakalarlar.
- **İşleme:** Yakalanan sinyalleri işlerler, sinyalin fazını ve amplitüdünü ayarlamak için kontrol sağlarlar.

- **Yeniden Yönlendirme:** İşlenmiş sinyalleri istenilen yönde yansıtarak elektromanyetik dalgaların yönlendirilmesini sağlarlar.

2.5.2.2. Faz Kayması İlkesi

RIS yansıtıcı birimleri, elektromanyetik dalgaların fazını ayarlayarak yönlendirmeyi gerçekleştirirler. Faz kayması, yansıtılan dalganın yönünü belirler [49]. Her yansıtıcı birim fazı, RIS üzerindeki konumuna ve hedeflenen yönlendirmeye bağlı olarak hassas bir şekilde ayarlanabilir.

2.5.2.3. Amplitüd Kontrolü

RIS yansıtıcı birimleri aynı zamanda sinyalin amplitüdünü de ayarlayabilirler. Bu, yansıtılan sinyalin yoğunluğunu kontrol etmek için kullanılır. Amplitüd kontrolü, iletişim sinyallerinin gücünü hassas bir şekilde düzenleyerek iletişim kalitesini artırır [50].

2.5.3. Akıllı Yansıtıcı Yüzeylerin Uygulama Alanları

RIS, elektromanyetik dalgaların özelleştirilebilir yönlendirilmesi ve kontrolü ile birçok uygulama alanında kullanılır:

2.5.3.1. Kablosuz İletişim Sistemleri

RIS, kablosuz iletişim sistemlerinde büyük bir potansiyele sahiptir. Özellikle, sinyal gücünü artırmak ve kapasiteyi iyileştirmek amacıyla baz istasyonlarına entegre edilebilirler [48]. Baz istasyonlarından gelen sinyalleri güçlendirerek ve yönlendirerek kablosuz iletişim sistemlerinin performansını artırır [5]. İHA'lar, RIS kullanarak iletişim sinyallerini güçlendirebilir veya gereken veri iletim gücünün azaltılmasını sağlayarak enerji verimliliğini artırabilirler [51].

2.5.3.2. 5G ve Sonraki Nesil İletişim

5G ve sonraki nesil iletişim ağları, yüksek hızlı veri iletimi gerektiren birçok uygulama için RIS kullanımını öngörüyor. Bu, iletişim performansını ve iletişimin güvenilirliğini artırabilir [5].

2.5.3.3. Güvenlik ve Gizlilik

RIS, elektromanyetik dalgaların istenmeyen bölgelere iletiminin engellenmesi ve böylece güvenliğin sağlanması açısından kullanılabilir bir teknolojidir. Özellikle, kablosuz ağlarda, sinyallerin sadece istenilen kullanıcılara yönlendirilmesiyle 3. şahısların iletimi dinlemesi ihtimali en aza indirgenebilir. Bu yüzden, güvenliğin ve gizliliğin artırılabilmesi için iyi bir potansiyele sahip bir teknolojidir [50], [52].

2.5.3.4. Uzay İletişimi

RIS, uzay iletişiminde sinyal gücünü artırmak ve veri iletimini iyileştirmek için kullanılabilir. Bu, gezegenlerarası iletişim ve keşifler için önemli olabilir [48]. RIS, SWaP (Size, Weight, and Power) gereksinimlerine uygun röle istasyonları kullanarak Karasal Olmayan Ağlar (Non-Terrestrial Networks - NTN) ile Derin Uzay Ağı (Deep Space Network - DSN) entegrasyonunu sağlayabilir. RIS'in, uzaydaki atmosferik etkilere dayanıklı, enerji verimli ve çevresel koşullara uygun bir şekilde tasarlanarak, uzay iletişimi alanında kapasite ve güvenilirliği artırma potansiyeli vardır [53].

2.5.3.5. Yeraltı İletişim

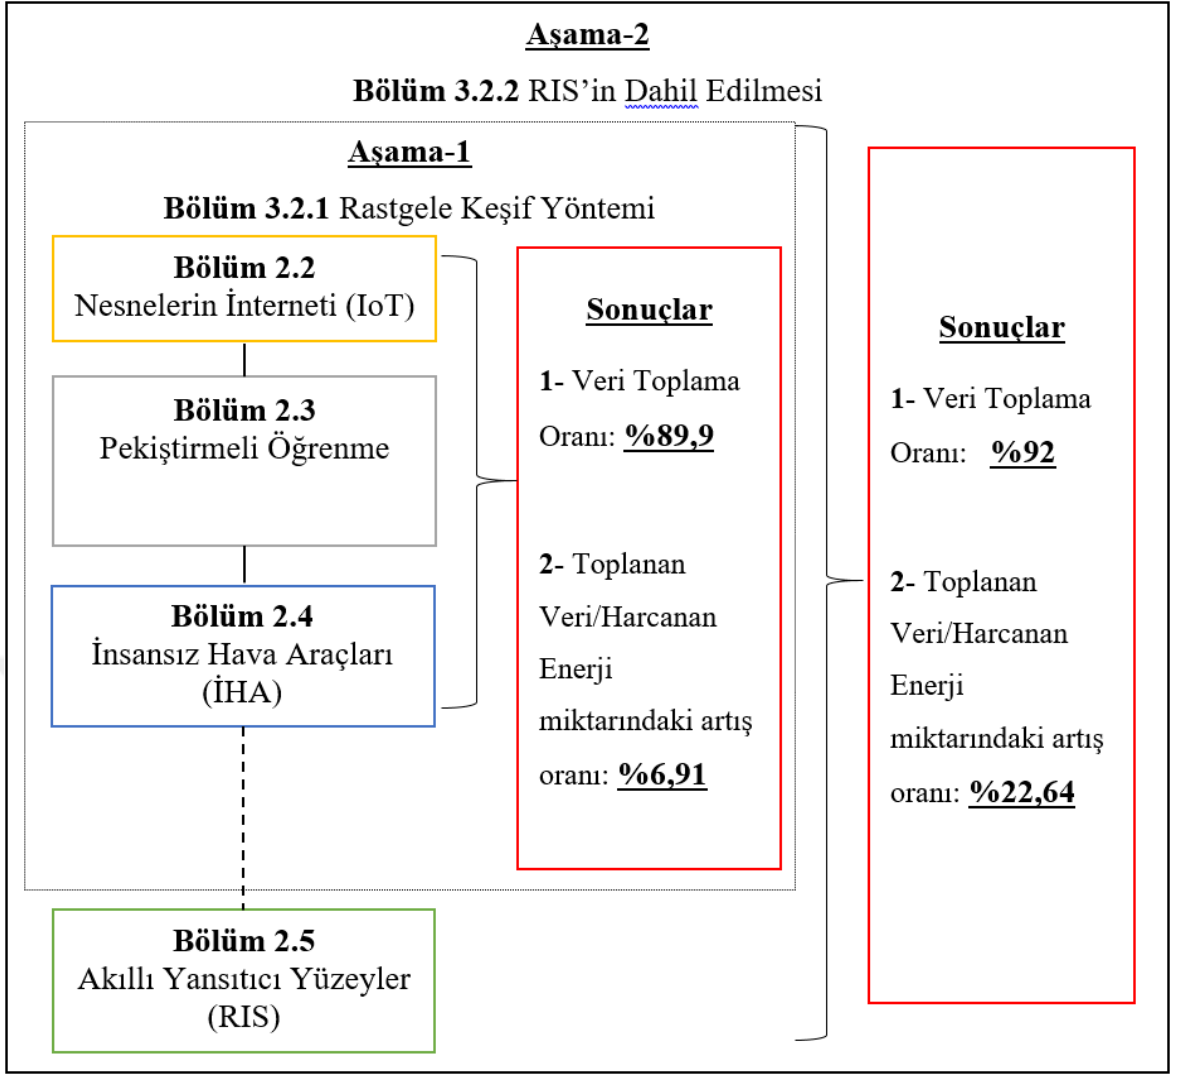
RIS, yeraltı iletişiminde sinyal penetrasyonunu artırmak ve kayıp oranını azaltmak için kullanılabilir. Bu, madencilik ve tünel iletişimi gibi uygulamalar için önemlidir [54].

Bu kullanım alanları, RIS'in çok yönlü ve gelecekteki iletişim teknolojilerinde önemli bir rol oynayabileceğini göstermektedir. Bu şekilde, RIS, elektromanyetik dalgaların özelleştirilebilir yönlendirilmesi ve kontrolü ile kablosuz iletişim sistemlerinde çeşitli avantajlar sunar ve gelecekteki iletişim teknolojilerinin gelişimine katkıda bulunabilir.

2.6. Tezin Aşamaları ve Başarım Oranları

Şekil 2.7'de tezin aşamaları ve bu aşamalarda elde edilen başarım oranları açıklanmıştır. Aşama-1 (Rastgele Keşif Yöntemi)'de; IoT, DDQN ve İHA teknolojileri kullanılmıştır. İHA, "Rastgele Keşif Yöntemi" algoritması eklendikten sonra yeniden eğitilmiş ve sistemin "Veri Toplama Oranı" başarısı %89,9'a çıkmıştır. Harcanan birim enerji başına toplanan veri miktarı ise %6,91 oranında artış göstermiştir.

Aşama-2'de, yukarıda bahsi geçen yönteme RIS teknolojisi dahil edilmiştir. Bu teknoloji sayesinde de "Veri Toplama Oranı" başarısı %92'ye çıkmış, harcanan birim enerji başına toplanan veri miktarı ise %22,64 oranında artmıştır.



Şekil 2.7. Tezin aşamaları ve elde edilen başarımlar oranları

3. MATERYAL VE YÖNTEM

Bu tez çalışmasında, karelere bölünmüş ve her bölüm x ve y koordinat düzleminde ifade edilebilen bir harita üzerine rastgele dağılmış IoT cihazlarından sabit bir yükseklikte (h) uçtuğu kabul edilen ve DDQN algoritmasıyla eğitilen bir İHA'nın, kalkış istasyonundan kalkarak engellere çarpmadan ve harita üzerinde “girilmesi yasak bölge” olarak işaretlenen alanlara girmeden, en uygun yolu tercih edip IoT cihazlarından maksimum veriyi toplayıp, güvenli bir şekilde iniş istasyonuna varması hedeflenmiştir.

Tezin bu bölümü iki aşamadan oluşmaktadır. Birinci aşamada, kullanılan sistem modeli ve sistemin performansının artırılması için simülasyonda yapılan değişiklikler detaylı bir şekilde açıklanmıştır. İkinci aşamada ise, RIS'in sisteme dahil edilmesi ile birlikte kullanılan yöntem ayrıntılı bir şekilde ortaya konmuştur.

3.1. Sistem Modeli

Bu çalışmada, Harald Bayerlein ve diğerleri [14] tarafından tasarlanan sistemin bazı durumlardaki veri toplamaya yönelik sorunları analiz edildi ve bu sorunlara çözüm getirilerek sistemin performansı iyileştirildi. Geliştirilen simülasyonun amacı, veri toplama görevini gerçekleştiren bir İHA ile sabit IoT cihazları arasındaki etkileşimi modellemektir. İlgili model aşağıda açıklanmıştır.

3.1.1. Ortam ve Koordinat Sistemi

Çalışma, her bir karesi x ve y koordinatlarıyla ifade edilebilen bir alanda gerçekleşmektedir. İHA, bu alanda bulunan K adet sabit IoT cihazından veri toplamaktadır. Her cihazın konumu;

$$c_k = [x_k ; y_k ; 0]^T \in R^3 \quad (3.1)$$

şeklinde ifade edilmektedir, burada $k \in [1, K]$ 'dir.

3.1.2. Görev Zaman Dilimi ve Konum

İHA'nın görevi $T \in \mathbb{N}$ zaman birimi boyunca devam eder ve bu süre $t \in [0, T]$ aralığına eşit zaman dilimlerine bölünmüştür.

İHA'nın konumu;

$$u_{konum} = [x(t); y(t); h]^T \in R^3 \quad (3.2)$$

olarak ifade edilir, burada h sabit bir yüksekliktir ve yükseklik değeri veri toplama süresince değişmemektedir.

3.1.3. İletişim Modeli

İHA ve K ($k \in [1, K]$) adet IoT cihazı arasındaki iletişim, [55]'teki kanal modeline benzer bir biçimde uygulanmıştır. Bu bağlantılar, görüş açısına bağlı olarak doğrudan görüş (LoS) veya doğrudan görüş olmayan (NLoS) noktadan noktaya kanallar olarak tasarlanmıştır. Çalışmada, logaritmik uzaklık yol kaybı ve gölge sönümlenmesi etkileri dikkate alınmıştır. Belirli bir an (n) için, k 'inci cihazın veri iletim hızı “Denklem 3.3” ile hesaplanmaktadır:

$$r_k(n) = \log_2(1 + SNR_k(n)) \quad (3.3)$$

Sinyalin gürültüye oranı ise “Denklem 3.4” ile ifade edilmiştir.

$$SNR_k(n) = \frac{P_k}{\sigma^2} \cdot d_k(n)^{-\alpha_l} \cdot 10^{\eta_l/10} \quad (3.4)$$

Burada, verici gücü P_k , alıcı gürültüsünün gücü σ^2 , İHA ile sensör arasındaki uzaklık d_k yol kaybı üstel değeri α_l ve gürültü Gauss rassal değişkeni $\eta_l \sim \mathcal{N}(0, \sigma_l^2)$ olarak verilmiştir.

3.1.4 İHA'nın Veri Toplama Modeli

İHA, çeşitli sensörleri kullanarak çevresindeki bilgileri toplamak ve iletişim zaman dilimleri içinde bu bilgileri iletmek için özel olarak tasarlanmıştır. Bu görevlerde temel amaç, toplanabilecek veri miktarını (throughput) maksimize etmek ve aynı zamanda uçuş süresini minimize etmektir. Bu bağlamda, belirli bir görev zaman dilimi içinde elde edilebilecek veri miktarını hesaplamak için “Denklem 3.5” kullanılmıştır. Bu optimizasyon problemi, maksimum uçuş süresi (dolayısıyla İHA enerjisi), uçuşa yasak bölge (No-Fly

Zones), engelden kaçınma ve güvenli iniş alanlarına ulaşma gibi kısıtlar dikkate alınarak formüle edilmiştir. Formül olarak ifade edildiğinde, elde edilebilir veri miktarı $C(t)$, belirli bir görev zaman kesiti t için şu şekilde hesaplanır [14]:

$$C(t) = \sum_{n=\delta t}^{\delta(t+1)-1} \sum_{k=1}^K q_k(n)r_k(n) \quad (3.5)$$

- $C(t)$: Elde edilebilir toplam veri miktarı
- δ : Her bir t süresi δ adet iletişim zaman kesitine bölünür. $N = \delta T$ şeklinde ifade edilir.
- t : Her bir görev zaman kesiti indeksi
- n : Her bir iletişim zaman kesiti indeksi
- K : Toplam sensör sayısı
- $q_k(n)$: n . zaman kesitinde sensörün veri transferi için aktif olup olmadığını gösterir. 0 veya 1 değerini alır. İlgili zaman kesitinde SNR değeri en yüksek sensörden veri alım işlemini gerçekleştirir.
- $r_k(n)$: Sensör k için n . zaman kesitindeki veri hızı

İHA'nın veri toplama görev süresine T denilirse, T 'nin eşit zaman aralıklarına bölünmüş her bir zaman kesiti t olarak belirlenmiştir. Her bir t süresi boyunca İHA'nın hızının sabit olduğu düşünülmektedir. Dolayısıyla her bir $t \in [0, T]$ için İHA $v(t) \in \{0, V\}$ olmak üzere iki hızla sınırlandırılmıştır. Ayrıca haberleşme zaman kesiti İHA'nın görev süresi kesitinden daha fazla olacağı için, her bir t kesiti de n adet eşit zaman aralığına bölünmüştür ve $n \in \{0, N\}$ için $N = \delta T$ şeklinde ifade edilmiştir. Diğer taraftan İHA'nın pozisyonu ve kanal kazancı'nın sabit sayılabilmesi için n 'nin yeterince bir büyüklükte seçildiği düşünülmüştür. Özetle, "Denklem 3.5" her bir zaman aralığı için, aktif olan farklı sensörlerden gelen verilerin toplamı, elde edilebilecek toplam veri miktarını ifade eder.

3.1.5. İHA Eğitimi

İHA, Bölüm 2.5.1.1'de detaylı olarak açıklanan DDQN algoritması sayesinde, her adımda veriyi en iyi toplayabileceği güzergahı belirlemektedir. Bunu yaparken de giremeyeceği bölgeler (girilmesi yasak bölge), gölge sönmelenmesi ve kalan enerjisini göz


önünde bulundurup, sinyal gücü en yüksek olan IoT cihazına doğru hareket edecek şekilde eğitilmiştir. Bu yöntemde, iki ayrı ağ kullanılmıştır: birincisi eğitilen ağ ve ikincisi hedef ağ (target network). Eğitilen ağ, Q-fonksiyonunu yakınsamak için kullanılmıştır. Diğer taraftan, hedef ağ, hedef değerlerin hesaplanması için devreye girmiştir. Yani, eğitilen ağ, belirli bir görevi öğrenirken, hedef ağ, bu görevin hedef değerlerini belirlemek için kullanılmıştır [29].

Deneyim tekrarı (Experience Replay) ve birleşik deneyim tekrarı (Combined Experience Replay) gibi teknikler, ajanın eğitimini daha kararlı hale getirmek için kullanılmıştır [56]. Yani, İHA veri toplamaya başlarken, iletişim kanalı, IoT cihazlarının konumu ve SNR hakkında önceden hiçbir bilgisi yoktur. Experience Replay ve Combined Experience Replay sayesinde deneyimlerden hareketle yola çıkmaktadır.

İHA'nın hareketi, bu öğrenme süreçleri aracılığıyla, durumu değerlendirme, en uygun eylemi seçme ve ödüllere dayanarak davranışını optimize etme yoluyla şekillenmiştir. Bu yöntemler, ajanın (İHA'nın) çevresiyle etkileşimde bulunarak öğrenmesini ve görevini optimize etmesini sağlamıştır [40].










3.1.6. Ortam ve Kullanılan Semboller

Sistemde kullanılan ortam [14]'deki gibi karelere ayrılmıştır. Her bir kare X ve Y şeklinde ifade edilebilen koordinatlara sahiptir. X yataydaki konumu ifade ederken, Y düşeydeki konumu ifade etmektedir. Ortamın görseli Şekil 3.1'de, kullanılan semboller ise Çizelge 3.1'de gösterildiği gibidir.



Şekil 3.1. İHA'nın öğrenerek veri toplama işlemini gerçekleştirdiği ortam modeli

Çizelge 3.1. Simülasyonda kullanılan semboller ve sembollerin açıklamaları [14]

Sembol	Açıklama
	Kalkış ve iniş bölgesi
	Uçuşa yasak bölge (NFZ)
	Bağlantıyı engelleyen binalar
	IoT cihazları (Farklı renklerde)
	Gölgeleme (Shadowing)
	Kalkış ve iniş pozisyonu
	İletişim sırasında İHA'nın hareketi (Yeşil IoT cihazından)
	İletişim sırasında havada asılı durma (Yeşil cihazla)
	İletişim kurmadan hareket eden İHA (Tüm veriler toplandıktan sonra)

3.1.7. Simülasyonun Ham Verileri

Simülasyon, orjinal formunda hiçbir değişiklik yapılmadan 1000 rastgele senaryo ile çalıştırıldı ve Çizelge 3.2'deki sonuçlar elde edildi. Buradaki öncelikli amacımız, kullanacağımız öğrenme modelinin testini yapmaktır. Daha sonra ise bu modeli yeni geliştirdiğimiz modelle karşılaştırmamız mümkün olacaktır.

Çizelge 3.2. 1000 adet denemenin her birinde parametrelerin değerleri Monte Carlo yöntemi ile rastgele bir aralıktan seçilmiştir ve ortalama değer elde edilmiştir [14]

	Simülasyon Sonuçları-1
Başarılı İniş*	0,983
Veri Toplama Oranı*	0,831
Toplam Veri	80242
Toplanan Veri	66055
Harcanan Enerji	83072
Toplanan Veri/Harcanan Enerji	0,795

* Değerler 0-1 arasında normalize edilmiştir.

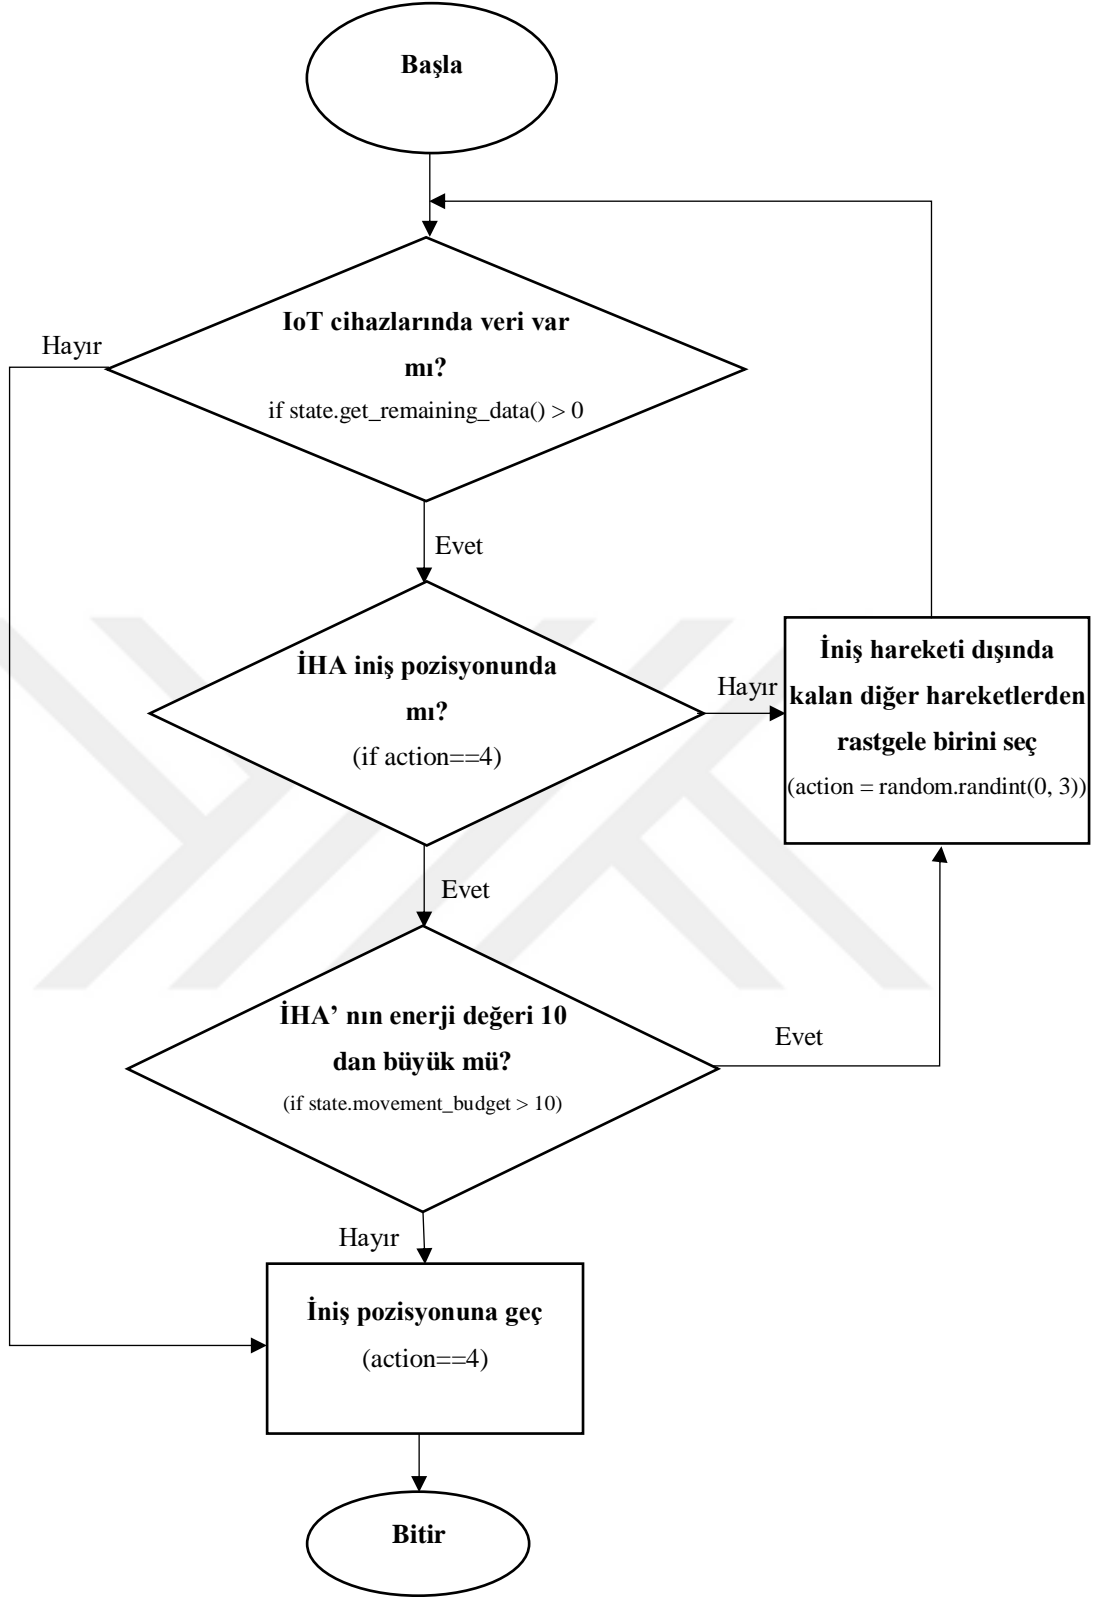
3.2. Yöntem

Bu bölümde çalışmada kullanılan yöntemler ele alınacaktır. Çalışmamız iki aşamadan oluşmaktadır: Aşama-1 ve Aşama-2.

3.2.1 Aşama-1: Rastgele Keşif Yöntemi ve Yön Kapasite Arttırımı

Aşama-1 için Bölüm 3.1'de anlatılan sistem modeli kullanılarak İHA'nın dört yöne doğru hareketi (Doğu, Batı, Kuzey, Güney) fazla enerji harcamasına sebep olduğu da göz önünde bulundurularak sistem 8 yöne doğru (Doğu, Batı, Kuzey, Güney, Güneydoğu, Güneybatı, Kuzeydoğu, Kuzeybatı) hareket etmek üzere yeniden tasarlandı.

Simülasyondaki bazı senaryolarda (örneğin verinin az ve IoT cihazının uzakta olduğu durumlarda) İHA'nın veri toplamak için harekete geçmediği ve bu veriyi toplamadığı saptandı. Bu durum simülasyona eklenen ve Şekil 3.2'de gösterilen algoritma ile çözülmeye çalışıldı. Buna göre, ortamda toplanması gereken veri varken İHA'nın da yeterli enerjisi varsa İHA'nın daha fazla keşif yapması sağlanmış oldu. Simülasyon bu değişikliklerden sonra 2 milyon iterasyonla yeniden eğitildi ve sonuçlar hazır modelle karşılaştırılarak veri toplama oranına etkisi incelendi. Bu değişikliklerin etkisi, hem manuel olarak oluşturulan senaryolarla tek tek incelendi, hem de 1000 adet rastgele (random) senaryodaki veri toplama oranı ortalaması ve enerji verimliliği üzerindeki etkiler araştırıldı.




Şekil 3.2. Rastgele Keşif Yöntemi akış şeması

3.2.2. Aşama-2: RIS'in Sisteme Dahil Edilmesi

Aşama-2'de ise Aşama-1'de geliştirilen sisteme RIS eklenerek İHA'nın performansı, toplanan veri miktarı ve enerji verimliliği açısından incelenmiştir. Bu bölümde RIS'in sisteme dahil edilmesiyle ne kadarlık bir enerji korunumunun gerçekleştirilebileceğinin analizini ilgili literatürden araştırdık. Buna göre de bir enerji harcanım oranı belirledik.


3.2.2.1. RIS'in Enerji Verimliliği

Yao Y. ve diğerleri [57]'deki çalışmada kablosuz güç iletim sistemini incelemiş, RIS ve AF (Amplify and Forward) röle sistemleri arasındaki enerji verimliliği oranını ele almışlardır. Çalışmadaki sonuçlara göre, RIS yardımcı sistemde elde edilen enerji verimliliği, aynı konumda bulunan 8 antenli bir AF röle sistemine kıyasla belirgin bir şekilde daha yüksektir. Optimal güç seviyeleri ve faz kaymalarını optimize etme stratejileri kullanıldığında, RIS yardımcı sistemin enerji verimliliğinde %150'ye varan bir iyileşme gözlemlenmiştir. Bu sonuçlar, RIS'in enerji tasarrufu sağlamakla kalmayıp aynı zamanda sistemdeki enerji verimliliğini artırdığını da göstermektedir. Şekil 3.3'de maksimum güç 17dBm değerinde sınırlandırılırken RIS optimize edilmediği durumda RIS' in olmadığı senaryoya kıyasla enerji verimliliğinde yaklaşık olarak %28 ve %48 artış sağlanmıştır.




Şekil 3.3. Farklı algoritmalarla Pmax'a (Maksimum Güç) karşı enerji verimliliği [57]

Mondal A. ve diğeri [58]'deki çalışmada IoT cihaz sayısının ortalama enerji verimi üzerindeki değişimi göstermektedir. Şekil 3.4'ten de görüleceği üzere, IoT cihazlarının sayısı arttıkça ağın enerji verimliliğinin düştüğü görülmektedir. Bu, toplam güç tüketimindeki artıştan kaynaklanmaktadır. Daha fazla IoT eklendikçe, ağın güç tüketimi, her IoT cihazından iletilen ve devre gücü tüketiminden dolayı artar. Şekil 3.4'te 1 adet IoT cihazıyla RIS kullanıldığında elde edilen enerji verimliliği RIS'in olmadığı duruma göre yaklaşık olarak %57 artmıştır.



Şekil 3.4. N elemanlı IoT cihazlarının enerji verimliliği üzerindeki etkisi [58]

AI-Hilo A. ve diğeri [59]'teki çalışmada RIS boyutlarının çeşitli olasılıkları için enerji verimliliği seviyelerini incelemişlerdir. RIS'in, insansız hava aracının (İHA) enerji verimliliği üzerindeki etkisini anlamak amacıyla yapılan bu analizde, RIS'in İHA'nın yol planlamasında esneklik sağlayarak tüketilen enerji miktarını minimize ettiği ve bağlantı kalitesini arttırdığı ortaya konmuştur. Şekil 3.5'te görüldüğü üzere 50 yansıtıcı birimli bir RIS sayesinde enerji verimliliği 15 bits/KJ'ün üzerinde gerçekleşiyor. Bu önemli artış, RIS'e sadece 25 yansıtıcı birim eklenerek %30'a kadar artarak devam ediyor ($M = 75$). RIS'in olmadığı duruma kıyasla 25 yansıtıcı birimli bir RIS cihazının enerji verimliliği üzerinde %100 oranında artış sağladığı da görülmektedir.




Şekil 3.5. M yansıtıcı birimli RIS cihazının enerji verimliliği üzerindeki etkisi [59]

Björnson E. ve diğerleri [47]'teki çalışmada enerji verimliliği ve veri iletim hızı arasındaki bağlantıyı incelemişlerdir. Enerji verimliliği, veri iletimi için harcanan enerji ile iletilen veri miktarı arasındaki oranı ifade eder. Şekil 3.6'da kullanılan değerler şu şekildedir;

- **v (verici verimliliği):** 0,5 olarak verilmiş. Bu, enerji verimliliğini hesaplarken kullanılan güç amplifikatörünün verimliliğini temsil eder.
- **P_s, P_d, P_r (güç değerleri):** $P_s=P_d=P_r = 100 \text{ mW}$ olarak belirtilmiş. Bu, sırasıyla kaynak, hedef ve rölede harcanan güç miktarlarını temsil eder.
- **P_e (eleman başına düşen güç tüketimi):** $P_e = 5 \text{ mW}$ olarak verilmiş. Bu, RIS'teki her bir yansıtıcı biriminin adaptif faz kaydırma için gerekli devreler tarafından tüketilen gücü temsil eder.
- **d_1 (mesafe):** $d_1 = 70 \text{ m}$ olarak verilmiş. Bu, iletim mesafesini ifade eder.

$r > 4,9 \frac{\text{bit}}{\text{s}}/\text{Hz}$ olduğunda RIS'in $N^{opt} > 0$ olduğu ve $r > 8,48 \frac{\text{bit}}{\text{s}}/\text{Hz}$ olduğunda RIS'in DF röleleme durumundan daha yüksek enerji verimliliği sağladığı belirtilmiş.



Şekil 3.6. Enerji verimliliği ile veri iletim hızı arasındaki ilişki [47]

3.2.2.2. Öğrenme Parametrelerinin Belirlenmesi

Yukarıda sunulan makalelerde RIS'in ek olarak getirmiş olduğu enerji verimliliği fiziksel katman tasarımı, RIS'in kaynak ve hedefe göre konumu, RIS'te kullanılan birim eleman sayısı, veri iletim kapasitesi vb. değişkenlerden dolayı %28 ile %150 arasında seyretmektedir. Fiziksel katman benzerliği göz önüne alındığında sistemimize uygulanabilir olmasından dolayı ve RIS'in avantajını ortaya koyabilmek adına Şekil 3.6'da verilen enerji verimliliği simülasyonunu tekrar çalıştırıp uygun olabilecek bir enerji verimliliği oranını sistemimize uyguladık [47]. Burada dikkat etmemiz gereken RIS (IRS)'in decode-and-forward (DF) sistemine göre avantajlı olmaya başladığı 8.48 bits/s/Hz veri iletim kapasitesi üzerindeki değerlerden seçmek gerekmektedir. Veri iletim kapasitesinin 8.8 bits/s/Hz ile 9.4 bits/s/Hz olduğu aralık için Çizelge 3.3'de sağlanan enerji verimliliği avantajı listelenmiş ve uygun görülen bir değer seçilmiştir.

Çizelge 3.3: Veri iletim hızına göre enerji verimliliği karşılaştırması

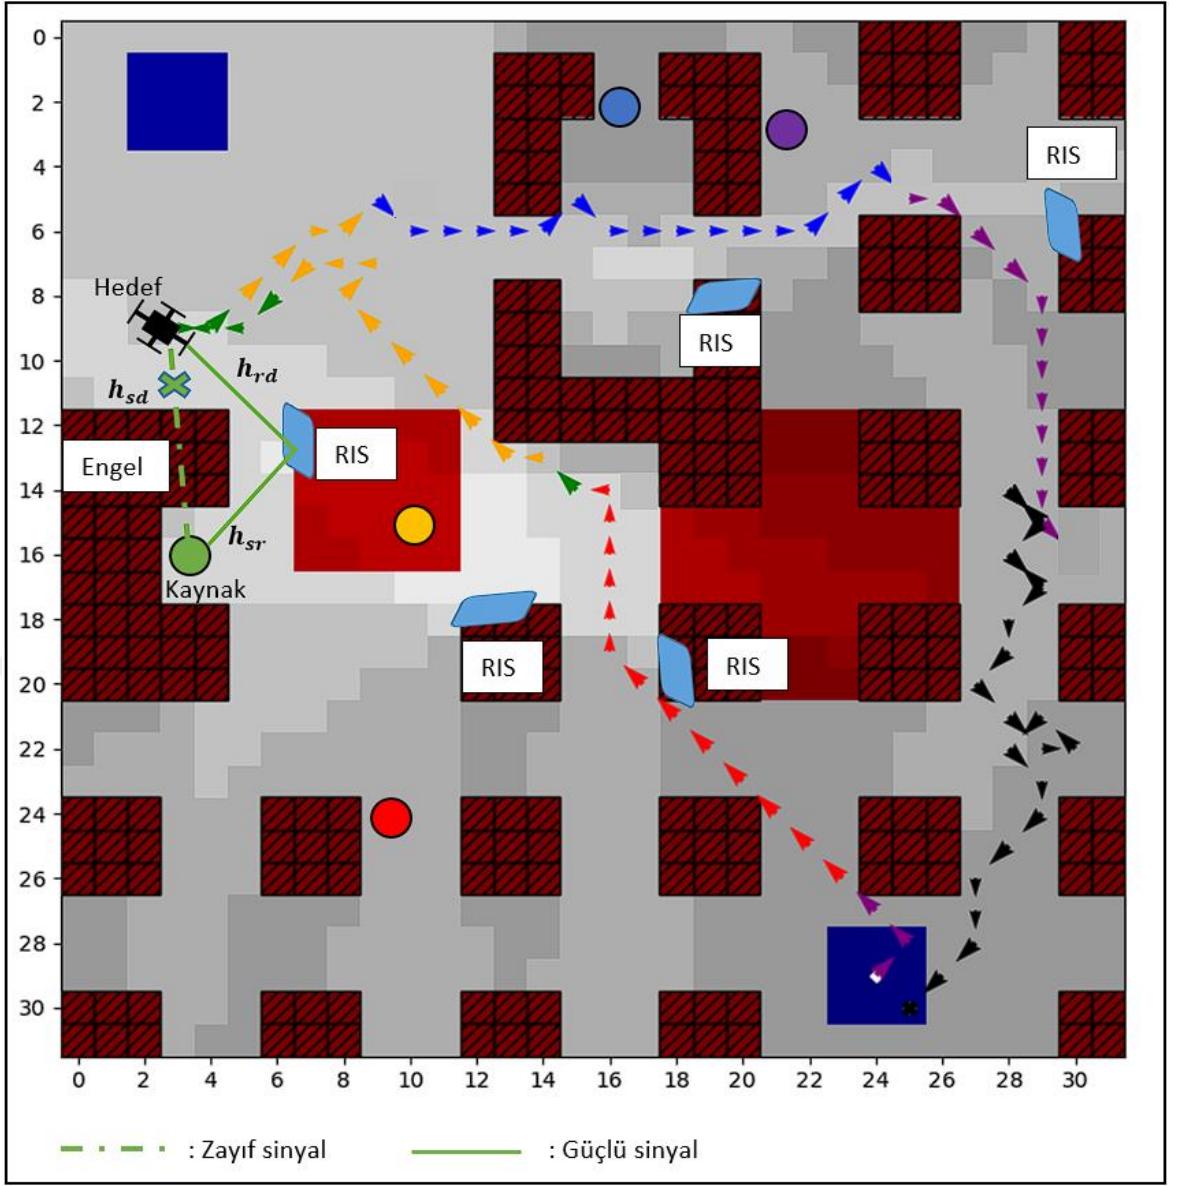
Veri iletim kapasitesi [bit/s/Hz]	RIS	Decode-and-forward (DF)	Enerji verimliliği DF'e göre % kaç daha iyi?
8,8	113,2643	89,0069	21,4167
8,9	112,1092	81,0174	27,7335
8,94	111,6455	77,9485	≈30
9	110,9483	73,4871	33,7646
9,1	109,7826	66,4407	39,4798
9,2	108,6127	59,8907	44,8585
9,3	107,4394	53,8388	49,8892
9,4	106,2634	48,2778	54,5678

Çizelge 3.3'e göre RIS'in DF sistemine göre yaklaşık %30 daha enerji verimli olduğu 8,94 bit/s/Hz değeri sistemimiz için düşünülmüştür. İHA, her bir sensöre yeterince yaklaşarak gerekli veri toplama işlemini gerçekleştirdiği için, Bjornson ve diğerlerinin [47]'de sunmuş olduğu karşılaştırmalı sistemin kendi sistemimize entegrasyonunun uygun olduğuna karar verilmiştir. Bu açıdan simülasyon için gerekli olan parametre değerleri [47]'nin Bölüm 4'üne göre tanımlanmış ve Çizelge 3.4'de sunulmuştur. Aynı harita dolayısıyla aynı gölge sönümlenmesi haritası için karşılaştırmalı analiz yapılacağı için gölge sönümlenmesi, çalışmanın RIS dahil edilen kısmında ihmal edilmiştir. Kanal kazancı 3GPP Urban Micro (UMI)'ye göre uzaklığın bir fonksiyonu olarak düşünülmüştür. Şekil 3.7'de görüldüğü gibi sistem modelimizde hedef sensörler ve RIS sabit bir şekilde konumlandırılmışken İHA, manevra hareketiyle sensörlere belirli bir mesafe yaklaşarak veri toplama görevini gerçekleştirmektedir. İHA'nın aynı zaman aralığında sadece SNR değeri en yüksek sensörden veri aldığı kabul edilmektedir. Bu mesafenin her bir hedef sensör için [47]'daki gibi ortalama 70 m olduğu düşünülmüştür. Bu modelde, RIS'in kullanımını teşvik edebilmek için İHA ile sensör arasında direkt görüşün olmadığını fakat İHA-RIS ve RIS-Sensör arasında direkt görüşün olduğunu kabul etmekteyiz. Sistemin genelinde belirlenimci düz-sönümlenmeli kanal düşünülmüştür. Ayrıca, her RIS en yakınındaki sensöre ve güzergahtan geçmekte olan İHA'ya tek antenli kaynak ve tek antenli hedef iletişimi şeklinde hizmet vermektedir. Bir RIS'in diğer bir RIS'le olabilecek etkileşimi (basamaklı kanal - cascaded channel) veya bir RIS'in birden fazla sensörle etkileşimi (çok kullanıcı sistemler - multi-user) bu çalışmada düşünülmemiştir. RIS'in yansıtıcı birim elemanı sayısı, RIS'in

enerji verimliliğinin belirlenmesindeki en önemli parametrelerden biridir. Bu yüzden, verilen veri transfer hızına ve toplam güç değerine göre bir sistemin yansıtıcı birim elemanı sayısını (N) optimize etmek [47]'daki "Denklem 3.6" ile mümkündür.

$$N^{opt} = \sqrt[3]{\frac{(2^r - 1)\sigma^2}{\alpha^2 \beta_{IRS} P_e}} - \frac{1}{\alpha} \sqrt{\frac{\beta_{sd}}{\beta_{IRS}}} \quad (3.6)$$

- σ^2 : Gürültünün gücü
- α : Genlik yansıtma katsayısı (0-1 aralığında)
- r : Veri hızı
- $\beta_{IRS} = (\frac{1}{N} \sum_{n=1}^N |[h_{sr}]_n [h_{rd}]_n|)^2$: RIS kanal kazancı
- $\beta_{sd} = (|h_{sd}|)^2$: Kaynaktan hedefe kanal kazancı
- P_e : RIS yansıtıcı birim elemanının güç kaybı



Şekil 3.7. İHA ile RIS destekli veri toplama sistemi (Temsili gösterim)

Çizelge 3.4: Simülasyon parametreleri ve parametrelerin değerleri

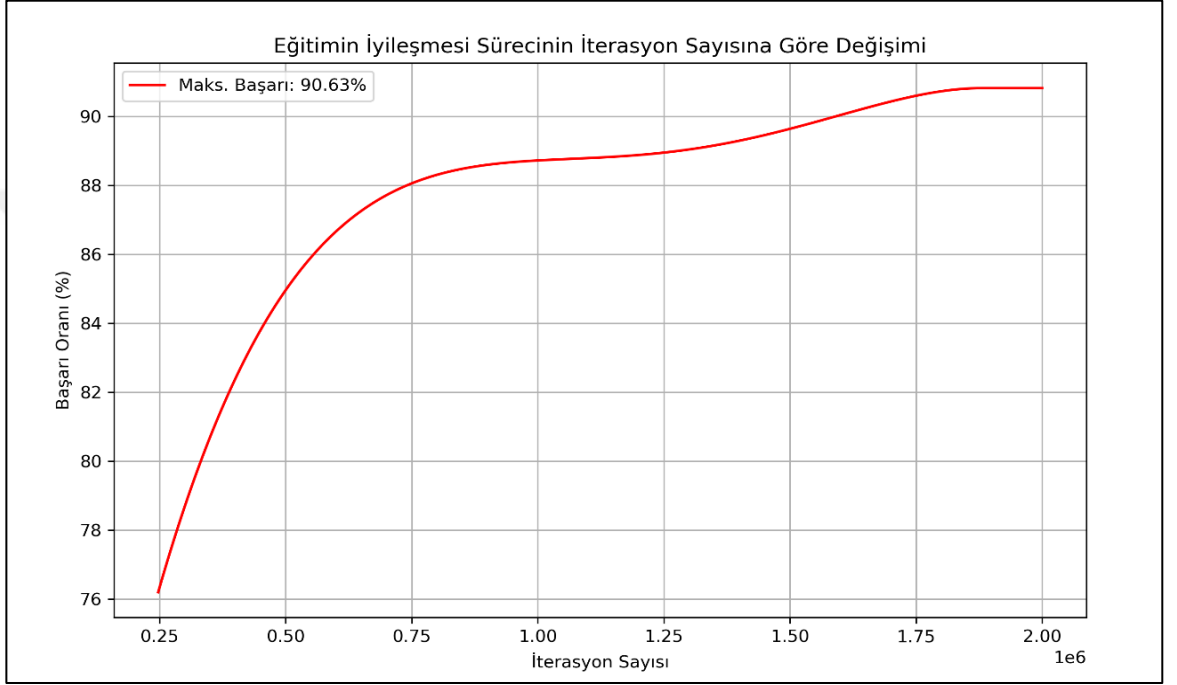
Parametre	Değer
Güç yükselticisi verimliliği, ν	0,5
Kaynak donanımından kaynaklı güç kaybı, p_s	100mW
Hedef donanımından kaynaklı güç kaybı, p_d	100mW
Aktarıcıdaki (DF için) güç kaybı, p_r	100mW
Her bir RIS birim elemanındaki güç kaybı, p_e	5mW
Mesafe, d_1	$\approx 70\text{m}$
Bant genişliği	10 MHz
Veri aktarım kapasitesi, r	$\approx 30 \text{ bit/s/Hz}$
Gönderici ve alıcı anten kazançları, G_t/G_r	5dBi
Taşıyıcı frekans	3 GHz
Genlik yansıtma katsayısı, α	1

4. BULGULAR VE TARTIŞMA

4.1. Aşama-1

4.1.1. İHA'nın Yeniden Eğitilmesi

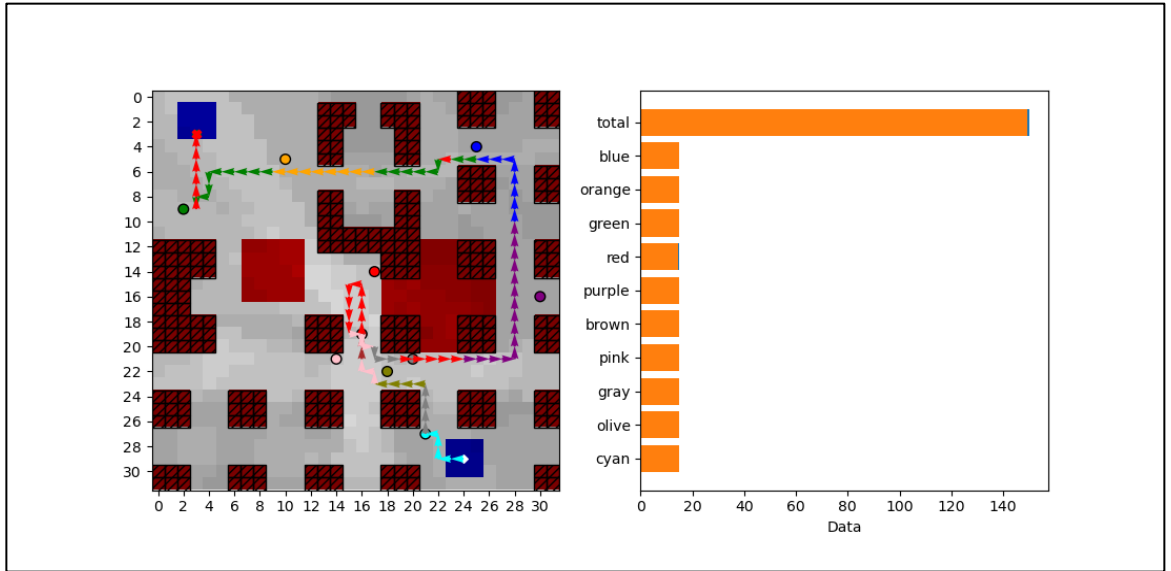
İHA, Bölüm 3.2.1'de yapılan değişikliklerle yeniden eğitilmiş olup eğitim sonuçları Şekil 4.1'deki gibi elde edilmiştir. Şekilde İHA'nın başarı oranı %90,63'e ulaştığında maksimum başarı oranına ulaştığı ve bu değerden sonra daha fazla iyileşme kaydetmediği ve yatay olarak ilerlediği görülmektedir.




Şekil 4.1. 2 Milyon iterasyonla eğitilen İHA'nın başarı grafiği (Eğitim ilerlemesinde elde edilen maksimum başarı değerleri baz alınarak oluşturulmuştur.)

4.1.2. İHA'nın Yön Kapasitesi Testi

Bu senaryoda sistemde bulunan 10 adet IoT cihazlarının her birine eşit olacak şekilde 15 birim veri yüklenmiş ve konumları manuel olarak ayarlanmıştır. İHA'nın enerji miktarı 150 birim olarak belirlenmiştir. İHA'nın 4 yöne doğru (Doğu, Batı, Kuzey, Güney) hareket edebilme rotası ve veri toplama kapasitesi ile 8 yöne doğru (Doğu, Batı, Kuzey, Güney, Güneydoğu, Güneybatı, Kuzeydoğu, Kuzeybatı) hareket rotası ve veri toplama kapasitesi Şekil 4.2 ve Şekil 4.3'te gösterilmiştir.



Şekil 4.2. İHA'nın 4 yöne hareket edebildiği rotası ve toplanan veri [14]



Şekil 4.3. İHA'nın 8 yöne hareket edebildiği rotası ve toplanan veri

Alınan sonuçlar yukarıda Şekil 4.2 ve Şekil 4.3'te de görüldüğü üzere İHA 8 yöne hareket edebildiği durumda veri toplama işini daha kısa sürede bitirmiş ve tüm verileri topladığı halde hala enerjisi bitmemiştir (siyah oklar İHA'nın toplayabileceği verinin kalmadığı durumlardaki hareketini gösterir). Ayrıca Şekil 4.2'de görüldüğü gibi İHA kırmızı renkli (red) IoT cihazı haricindeki tüm verileri topladıktan sonra iniş yapmadan önce son bir kez geriye kalan veriyi toplamaya çalışmış ama bunu başaramamıştır. Fakat Şekil 4.3'te cihazlardaki tüm veriler toplanabilmiştir.


4.1.3. Manuel Senaryo Testleri

İHA, enerjisi yeterli olduğu halde bazı sensörlerde daha az veri olduğu durumlarda veya uzak olduğu durumlarda bu sensörde bulunan veriden vazgeçip iniş pozisyonuna

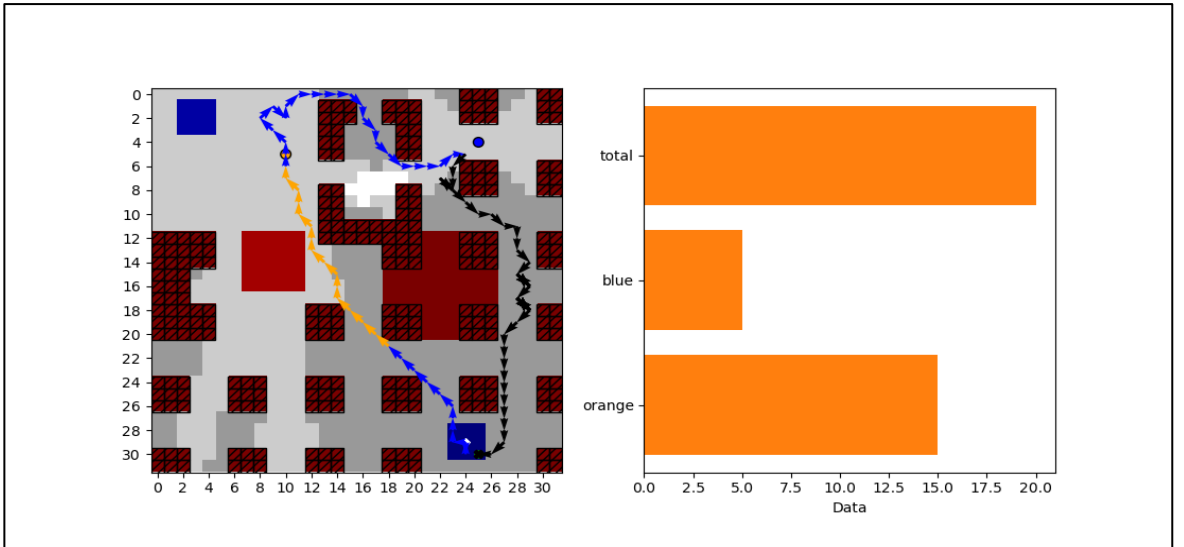
geçebiliyordu. Bazı durumlarda ise İHA sistemdeki bu cihazları hiç algılamayıp kalkışa geçmiyordu [14]. Bu durum sistemde bulunan görece az ama önemli veri barındıran bir sensördeki verinin alınmamasına sebep verebilirdi. Bu sorun, Bölüm 3.2.1 ve Şekil 3.2’de de gösterdiğimiz algoritma sayesinde, sistemde veri olduğunda bunu algılamasını sağlayan ve enerji yeterli miktarda ise daha fazla keşif yapmasına olanak tanıyan algoritma değişikliği ile sistem, [14]’ teki sisteme göre daha verimli hale getirilmiştir.

4.1.3.1. Senaryo-1: Keşif Kabiliyeti

Bu senaryoda; Şekil 4.4 ve Şekil 4.5’te mavi (blue) cihaza 5 birim, turuncu (orange) cihaza 15 birim veri yüklenmiştir. İHA’nın enerji miktarı 150 birimdir. IoT cihazlarının konumu manuel belirlenmiş ve her iki şekilde de aynı konuma yerleştirilmiştir. Data grafiğinde mavi renk verinin toplanmadığı durumu, turuncu renk ise toplanabildiği durumu göstermektedir.



Şekil 4.4. İHA'nın cihazları algılayamadığı durum [14]




Şekil 4.5. Yeni parametrelere göre tekrar eğitilen İHA'nın hareketi


Şekil 4.4'te İHA cihazlardaki veriyi algılayamadığı için hareketsiz kalmıştır fakat Şekil 4.5'te İHA ortamdaki veriyi algılıyor ve tüm verileri topladıktan sonra güvenli bir şekilde iniş yapıyor. Bu örnekteki başarı oranı %100'dür. Bu durum Bölüm 3.2'deki yöntemde anlatılan ve İHA'nın ortamda veri varsa eğer, daha fazla keşif yapmasını sağlayan paradigma değişikliğinin ortaya koyduğu başarının kanıtıdır.

4.1.3.2. Senaryo-2: Düşük Miktarlı Veri Toplama Testi

Bu senaryoda 10 tane IoT cihazına 5-20 birim aralığında veriler manuel olarak yüklenmiş İHA'nın enerjisi 150 birim olarak belirlenmiştir. IoT cihazlarının konumu her iki durumda da eşittir. Cihazlardaki veri miktarı şu şekildedir; mavi (blue):20 birim, turuncu (orange):10 birim, yeşil (green):18 birim, kırmızı (red):5 birim, mor (purple):19 birim, kahverengi (Brown):12 birim, pembe (pink):15 birim, gri (gray):14 birim, zeytin yeşili (olive):13 birim, cam göbeği (cyan):12 birimdir.



Şekil 4.6. [14]'teki modele göre eğitilen İHA'nın performansı




Şekil 4.7. Yeni parametreler ile (Rastgele keşif yöntemi algoritması) eğitilmiş İHA'nın performansı


Şekil 4.6'da İHA kırmızı cihaza 5 defa bağlanmaya çalıştığı halde veri almayı başaramamış ve enerjisi yetmediği için diğer köşedeki iniş bölgesine inmiştir. Veri toplama başarısı %96,38'dir. Tüm parametreler eşit tutulup Bölüm 3.2.1'de belirtilen değişikliklerden sonra yeniden eğitilen İHA'nın başarısı Şekil 4.7'de görüldüğü üzere %100 olmuştur. Öte yandan İHA ortamdaki verileri bitirdikten sonra bile geriye enerjisi kalmış ve güvenli bir şekilde kalktığı noktaya iniş yapmıştır.

4.1.3.3. Senaryo-3: Uçuşa Yasak Bölgeden Veri Toplama Testi

Bu senaryoda ise 10 adet IoT cihazına 5-25 birim aralığında toplam 150 birim veri yüklenmiş, cihazlardan biri İHA'nın girmesi yasak olan bölgeye yerleştirilirken bir başka cihaz diğer cihazların bulunduğu bölgeden uzak bir bölgeye yerleştirilmiştir. İHA'nın başlangıç enerjisi 150 birimdir.



Şekil 4.8. Giriş yasak bölge senaryosu ([14]'de sunulan model)



Şekil 4.9. Giriş yasak bölge senaryosu (Rastgele keşif yöntemi ile eğitildikten sonra)

Şekil 4.8'de kahverengi (brown) cihaz giriş yasak bölgede bulunduğu için İHA çok fazla yaklaşmıyor ve bu cihazdan çok az veri toplayabiliyor. Mor (purple) renkli cihaz ise diğerlerinden uzakta bir bölgede olduğu için İHA bu cihazı hiç algılayamıyor ve hiç veri toplayamıyor. Şekil 4.9'da ise kahverengi ve mor renkli cihazların barındırdığı veri miktarı mavi (blue) renkli cihazdan çok daha fazla olduğu için İHA mavi cihazdan az bir veri aldıktan hemen sonra kahverengi ve mor cihazlara bağlanmaya çalışmıştır. Mor cihazdaki verinin tamamını, kahverengi cihazdaki verinin de tamamına yakınına toplayabilmiştir. Fakat 5 birim bulunan mavi cihazdaki verinin çok azını alabilmiştir. Grafik incelendiğinde toplanan toplam verinin miktarı Şekil 4.8'de 120 birim iken Şekil 4.9'de 145 birimdir. Her iki durumda da İHA güvenli bir şekilde iniş bölgesine inmiştir. Toplanan veri miktarı Şekil 4.8'e göre %16,7 artmıştır.

4.1.4. Rastgele Senaryolarla Sistemin Genel Performansının Ölçülmesi

Sistemin konfigürasyon dosyası; 3-10 adet arası rastgele IoT cihazı ve bu cihazlardaki veri miktarı 5.00-20.00 birim ve rastgele olacak şekilde ayarlanmıştır. Cihazların konumu da rastgele olacak şekilde haritaya dağıtılmış ve her senaryoda yine rastgele dağılacak şekilde ayarlanmıştır. İHA'nın enerji miktarı 50-150 birim ve her senaryoda bu değer aralığında yine rastgele olacak şekilde belirlenmiştir.

```
1  {
2    "model_stats_params": {
3      "save_model": "models/manhattan32_dh",
4      "moving_average_length": 200,
5      "log_file_name": "manhattan32_dh",
6      "training_images": false
7    },
8    "grid_params": {
9      "movement_range": [
10       50,
11       150
12     ],
13     "map_path": "res/manhattan32.png",
14     "device_manager": {
15       "device_count_range": [
16         3,
17         10
18       ],
19       "data_range": [
20         5.0,
21         20.0
22       ],
23       "fixed_devices": false
24     }
25   }
```


Şekil 4.10. Sistem Konfigürasyon Parametreleri

Sistem Şekil 4.10'daki ayarlarla 1000 rastgele örnekle çalıştırılmıştır. Elde edilen sonuçlar şöyledir;


Çizelge 4.1. Simülasyon sonuçlarının karşılaştırılması (RIS dahil edilmeden)

	Simülasyon Sonuçları -1 [14]	Simülasyon Sonuçları -2 (Eğitim Sonrası-RIS yok)
Başarılı İniş*	0,983	0,986
Veri Toplama Oranı*	0,831	0,899
Toplam Veri	80242	81890
Toplanan Veri	66055	72534
Harcanan Enerji	83072	85331
Toplanan Veri/Harcanan Enerji	0,795	0,850

* Değerler 0-1 arasına normalize edilmiştir.



Şekil 4.11. Simülasyon sonuçlarının RIS dahil edilmeden önce başarılı iniş ve veri toplama oranı açısından karşılaştırılması



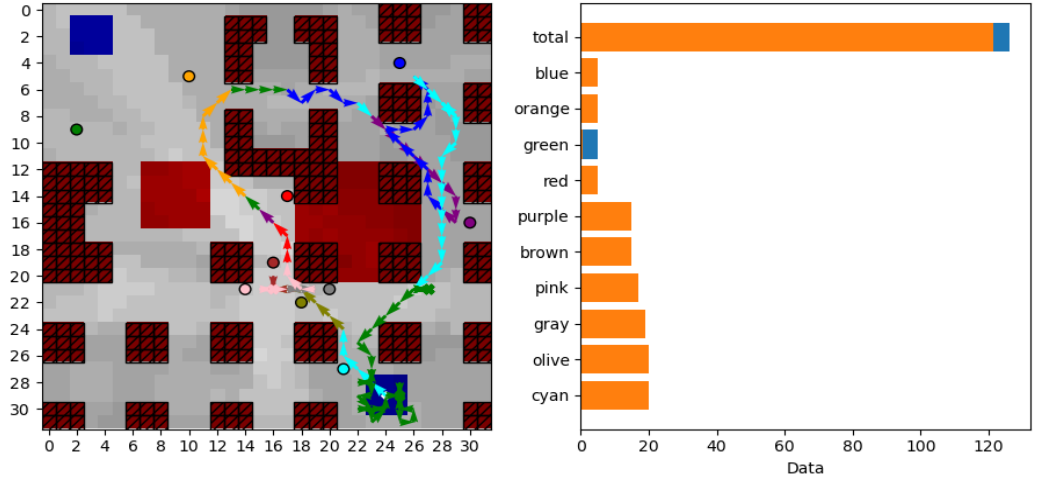
Şekil 4.12. Simülasyon sonuçlarının RIS dahil edilmeden önce birim enerji başına toplanan veri miktarı açısından karşılaştırılması

Grafik sonuçlarına bakıldığında, zaten yüksek bir değere sahip olan “Başarılı İniş” oranındaki küçük artışın yanında asıl odaklanılan “Veri Toplama” oranında %8,18 artış sağlanmıştır. Birim enerji başına toplanan veri miktarındaki artış ise %6,91 oranında olmuştur. Sunulan sonuçlar, Bölüm 3.2.1’de açıklanan metodolojinin, hem veri toplama süreçleri hem de enerji verimliliği açısından İHA'nın başarısına sağladığı katkıları açıkça göstermektedir.

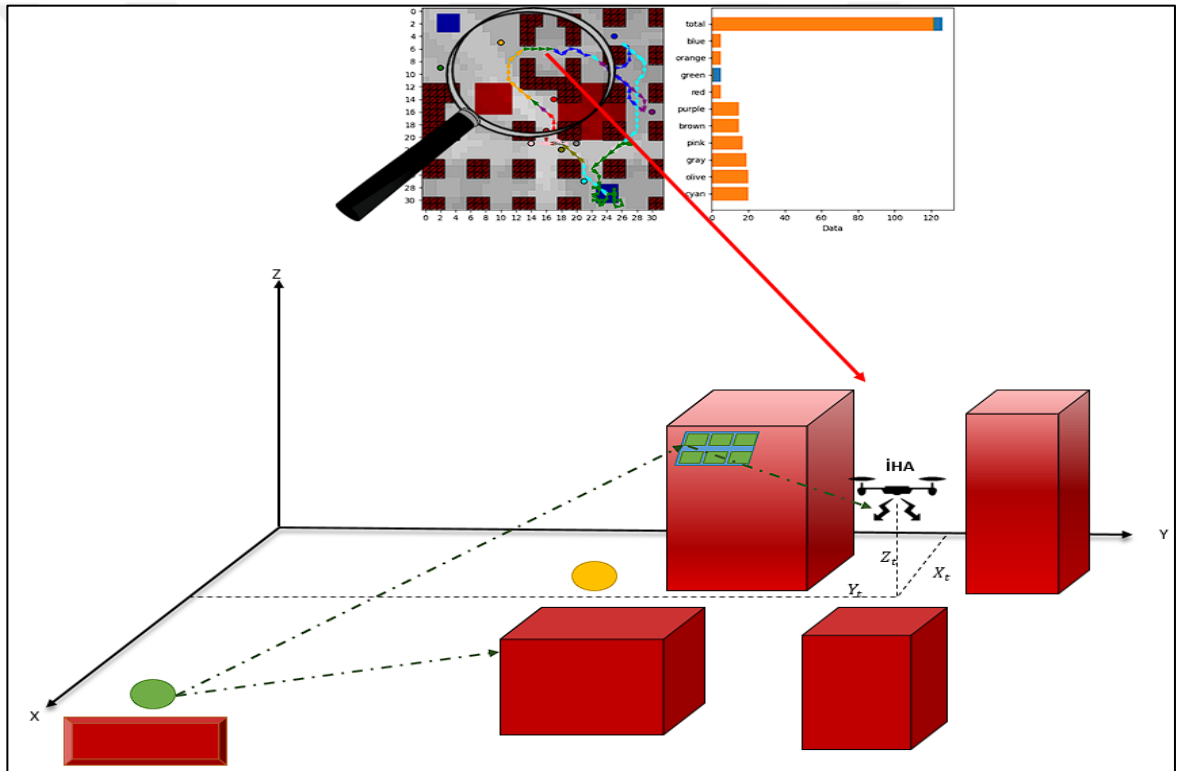
4.2. Aşama-2

4.2.1. Sisteme RIS’in Dahil Edilmesi

Simülasyondaki geliştirmeler sonrasında, Şekil 4.13'te örneği görülen senaryolarda İHA maksimum başarıyı elde edebilmesi için, temsili olarak Şekil 4.14'te gösterildiği üzere, Bölüm 3.2.2’deki metodoloji kullanılarak RIS eklenmiş ve sistem performansının artması sağlanmıştır.



Şekil 4.13. İHA yeşil(green) IoT cihazından veri alamadığı senaryo



Şekil 4.14. İHA'nın veri alamadığı IoT cihazından RIS sayesinde veri alması (Temsili üç boyutlu gösterim)


Çalışma kapsamında, veri toplama miktarını ve enerji verimliliğini artırmak amacıyla sisteme RIS eklenmesi sonrasında, simülasyon rastgele 1000 örnekle tekrar yürütülmüş ve elde edilen sonuçlar Çizelge 4.2, Şekil 4.15 ve Şekil 4.16'te sunulmuştur. Elde edilen sonuçlara dikkatlice bakıldığında, RIS'in sisteme dahil edilmesiyle İHA'nın veri toplama kapasitesinin sırasıyla diğer iki yöntemle göre %10,7 ve %2,33 oranında arttığı, birim enerji

başına toplanan veri miktarının ise diğer iki yöntemle göre sırasıyla %22,64 ve %14,7 oranında arttığı gözlemlenmiştir.


Çizelge 4.2. Simülasyon sonuçlarının karşılaştırılması (RIS dahil edildiğinde)

	Simülasyon Sonuçları -1 [14]	Simülasyon Sonuçları -2 (Eğitim Sonrası- RIS yok)	Simülasyon Sonuçları -3 (Eğitim Sonrası-RIS var)
Başarılı İniş*	0,983	0,986	0,995
Veri Toplama Oranı*	0,831	0,899	0,919
Toplam Veri	80242	81890	83167
Toplanan Veri	66055	72534	75682
Harcanan Enerji	83072	85331	77548
Toplanan Veri/Harcanan Enerji	0,795	0,850	0,975

* Değerler 0-1 arasına normalize edilmiştir.



Şekil 4.15. Simülasyon sonuçlarının “Başarılı İniş” ve “Veri Toplama Oranı” karşılaştırma grafiği



Şekil 4.16. Simülasyon sonuçlarının “Birim Enerji Başına Toplanan Veri Miktarı” bakımından karşılaştırması

5. SONUÇ

Bu çalışma, İnsansız Hava Aracı'nın veri toplama süreçlerini ve enerji verimliliğini artırmak amacıyla sistemimize Akıllı Yansıtıcı Yüzey (RIS) teknolojisinin eklenmesinin etkilerini ayrıntılı bir şekilde değerlendirmiştir. Tez çalışmamız iki aşamadan oluşmaktadır. İlk aşamada, Bayerlein H. ve diğerleri [14]'te sundukları çalışmadaki veri toplama performansını incelediğimizde bazı özel durumlarda verilerin etkin bir şekilde toplanamadığına kanaat getirdik ve bunu nasıl daha iyi hale getirebileceğimiz üzerinde durduk. Bu sorunu çözmek için, İHA'nın hareket kabiliyetini arttırarak veri toplama kapasitesini artırdık. Böylece ortamda veri miktarı görece az olsa bile bu verinin önemli olabileceğini düşünerek Bölüm 3.2.1'deki yöntemle keşif kabiliyetini arttırmış olduk. Yaptığımız bu geliştirmeden sonra İHA'nın veri toplama oranında %8,18 ve birim enerji başına toplayabildiği veri miktarında %6,91 oranında artış sağladık. İkinci aşamada, önceki sunmuş olduğumuz sisteme RIS entegrasyonunu gerçekleştirdik. Simülasyon sonuçları, RIS'in İHA'nın veri toplama kapasitesini %10,7 oranında arttırdığını, aynı zamanda birim enerji başına toplanan veri miktarını %22,64 oranında arttırdığını göstermektedir.

Bu artışlar, RIS'in İHA destekli veri toplama süreçlerindeki verimliliği artırma potansiyelini göstermektedir. İHA'nın enerji verimliliği açısından bu gelişmeler, sürdürülebilir ve uzun ömürlü görevlerin gerçekleştirilmesinde önemli bir adım olabilir.

Bu bağlamda, DDQN gibi güçlü öğrenme algoritmaları, İHA'nın veri toplama süreçlerinde önemli rol oynayabilir. Bu öğrenme yaklaşımını, karmaşık ve dinamik çevrelerde kararlar almak ve dinamik parametrelerle öğrenme sürecini tekrarlamamak adına tercih ettik. İHA'nın veri toplama süreçlerinde DDQN'nin kullanılması, çevresel koşulların değişken olduğu durumlarda, DDQN, İHA'nın çevresini daha etkili bir şekilde anlamasına ve bu değişkenliklere hızlı bir şekilde uyum sağlamasına yardımcı olmuştur. Ayrıca, DDQN'nin öğrenme yetenekleri, İHA'nın karar alma süreçlerini optimize ederek veri toplama kapasitesini artırmasına yardımcı olmuştur.

DDQN'nin kullanımı, özellikle veri toplama süreçlerindeki belirsizliklerle başa çıkma, hata toleransını artırma ve daha akıllı, özerk kararlar alma konularında İHA sistemlerini güçlendirebilir. Bu da sürdürülebilir ve uzun ömürlü görevlerin daha etkili bir şekilde gerçekleştirilmesine olanak tanır. Yani, DDQN gibi derin pekiştirmeli öğrenme algoritmalarının İHA teknolojilerindeki önemi, sistemlerin daha adaptif, güvenilir ve verimli bir şekilde çalışmasına katkı sağlayabilir. DDQN'nin dinamik yapısı sayesinde sistemi ikinci aşamada tekrar eğitmeye gerek kalmadan literatürde kabul gören çalışmalardan elde

ettiğimiz sonuçlarla kıyaslayarak RIS'in enerji verimliliği ve veri toplama performansı üzerindeki başarısını göstermeyi başarabildik.

Gelecekteki çalışmalar, RIS teknolojisinin daha geniş bir uygulama alanında nasıl kullanılabileceği, farklı senaryolarda performansının nasıl değiştiği ve bu teknolojinin diğer hava aracı sistemleri üzerindeki potansiyel etkilerini daha ayrıntılı bir şekilde inceleyebilir. Ayrıca, bu tarz uygulamalarda RIS'in kullanılabilirliği ve uygulanabilirliği konularında daha fazla araştırmaya ihtiyaç bulunmaktadır.

Sonuç olarak, bu çalışma, İHA teknolojisinin verimliliğini artırmak için RIS gibi yenilikçi teknolojilerin başarıyla uygulanabileceğini ve bu tür teknolojik gelişmelerin İHA sistemlerinin gelecekteki evrimine önemli bir katkıda bulunabileceğini göstermektedir.



KAYNAKLAR

- [1] J. Gubbi, R. Buyya, S. Marusic, and M. Palaniswami, "Internet of Things (IoT): A vision, architectural elements, and future directions," *Future Generation Computer Systems*, vol. 29, no. 7, pp. 1645–1660, Sep. 2013, doi: 10.1016/j.future.2013.01.010.
- [2] L. Atzori, A. Iera, and G. Morabito, "The Internet of Things: A survey," *Computer Networks*, vol. 54, no. 15, pp. 2787–2805, Oct. 2010, doi: 10.1016/j.comnet.2010.05.010.
- [3] A. Zanella, N. Bui, A. Castellani, L. Vangelista, and M. Zorzi, "Internet of Things for Smart Cities," *IEEE Internet Things J*, vol. 1, no. 1, pp. 22–32, Feb. 2014, doi: 10.1109/JIOT.2014.2306328.
- [4] M. Mozaffari, W. Saad, M. Bennis, Y.-H. Nam, and M. Debbah, "A Tutorial on UAVs for Wireless Networks: Applications, Challenges, and Open Problems," *IEEE Communications Surveys & Tutorials*, vol. 21, no. 3, pp. 2334–2360, Mar. 2019, doi: 10.1109/COMST.2019.2902862.
- [5] C. Huang, A. Zappone, G. C. Alexandropoulos, M. Debbah, and C. Yuen, "Reconfigurable Intelligent Surfaces for Energy Efficiency in Wireless Communication," *IEEE Trans Wirel Commun*, vol. 18, no. 8, pp. 4157–4170, Aug. 2019, doi: 10.1109/TWC.2019.2922609.
- [6] V. Mnih *et al.*, "Playing Atari with Deep Reinforcement Learning," Dec. 2013, Accessed: Dec. 08, 2022. [Online]. Available: <http://arxiv.org/abs/1312.5602>
- [7] H. Mei, K. Yang, Q. Liu, and K. Wang, "3D-Trajectory and Phase-Shift Design for RIS-Assisted UAV Systems Using Deep Reinforcement Learning," *IEEE Trans Veh Technol*, vol. 71, no. 3, pp. 3020–3029, Mar. 2022, doi: 10.1109/TVT.2022.3143839.
- [8] C. Cao, Z. Lian, Y. Wang, Y. Su, and B. Jin, "A Non-Stationary Geometry-Based Channel Model for IRS-Assisted UAV-MIMO Channels," *IEEE Communications Letters*, vol. 25, no. 12, pp. 3760–3764, Dec. 2021, doi: 10.1109/LCOMM.2021.3116192.
- [9] Z. Lian *et al.*, "A Novel Geometry-Based 3-D Wideband Channel Model and Capacity Analysis for IRS-Assisted UAV Communication Systems," *IEEE Trans Wirel Commun*, vol. 22, no. 8, pp. 5502–5517, Aug. 2023, doi: 10.1109/TWC.2023.3234555.
- [10] F. Wang and X. Zhang, "Active-IRS-Enabled Energy-Efficiency Optimizations for UAV-Based 6G Mobile Wireless Networks," in *2023 57th Annual Conference on Information Sciences and Systems (CISS)*, IEEE, Mar. 2023, pp. 1–6. doi: 10.1109/CISS56502.2023.10089767.

- [11] M. Al-Jarrah, E. Alsusa, A. Al-Dweik, and D. K. C. So, "Capacity Analysis of IRS-Based UAV Communications With Imperfect Phase Compensation," *IEEE Wireless Communications Letters*, vol. 10, no. 7, pp. 1479–1483, Jul. 2021, doi: 10.1109/LWC.2021.3071059.
- [12] Y. M. Park, Y. K. Tun, Z. Han, and C. S. Hong, "Trajectory Optimization and Phase-Shift Design in IRS-Assisted UAV Network for Smart Railway," *IEEE Trans Veh Technol*, vol. 71, no. 10, pp. 11317–11321, Oct. 2022, doi: 10.1109/TVT.2022.3189024.
- [13] A. C. Pogaku, D.-T. Do, B. M. Lee, and N. D. Nguyen, "UAV-Assisted RIS for Future Wireless Communications: A Survey on Optimization and Performance Analysis," *IEEE Access*, vol. 10, pp. 16320–16336, 2022, doi: 10.1109/ACCESS.2022.3149054.
- [14] H. Bayerlein, M. Theile, M. Caccamo, and D. Gesbert, "UAV path planning for wireless data harvesting: A deep reinforcement learning approach," in *GLOBECOM 2020-2020 IEEE Global Communications Conference*, 2020, pp. 1–6.
- [15] O. Ghdiri, W. Jaafar, S. Alfattani, J. Ben Abderrazak, and H. Yanikomeroglu, "Energy-Efficient Multi-UAV Data Collection for IoT Networks with Time Deadlines," in *GLOBECOM 2020 - 2020 IEEE Global Communications Conference*, IEEE, Dec. 2020, pp. 1–6. doi: 10.1109/GLOBECOM42002.2020.9322626.
- [16] S. N. Swamy and S. R. Kota, "An Empirical Study on System Level Aspects of Internet of Things (IoT)," *IEEE Access*, vol. 8, pp. 188082–188134, 2020, doi: 10.1109/ACCESS.2020.3029847.
- [17] E. Al-Masri *et al.*, "Investigating Messaging Protocols for the Internet of Things (IoT)," *IEEE Access*, vol. 8, pp. 94880–94911, 2020, doi: 10.1109/ACCESS.2020.2993363.
- [18] M. E. Kounavis, X. Kang, K. Grewal, M. Eszenyi, S. Gueron, and D. Durham, "Encrypting the internet," *ACM SIGCOMM Computer Communication Review*, vol. 40, no. 4, pp. 135–146, Aug. 2010, doi: 10.1145/1851275.1851200.
- [19] R. Roman, J. Zhou, and J. Lopez, "On the features and challenges of security and privacy in distributed internet of things," *Computer Networks*, vol. 57, no. 10, pp. 2266–2279, Jul. 2013, doi: 10.1016/j.comnet.2012.12.018.
- [20] M. Centenaro, L. Vangelista, A. Zanella, and M. Zorzi, "Long-range communications in unlicensed bands: the rising stars in the IoT and smart city scenarios," *IEEE Wirel Commun*, vol. 23, no. 5, pp. 60–67, Oct. 2016, doi: 10.1109/MWC.2016.7721743.

- [21] O. Vermesan *et al.*, “Internet of things strategic research and innovation agenda,” in *Internet of things*, River Publishers, 2022, pp. 7–151.
- [22] L. A. Baxter, *Markov decision processes: Discrete stochastic dynamic programming*. Taylor & Francis, 1995.
- [23] T. P. Lillicrap *et al.*, “Continuous control with deep reinforcement learning,” *arXiv preprint arXiv:1509.02971*, 2015.
- [24] V. Mnih *et al.*, “Asynchronous methods for deep reinforcement learning,” in *International conference on machine learning*, 2016, pp. 1928–1937.
- [25] M. Bojarski *et al.*, “End to end learning for self-driving cars,” *arXiv preprint arXiv:1604.07316*, 2016.
- [26] S. Levine, P. Pastor, A. Krizhevsky, J. Ibarz, and D. Quillen, “Learning hand-eye coordination for robotic grasping with deep learning and large-scale data collection,” *Int J Rob Res*, vol. 37, no. 4–5, pp. 421–436, 2018.
- [27] D. Silver *et al.*, “Mastering the game of Go with deep neural networks and tree search,” *Nature*, vol. 529, no. 7587, pp. 484–489, 2016.
- [28] J. Schulman, S. Levine, P. Abbeel, M. Jordan, and P. Moritz, “Trust region policy optimization,” in *International conference on machine learning*, 2015, pp. 1889–1897.
- [29] V. Mnih *et al.*, “Human-level control through deep reinforcement learning,” *Nature*, vol. 518, no. 7540, pp. 529–533, 2015.
- [30] C. WATKINS and P. DAYAN, “Q-learning Machine learning. 1992, 8 (3-4),” *doi*, vol. 10, pp. 279–292.
- [31] J. Schulman, F. Wolski, P. Dhariwal, A. Radford, and O. Klimov, “Proximal policy optimization algorithms,” *arXiv preprint arXiv:1707.06347*, 2017.
- [32] A. Y. Ng, D. Harada, and S. Russell, “Policy invariance under reward transformations: Theory and application to reward shaping,” in *Icml*, 1999, pp. 278–287.
- [33] R. S. Sutton and A. G. Barto, “*Reinforcement learning: An introduction.*” MIT press, 2018. Accessed: Oct. 07, 2022. [Online]. Available: <https://t.ly/vjRmb>
- [34] M. G. Bellemare, Y. Naddaf, J. Veness, and M. Bowling, “The arcade learning environment: An evaluation platform for general agents,” *Journal of Artificial Intelligence Research*, vol. 47, pp. 253–279, 2013.

- [35] S. M. Kakade, “A Natural Policy Gradient,” *Advances in Neural Information Processing Systems*. Accessed: Sep. 20, 2022. [Online]. Available: https://proceedings.neurips.cc/paper_files/paper/2001/file/4b86abe48d358ecf194c56c69108433e-Paper.pdf
- [36] D. Silver *et al.*, “A general reinforcement learning algorithm that masters chess, shogi, and Go through self-play,” *Science (1979)*, vol. 362, no. 6419, pp. 1140–1144, 2018.
- [37] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*. MIT press, 2016.
- [38] M. Hessel *et al.*, “Rainbow: Combining improvements in deep reinforcement learning,” in *Proceedings of the AAAI conference on artificial intelligence*, 2018.
- [39] A. H. Zarif, “AoI Minimization in Energy Harvesting and Spectrum Sharing Enabled 6G Networks.” Accessed: Sep. 27, 2022. [Online]. Available: <https://iee-dataport.org/documents/aoi-minimization-energy-harvesting-and-spectrum-sharing-enabled-6g-networks>
- [40] H. Van Hasselt, A. Guez, and D. Silver, “Deep reinforcement learning with double q-learning,” in *Proceedings of the AAAI conference on artificial intelligence*, 2016.
- [41] H. Shakhathreh *et al.*, “Unmanned Aerial Vehicles (UAVs): A Survey on Civil Applications and Key Research Challenges,” *IEEE Access*, vol. 7, pp. 48572–48634, 2019, doi: 10.1109/ACCESS.2019.2909530.
- [42] S. Hayat, E. Yanmaz, and R. Muzaffar, “Survey on Unmanned Aerial Vehicle Networks for Civil Applications: A Communications Viewpoint,” *IEEE Communications Surveys & Tutorials*, vol. 18, no. 4, pp. 2624–2661, Apr. 2016, doi: 10.1109/COMST.2016.2560343.
- [43] O. VİLLİ ve M. YAKAR, “İnsansız Hava Araçlarının Kullanım Alanları ve Sensör Tipleri,” *Türkiye İnsansız Hava Araçları Dergisi*, c. 4, sayı. 2, ss. 73–100, Aralık 2022, doi: 10.51534/tiha.1189263.
- [44] M. Di Renzo *et al.*, “Smart Radio Environments Empowered by Reconfigurable Intelligent Surfaces: How It Works, State of Research, and The Road Ahead,” *IEEE Journal on Selected Areas in Communications*, vol. 38, no. 11, pp. 2450–2525, Nov. 2020, doi: 10.1109/JSAC.2020.3007211.
- [45] R. A. Tasci, F. Kilinc, E. Basar, and G. C. Alexandropoulos, “A New RIS Architecture With a Single Power Amplifier: Energy Efficiency and Error Performance Analysis,” *IEEE Access*, vol. 10, pp. 44804–44815, 2022, doi: 10.1109/ACCESS.2022.3167841.

- [46] Keith Dyer, “What are Reconfigurable Intelligent Surfaces?,” <https://the-mobile-network.com/2021/10/what-are-reconfigurable-intelligent-surfaces/>.
- [47] E. Björnson, Ö. Özdogan, and E. G. Larsson, “Intelligent reflecting surface versus decode-and-forward: How large surfaces are needed to beat relaying?,” *IEEE Wireless Communications Letters*, vol. 9, no. 2, pp. 244–248, 2019.
- [48] Q. Wu and R. Zhang, “Towards Smart and Reconfigurable Environment: Intelligent Reflecting Surface Aided Wireless Network,” *IEEE Communications Magazine*, vol. 58, no. 1, pp. 106–112, Jan. 2020, doi: 10.1109/MCOM.001.1900107.
- [49] J. Yuan, Y.-C. Liang, J. Joung, G. Feng, and E. G. Larsson, “Intelligent Reflecting Surface-Assisted Cognitive Radio System,” Dec. 2019.
- [50] M. Cui, G. Zhang, and R. Zhang, “Secure Wireless Communication via Intelligent Reflecting Surface,” *IEEE Wireless Communications Letters*, vol. 8, no. 5, pp. 1410–1414, Oct. 2019, doi: 10.1109/LWC.2019.2919685.
- [51] H. Nguyen-Kha, H. V. Nguyen, M. T. P. Le, and O.-S. Shin, “Joint UAV Placement and IRS Phase Shift Optimization in Downlink Networks,” *IEEE Access*, vol. 10, pp. 111221–111231, 2022, doi: 10.1109/ACCESS.2022.3214663.
- [52] Q. Pan, J. Wu, X. Zheng, W. Yang, and J. Li, “Differential Privacy and IRS Empowered Intelligent Energy Harvesting for 6G Internet of Things,” *IEEE Internet Things J*, vol. 9, no. 22, pp. 22109–22122, Nov. 2022, doi: 10.1109/JIOT.2021.3104833.
- [53] K. Tekbıyık, G. K. Kurt, A. R. Ekti, and H. Yanikomeroglu, “Reconfigurable Intelligent Surfaces in Action for Non-Terrestrial Networks,” Dec. 2020, doi: 10.1109/MVT.2022.3168995.
- [54] M.-M. Zhao, Q. Wu, M.-J. Zhao, and R. Zhang, “Intelligent Reflecting Surface Enhanced Wireless Networks: Two-Timescale Beamforming Optimization,” *IEEE Trans Wirel Commun*, vol. 20, no. 1, pp. 2–17, Jan. 2021, doi: 10.1109/TWC.2020.3022297.
- [55] O. Esrafilian, R. Gangula, and D. Gesbert, “Learning to communicate in UAV-aided wireless networks: Map-based approaches,” *IEEE Internet Things J*, vol. 6, no. 2, pp. 1791–1802, 2018.
- [56] S. Zhang and R. S. Sutton, “A deeper look at experience replay,” *arXiv preprint arXiv:1712.01275*, 2017.
- [57] Y. Yao, K. Lv, N. Ma, X. Yue, X. Qin, and X. Yun, “Energy efficient air-to-ground communication networks with reconfigurable intelligent surface,” *Journal of*

Communications and Networks, vol. 24, no. 5, pp. 555–565, Aug. 2022, doi: 10.23919/jcn.2022.000025.

- [58] A. Mondal, A. M. H. Al Junaedi, K. Singh, and S. Biswas, “Spectrum and Energy-Efficiency Maximization in RIS-Aided IoT Networks,” *IEEE Access*, vol. 10, pp. 103538–103551, 2022, doi: 10.1109/ACCESS.2022.3209823.
- [59] A. Al-Hilo, M. Samir, M. Elhatab, C. Assi, and S. Sharafeddine, “RIS-Assisted UAV for Timely Data Collection in IoT Networks,” Mar. 2021, Accessed: Nov. 11, 2022. [Online]. Available: <http://arxiv.org/abs/2103.17162>

