



**OTONOM HAVA KARGO ARAÇLARININ DERİN
ÖĞRENME YÖNTEMLERİYLE LOJİSTİK
PLANLAMASI**

Muhammed Sefa GÖR

Danışman: Prof. Dr. Cafer ÇELİK

Doktora Tezi

Endüstri Mühendisliği Ana Bilim Dalı

2026

(Her hakkı saklıdır.)

T.C.
ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANA BİLİM DALI

**OTONOM HAVA KARGO ARAÇLARININ DERİN ÖĞRENME YÖNTEMLERİYLE
LOJİSTİK PLANLAMASI**

(Logistics Planning with Deep Learning Methods of Autonomous Air Cargo Vehicles)

DOKTORA TEZİ

Muhammed Sefa GÖR

Danışman: Prof. Dr. Cafer ÇELİK

Erzurum

Şubat, 2026

KABUL VE ONAY TUTANAĞI

Muhammed Sefa GÖR tarafından hazırlanan “**OTONOM HAVA KARGO ARAÇLARININ DERİN ÖĞRENME YÖNTEMLERİYLE LOJİSTİK PLANLAMASI**” başlıklı çalışması 18/02/2026 tarihinde yapılan tez savunma sınavı sonucunda başarılı bulunarak jürimiz tarafından Endüstri Mühendisliği Ana Bilim Dalı, Endüstri Mühendisliği Bilim Dalında Doktora tezi olarak kabul edilmiştir.

Jüri Başkanı:	Prof. Dr. Mustafa YILMAZ <i>Atatürk Üniversitesi</i>	
Danışman:	Prof. Dr. Cafer ÇELİK <i>Atatürk Üniversitesi</i>	
Jüri Üyesi:	Dr. Öğr. Üyesi Sinan ÖZTAŞ <i>Atatürk Üniversitesi</i>	
Jüri Üyesi:	Dr. Öğr. Üyesi Şeyma EMEÇ <i>Erzurum Teknik Üniversitesi</i>	
Jüri Üyesi:	Dr. Öğr. Üyesi Ferhat YUNA <i>Erzurum Teknik Üniversitesi</i>	

Bu tezin Atatürk Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili maddelerinde belirtilen şartları yerine getirdiğini onaylarım.

Prof. Dr. Alper NUHOĞLU

Enstitü Müdürü

Bu çalışma Bilimsel Araştırma Projeleri kapsamında desteklenmiştir.

Proje No: FDK-2023-13049

Not: Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildiriş, çizelge, şekil ve fotoğrafların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU

Doktora Tezi olarak Prof. Dr. Cafer ÇELİK danışmanlığında sunulan “**Otonom Hava Kargo Araçlarının Derin Öğrenme Yöntemleriyle Lojistik Planlaması**” başlıklı çalışmanın tarafımızdan bilimsel etik ilkelere uyularak yazıldığını, yararlanılan eserlerin kaynakçada gösterildiğini, Fen Bilimleri Enstitüsü tarafından belirlenmiş olan Turnitin Programı benzerlik oranlarının aşılmadığını ve aşağıdaki oranlarda olduğunu beyan ederiz.

Tez Bölümleri	Tezin Benzerlik Oranı (%)	Maksimum Oran (%)
Giriş	0	30
Kuramsal Temeller	2	30
Materyal ve Metot	1	35
Araştırma Bulguları ve Tartışma	2	20
Sonuçlar	0	20
Tezin Geneli	2	25

***Not:** Yedi kelimeye kadar benzerlikler ile Başlık, Kaynakça, İçindekiler, Teşekkür, Dizin ve Ekler kısımları tarama dışı bırakılabilir. Yukarıdaki azami benzerlik oranları yanında tek bir kaynaktan olan benzerlik oranlarının %5'den büyük olmaması gerekir.*

Beyan edilen bilgilerin doğru olduğunu, aksi halde doğacak hukuki sorumlulukları kabul ve beyan ederiz.

Tez Yazarı (Öğrenci)	Tez Danışmanı
Muhammed Sefa GÖR	Prof. Dr. Cafer ÇELİK
18.2.2026	18.2.2026
İmza:	İmza:

* Tez ile ilgili YÖKTEZ’de yayınlamasına ilişkin bir engelleme var ise aşağıdaki alanı doldurunuz.

☐ Tezle ilgili patent başvurusu yapılması / patent alma sürecinin devam etmesi sebebiyle Enstitü Yönetim Kurulunun/...../.... tarih ve sayılı kararı ile teze erişim 2 (iki) yıl süreyle engellenmiştir.

☐ Enstitü Yönetim Kurulunun/...../.... tarih ve sayılı kararı ile teze erişim 6 (altı) ay süreyle engellenmiştir.

TEŞEKKÜR

Doktora tezimin hazırlanması sürecinde rehberliğini, tecrübelerini ve manevi desteğini esirgemeyen danışmanım Prof. Dr. Cafer ÇELİK'e, sürecin her aşamasında bana yol gösteren fikirleri ve bilgi birikimi ile bu çalışmanın şekillenmesine sağladığı katkılar için sonsuz teşekkürlerimi sunarım.

Değerli görüşleriyle bana destek olan tez izleme komitesi üyeleri Prof. Dr. Mustafa YILMAZ ve Dr. Öğr. Üyesi Faruk Baturalp GÜNAY'a da sürece olan katkılarından dolayı teşekkür ederim.

Bu araştırmanın gerçekleştirilmesinde sağladıkları finansal desteklerle çalışmanın kapsamını genişleten Atatürk Üniversitesi BAP Koordinatörlüğü'ne (FDK-2023-13049) teşekkürlerimi sunarım.

Bugünlere gelmende çok emeği olan, bu süreçte ve öncesinde her zaman dualarıyla, sevgileriyle ve özveriyle yanımda olan kıymetli babam Dursun GÖR'e, her türlü fedakarlığı sağlayan canım annem Semahat GÖR'e, birbirinden değerli kardeşlerim Meryem Kübra GÖR ÜLKER'e, Ahmet Berat GÖR'e ve Demet GÖR'e en içten duygularım ile teşekkürlerimi sunarım.

Bu akademik yolculukta zor zamanlarda her zaman yanımda olarak beni motive eden, başaracağıma dair inancını hep diri tutup bana hissettiren, ayrıca gösterdiği sonsuz anlayış, sabır ve destek için sevgili eşim Betül AYDIN GÖR'e ve varlığıyla mucizeler yaşadığım, ilham kaynağım kızım İnci Lina GÖR'e teşekkür ederim.

Çalışmamı eşim Betül AYDIN GÖR ve kızım İnci Lina GÖR'e ithaf ederim.

Muhammed Sefa GÖR

ÖZET

DOKTORA TEZİ

OTONOM HAVA KARGO ARAÇLARININ DERİN ÖĞRENME YÖNTEMLERİYLE LOJİSTİK PLANLAMASI

Muhammed Sefa GÖR

Danışman: Prof. Dr. Cafer ÇELİK

Amaç: Bu çalışma, otonom hava kargo araçlarının (OHKA) derin öğrenme tabanlı lojistik planlama süreçlerine entegrasyonunu kapsamlı bir şekilde ele alarak, beş farklı performans karakteristiği üzerinden çok boyutlu ve bütüncül bir değerlendirme yapmayı amaçlamaktadır. Araştırmanın temel amacı ise, OHKA sistemlerinde derin öğrenme algoritmalarını kullanarak karar destek, rota optimizasyonu ve kaynak tahsisi gibi kritik süreçlerin otonom olarak yönetilmesini sağlayan entegre bir yapay zekâ modeli geliştirmektir.

Yöntem: Yedi kontrol faktörü ile bu faktörler arasındaki altı adet bileşik etkiyi incelemek amacıyla Taguchi'nin L54 ortogonal dizisi deney planı olarak seçilmiş; elde edilen deneysel veriler, beş performans karakteristiğinin bireysel ve eşzamanlı olarak optimize edilmesinde kullanılmıştır. Buna ek olarak, VRP/TSP temelli karayolu filosu ve çoklu OHKA rota optimizasyonu, süreç yeterliliği ve OEE analizleri, MTBF–MTTR ve Weibull güvenilirlik çözümleri, FTA–ETA tabanlı risk analizi, CNN–LSTM–GRU temelli derin öğrenme modelleri ile NŞD, iç verim oranı, TCO ve SROI göstergelerini içeren ekonomik değerlendirmeler yürütülmektedir.

Bulgular: Uygulama sonucunda, optimum faktör kombinasyonlarında yaklaşık 29,7 dakikalık teslimat süresi, %95,1 görev başarı oranı ve 122,9 TL düzeyinde operasyonel maliyet elde edilmiştir. Süreç yeterliliği analizlerinde batarya sıcaklığı ve paket titreşimi gibi kritik kalite karakteristikleri için σ -ST=4,266 σ – 4,635 σ ve σ -LT=5,766 σ – 6,135 σ aralığında yüksek süreç seviyelerine ulaşılmış; teslimat süresi ve konumsal/iniş parametreleri için ise σ -ST=2,853 σ – 3,258 σ ve σ -LT=4,353 σ – 4,758 σ aralığında süreç seviyeleri elde edilmiştir. OEE %80,2, kullanılabilirlik %99,6–%99,7 aralığında gerçekleşmiştir. Ekonomik analizler, 89,2 milyon TL NŞD, %133 iç getiri oranı, 0,9 yıl geri ödeme süresi ve karayolu filosuna kıyasla yaklaşık %28 daha düşük TCO ile OHKA'ların birçok alanda daha avantajlı olduğunu göstermiştir.

Sonuç: Çalışma, OHKA'ların derin öğrenme tabanlı planlama algoritmalarıyla bütünleştiğinde lojistik alanında teknik olarak uygulanabilir, ekonomik açıdan üstün ve çevresel anlamda daha sürdürülebilir olduğunu ortaya koymaktadır.

Anahtar Kelimeler: Otonom Hava Kargo Araçları, Derin Öğrenme, Lojistik Planlama, Taguchi Deney Tasarımı, Yapay Zekâ

Şubat 2026, 202 sayfa

ABSTRACT

DOCTORAL DISSERTATION

LOGISTICS PLANNING WITH DEEP LEARNING METHODS OF AUTONOMOUS AIR CARGO VEHICLES

Muhammed Sefa GÖR

Supervisor: Prof. Dr. Cafer ÇELİK

Purpose: This study aims to comprehensively investigate the integration of autonomous air cargo vehicles (AACVs) into deep learning-based logistics planning processes and to provide a multidimensional and holistic evaluation across five key performance characteristics. The primary objective is to develop an integrated artificial intelligence model that enables autonomous management of critical processes such as decision support, route optimization and resource allocation in AACV systems through deep learning algorithms.

Method: To examine seven control factors and six interaction effects among these factors, Taguchi's L54 orthogonal array was selected as the experimental design, and the resulting experimental data were used to optimize five performance characteristics both individually and simultaneously. In addition, VRP/TSP-based road-fleet and multi-OHKA route optimization, process capability and OEE analyses, MTBF–MTTR and Weibull reliability solutions, FTA–ETA-based risk analysis, CNN–LSTM–GRU-based deep learning models, and economic evaluations including NPV, internal rate of return, TCO, and SROI indicators are being conducted.

Findings: As a result of the implementation, under the optimum factor combinations, an approximately 29.7-minute delivery time, a 95.1% mission success rate, and an operational cost of TRY 122.9 were achieved. In the process capability analyses, high process levels were attained for critical quality characteristics such as battery temperature and package vibration, within the ranges of σ -ST = $4.266\sigma - 4.635\sigma$ and σ -LT = $5.766\sigma - 6.135\sigma$; for delivery time and positional/landing parameters, process levels were obtained within the ranges of σ -ST = $2.853\sigma - 3.258\sigma$ and σ -LT = $4.353\sigma - 4.758\sigma$. The OEE was 80.2%, while availability ranged between 99.6% and 99.7%. Economic analyses indicated that OHKAs are more advantageous in many respects, with an NPV of TRY 89.2 million, an internal rate of return of 133%, a 0.9-year payback period, and an approximately 28% lower TCO compared to a road-based fleet.

Results: The study reveals that, when integrated with deep learning-based planning algorithms, AACVs constitute a technically feasible, economically superior and environmentally more sustainable alternative for logistics operations.

Keywords: Autonomous Air Cargo Vehicles, Deep Learning, Logistics Planning, Taguchi Experimental Design, Artificial Intelligence

February 2026, 202 pages

İÇİNDEKİLER

KABUL VE ONAY TUTANAĞI.....	i
ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU	ii
TEŞEKKÜR	iii
ÖZET	iv
ABSTRACT	v
İÇİNDEKİLER.....	vi
TABLolar DİZİNİ.....	ix
ŞEKİLLER DİZİNİ	x
KISALTMALAR VE SİMGELER DİZİNİ.....	xiv
GİRİŞ.....	1
KURAMSAL TEMELLER.....	4
Otonom Hava Kargo Araçları ve Drone Teknolojileri	4
Drone teknolojilerinin tarihçesi ve gelişimi	5
Drone tipleri ve kullanım alanları	6
Drone dinamiği ve uçuş kontrol sistemleri	7
Lojistik ve Tedarik Zinciri Yönetiminde Yapay Zekâ Uygulamaları.....	8
Yapay zekânın lojistik sektöründeki genel uygulamaları	8
Yapay zekânın tedarik zinciri yönetiminde kullanımı	9
Otonom sistemlerin lojistik sektörüne entegrasyonu	11
Derin Öğrenme Tekniklerinin Lojistik ve Drone Yönetimi Alanında Kullanımı.....	11
Derin öğrenme yöntemlerinin temel prensipleri	11
Drone ve lojistik alanında derin öğrenme yöntemleri ile yapılan araştırmalar.....	15
Derin öğrenme yöntemlerinin avantaj ve kısıtlamaları.....	15
Drone Rota Optimizasyonu için Kullanılan Algoritmalar ve Yöntemler	16
Geleneksel rota optimizasyonu yöntemleri.....	16
Yapay zekâ ve optimizasyon temelli rota planlama teknikleri	16
Enerji Yönetimi ve Verimlilik Artırma Yöntemleri.....	18
Drone sistemlerinde enerji yönetiminin önemi	18
Pil yönetimi ve enerji optimizasyon yöntemleri	18
Yapay zekâ destekli enerji yönetim stratejileri	18
Enerji yönetimi ve performans değerlendirme metrikleri.....	19
Hava Durumu Tahmini ve Drone Operasyonları Üzerindeki Etkileri	19
Meteorolojik veri analizi ve hava durumu tahmin teknikleri.....	19

Drone operasyonlarında hava durumunun etkisi	20
Yapay zekâ tabanlı hava durumu tahmin modelleri.....	20
Çoklu Drone Koordinasyonu ve Operasyonel Zorluklar	21
Çoklu drone sistemlerinde koordinasyon ve iş birliği	21
Kooperatif aktif yerleştirme ve çoklu sensör veri füzyonu	22
Çarpışma önleme algoritmaları ve güvenlik mekanizmaları	22
Operasyonel zorluklar ve çözüm yaklaşımları	23
Literatürde Öne Çıkan Çalışmaların Karşılaştırmalı Analizi.....	24
Literatürdeki önemli çalışmaların yöntem ve bulgularının değerlendirilmesi.....	24
Bu çalışmanın literatüre beklenen katkıları ve yenilikleri	24
MATERYAL ve METOT	31
Araştırma Tasarımı.....	32
Sistem yaklaşımı ve modüler mimari.....	34
Karma araştırma yöntemi ve senaryo bazlı analiz	39
Kullanılan Materyaller	40
Donanım altyapısı	41
Veri kaynakları.....	47
Yazılım altyapısı	52
Biyometrik doğrulama sistemleri.....	58
Veri Ön İşleme ve Özellik Çıkarımı Yöntemleri	59
Veri temizliği ve gürültü azaltma.....	60
Özellik ölçeklendirme ve normalizasyon teknikleri	61
Zaman serisi verilerinde özellik çıkarımı.....	63
Drone telemetri verilerinden özelliklerin belirlenmesi ve seçimi	67
DL Modellerinin Tasarımı ve Uygulanması	68
Kullanılan DL teknikleri	69
Model eğitim ve hiperparametre optimizasyonu.....	79
Modüler sistem entegrasyonu ve operasyonel akış	85
Deney Tasarım ve Performans Analiz Yöntemleri.....	86
Taguchi L54 deney planı.....	88
OEE, DR, sigma seviyesi ve PCI analizleri	92
İstatistiksel analizler.....	92
ARAŞTIRMA BULGULARI VE TARTIŞMA.....	94
Deney Tasarım ve Optimizasyon Analizleri.....	94
Rota Optimizasyon Analizleri.....	111

Performans Analizleri ve Kalite Yönetimi.....	117
Güvenilirlik ve Risk Analizleri	123
Derin Öğrenme, Makine Öğrenmesi ve Yapay Zekâ Analizleri.....	128
Ekonomik Analizler	147
OHKA Sistem Takip ve Simülasyon Ekranı.....	150
SONUÇLAR VE ÖNERİLER	156
KAYNAKLAR.....	161
EKLER	170
EK-1. Modül 1'in 1. parçası.....	170
EK-2. Modül 1'in 2.parçası.....	171
EK-3. Modül 2'nin 1.parçası.....	172
EK-4. Modül 2'nin 2.parçası.....	173
EK-5. Modül 3'ün 1.parçası.....	174
EK-6. Modül 3'ün 2. Parçası.....	175
EK-7. Modül 4'ün 1.parçası.....	176
EK-8. Modül 4'ün 2.parçası.....	177
EK-9. Modül 5'in 1.parçası.....	178
EK-10. Modül 5'in 2.parçası.....	179
EK-11. Modül 5'in 3.parçası.....	180
EK-12. Ana Modül'ün 1.parçası	181
EK-13. Ana Modül'ün 2.parçası	182
ÖZGEÇMİŞ.....	183

TABLÖLAR DİZİNİ

Tablo 1. Taranan Literatürde Kullanılan DL Yöntemleri	25
Tablo 2. Lojistik Açından Taranan Çalışmaların Tematik Konulara Göre Sınıflandırılması	27
Tablo 3. Drone Tipleri Temel Özellikleri ve Kullanım Alanları	42
Tablo 4. Kullanılan DL Çerçeveleri	56
Tablo 5. Özellik Türleri ve Kullanım Alanları	66
Tablo 6. Kullanım Alanlarına Göre DL Teknikleri	70
Tablo 7. Öne Çıkan CNN Mimarilerinin Özellikleri ve Kullanım Alanları	71
Tablo 8. LSTM ve GRU Teknik Özellikler ve Model Karşılaştırması	73
Tablo 9. GNN Mimarileri ve Teknik Özellikler	74
Tablo 10. DQN, DDPG ve PPO Karşılaştırma Tablosu	77
Tablo 11. Kullanılan GAN Mimarileri ve Kullanım Alanları	78
Tablo 12. Izgara Arama ve Rastgele Arama Karşılaştırma Tablosu	81
Tablo 13. Bayesyen Optimizasyon, Izgara Arama ve Rastgele Arama Karşılaştırma Tablosu	82
Tablo 14. Kullanılan Erken Durdurma ve Düzenleştirme Teknikleri	83
Tablo 15. Deneylerde İncelenecek Parametreler, Seviyeleri ve Aralıkları	88
Tablo 16. Taguchi L54 Deney Planı	89
Tablo 17. Teslimat Süresi Ham Verileri Üzerine Yapılan Varyans Analizi Tablosu	95
Tablo 18. Teslimat Süresi S/N Verileri Üzerine Yapılan Varyans Analizi Tablosu	95
Tablo 19. Operasyonel Maliyet Ham Verileri Üzerine Yapılan Varyans Analizi Tablosu	97
Tablo 20. Operasyonel Maliyet S/N Verileri Üzerine Yapılan Varyans Analizi Tablosu	97
Tablo 21. Görev Başarı Oranı Ham Verileri Üzerine Yapılan Varyans Analizi Tablosu	99
Tablo 22. Görev Başarı Oranı S/N Verileri Üzerine Yapılan Varyans Analizi Tablosu	99
Tablo 23. Enerji Tüketimi Ham Verileri Üzerine Yapılan Varyans Analizi Tablosu	101
Tablo 24. Enerji Tüketimi S/N Verileri Üzerine Yapılan Varyans Analizi Tablosu	101
Tablo 25. Karbon Ayak İzi Ham Verileri Üzerine Yapılan Varyans Analizi Tablosu	103
Tablo 26. Karbon Ayak İzi S/N Verileri Üzerine Yapılan Varyans Analizi Tablosu	103
Tablo 27. Etkin Olan Parametrelerin ve Bileşik Etkilerin Katkı Yüzdeleri ile Optimum Çalışma Şartları	105

ŞEKİLLER DİZİNİ

Şekil 1. Taranan literatürde bulunan konuların sayısı.	4
Şekil 2. DL teknikleri.	12
Şekil 3. Modül 1'in parçalanmış gösterimi.	35
Şekil 4. Modül 2'nin parçalanmış gösterimi.	35
Şekil 5. Modül 3'in parçalanmış gösterimi.	36
Şekil 6. Modül 4'ün parçalanmış gösterimi.	37
Şekil 7. Modül 5'in parçalanmış gösterimi.	37
Şekil 8. Ana Modül'ün parçalanmış gösterimi.	38
Şekil 9. Model geliştirme süreci.	54
Şekil 10. Bayesyen optimizasyon süreci.	81
Şekil 11. Teslimat süresi ham veri grafikleri; (a) asıl etki grafikleri, (b) bileşik etki grafikleri. Teslimat süresi S/N grafikleri; (c) asıl etki grafikleri, (d) bileşik etki grafikleri.	96
Şekil 12. Operasyonel maliyet ham veri grafikleri; (a) asıl etki grafikleri, (b) bileşik etki grafikleri. Operasyonel maliyet S/N grafikleri; (c) asıl etki grafikleri, (d) bileşik etki grafikleri.	98
Şekil 13. Görev başarı oranı ham veri grafikleri; (a) asıl etki grafikleri, (b) bileşik etki grafikleri. Görev başarı oranı S/N grafikleri; (c) asıl etki grafikleri, (d) bileşik etki grafikleri.	100
Şekil 14. Enerji tüketimi ham veri grafikleri; (a) asıl etki grafikleri, (b) bileşik etki grafikleri. Enerji tüketimi S/N grafikleri; (c) asıl etki grafikleri, (d) bileşik etki grafikleri.	102
Şekil 15. Karbon ayak izi ham veri grafikleri; (a) asıl etki grafikleri, (b) bileşik etki grafikleri. Karbon ayak izi S/N grafikleri; (c) asıl etki grafikleri, (d) bileşik etki grafikleri.	104
Şekil 16. Pareto frontu analizi ve ikili hedef optimizasyonu sonuçları; (a) teslimat süresi - görev başarı oranı grafiği, (b) operasyonel maliyet - görev başarı oranı grafiği, (c) enerji tüketimi – görev başarı oranı grafiği ve (d) karbon ayak izi – görev başarı oranı grafiği.	106
Şekil 17. OHKA performans optimizasyon uzayı.	107
Şekil 18. OHKA performans analizi; (a) MCDM kriter ağırlıkları, (b) TOPSİS skor dağılımı, (c) günlük enerji-karbon performans döngüsü ve (d) en iyi ve en kötü senaryolar için normalize karar matrisi.	108
Şekil 19. RSM model analizi ve değerlendirmesi; (a) model R^2 karşılaştırması, (b) artık grafiği ve (c) normal Q-Q grafiği.	109

Şekil 20. RSM model görselleştirme ve yanıt yüzeyi analizi; (a) toplam standardize model etkileri, (b) operasyonel maliyette $D \times F$ bileşik etkisine ait yanıt yüzeyi, (c) enerji tüketimindeki $D \times E$ bileşik etkisine ait yanıt yüzeyi ve (d) görev başarı oranındaki $D \times G$ bileşik etkisine ait yanıt yüzeyi.	110
Şekil 21. Araç rotalama problemi; (a) araç kapasite kullanımı, (b) araç mesafe karşılaştırması, (c) talep dağıtım ısı haritası, (d) araç verimlilik metrikleri ve (e) CVRP araç rotaları.....	111
Şekil 22. Gezgin satıcı problemi; (a) TSP çözümü en kısa rota ve (b) ilçeler arası uzaklık matrisi.	112
Şekil 23. OHKA rota problemi; (a) OHKA rotaları, (b) OHKA performans metrikleri, (c) OHKA kapasite kullanımı ve (d) OHKA teslimat dağılımı.....	113
Şekil 24. Operasyonel analizler; (a) ilçe bazlı performans dağılımı, (b) haftalık teslimat trendi, (c) 24 saatlik talep dağılımı ve (d) haftalık talep yoğunluğu haritası.	115
Şekil 25. Teknik analizler; (a) risk matrisi analizi, (b) batarya sağlık göstergesi, (c) drone bakım takvimi ve periyotları ve (d) motor ve sistem performans metrikleri.....	116
Şekil 26. Süreç seviyesi; (a) batarya sıcaklığı, (b) teslimat süresi, (c) GPS doğruluğu, (d) iniş hassasiyeti, (e) paket titreşimi ve (f) dağılım analizi.....	118
Şekil 27. Kontrol grafiği analizleri; (a) hata oranı, (b) verim yüzdesi trendi, (c) X bar grafiği ve (d) R grafiği.	119
Şekil 28. OEE analizleri; (a) süreç kapasitesi ve darboğaz analizi, (b) duruş türleri dağılımı, (c) OEE trendi ve bileşenleri ve (d) OEE waterfall (şelale) analizi-kayıp kaynaklar.....	121
Şekil 29. Performans entegre analizleri; (a) DPMO trendi, (b) ilçe bazında hata dağılımı, (c) hata tipleri pareto analizi ve (d) 30 günlük performans trendi ve projeksiyonları.....	122
Şekil 30. MTBF-MTTR analizleri; (a) OHKA filosu MTBF analizi, (b) OHKA filosu MTTR analizi, (c) OHKA filosu kullanılabilirlik analizi ve (d) aylık arıza trend analizi.	123
Şekil 31. Güvenilirlik fonksiyonu ve hayatta kalma analizi; (a) OHKA filosu güvenilirlik fonksiyonu, (b) arıza oranı analizi, (c) weibull olasılık grafiği ve (d) hayatta kalma eğrisi.	125
Şekil 32. FMEA ve risk değerlendirme analizi; (a) tespit yeteneği ve şiddet analizi, (b) RPN pareto analizi, (c) risk matrisi – FMEA ve (d) sistem bazlı risk analizi.	126
Şekil 33. FTA ve ETA analizi; (a) FTA OHKA teslimat başarısızlığı, (b) temel olay kritik analizi, (c) ETA sonuç dağılımı ve (d) entegre risk değerlendirme matrisi.....	127
Şekil 34. Giresun ilçeleri drone operasyon risk haritası.....	128

Şekil 35. Güvenli iniş ve trafik analizi; (a) mesafe-süre ilişkisi, (b) mesafe-enerji tüketimi, (c) güvenli iniş noktaları ve (d) günlük hava trafik yoğunluğu.	129
Şekil 36. Q-öğrenme analizi sonuçları; (a) Q-öğrenme eğitim süreci ve (b) en sık kullanılan başarılı rotalar.	130
Şekil 37. OHKA telemetri verisi analizi; (a) hız – batarya ilişkisi, (b) motor RPM dağılımı, (c) yük ağırlığına göre batarya performansı ve (d) örnek uçuş profili.	131
Şekil 38. CNN performans analizleri; (a) model kayıp değişimi, (b) model doğruluk oranı, (c) karmaşıklık matrisi, (d) ROC eğrisi, (e) öğrenme hızı analizi ve (f) tahmin güven dağılımı.	133
Şekil 39. Çarpışma önleme sistemi; (a) 3D OHKA yolları ve çarpışma önleme, (b) yan görünüm XZ düzlemi, (c) üstten görünüm XY düzlemi, (d) yan görünüm YZ düzlemi, (e) mesafe matrisi ve (f) yükseklik kullanım dağılımı.	135
Şekil 40. LSTM ve GRU model performans karşılaştırması; (a) model eğitim kayıpları ve (b) batarya seviyesi tahminleri.	136
Şekil 41. Yüksek frekans sensör verisi ve titreşim analizleri; (a) 3 eksen titreşim verileri, (b) titreşim frekans spektrumu, (c) titreşim anomali tespiti, (d) motor sıcaklığı – titreşim ilişkisi, (e) hareketli ortalama ve (f) titreşim istatistikleri.	137
Şekil 42. Sensör füzyonu ve durum kestirimi analizi; (a) sensör korelasyon matrisi, (b) kalman filtresi ve irtifa tahmini, (c) IMU tabanlı yönelim tahmini ve (d) sensör güvenilirlik analizi.	139
Şekil 43. Arıza tahmini ve önleyici bakım analizi; (a) arıza belirtileri özeti, (b) bathtub eğrisi – arıza olasılığı, (c) önleyici bakım takvimi ve (d) bakım stratejileri maliyet karşılaştırması.	140
Şekil 44. Sensör anomali analizi; (a) yeniden yapılandırma hatası dağılımı, (b) zaman serisi anomali tespiti, (c) 3D PCA uzayında anomaliler ve (d) DBSCAN kümeleme ile anomali tespiti.	140
Şekil 45. Meteorolojik ve çevresel faktörlerin analizi; (a) mevsimsel sıcaklık dağılımı, (b) basınç-sıcaklık ilişkisi, (c) görüş mesafesi dağılımı ve (d) nem – yağış ilişkisi. ..	142
Şekil 46. İniş bölgeleri; (a) iniş alanları risk dağılımı, (b) yüzey malzemesine göre güvenlik, (c) alan büyüklüğü – güvenlik skoru ve (d) Giresun ili ve ilçeleri iniş bölgeleri. ..	143
Şekil 47. Kargo analizleri – 1; (a) kargo ağırlık dağılımı, (b) kargo boyut dağılımı, (c) ağırlık merkezi – stabilite ilişkisi ve (d) farklı yükleme senaryolarında stabilite.	144
Şekil 48. Kargo analizleri – 2; (a) kargo hassasiyet matrisi, (b) OHKA yük alanı ağırlık dağılımı, (c) kargo tipi dağılımı ve (d) yükleme stratejisi performans karşılaştırması.	145

Şekil 49. Transfer öğrenme; (a) transfer öğrenme model karşılaştırması, (b) çok sınıflı ROC eğrileri, (c) öğrenme hızı programlama stratejileri ve (d) öz-dikkat ağırlık haritası.	146
Şekil 50. NŞD, iç getiri oranı ve geri ödeme periyodu analizi; (a) NŞD duyarlılık analizi, (b) yıllık ve kümülatif nakit akışları, (c) geri ödeme periyodu analizi ve (d) finansal performans özeti.	147
Şekil 51. Sosyal yatırım getirisi (SROI); (a) SROI bileşenleri, (b) yatırım ve sosyal fayda karşılaştırması, (c) SROI projeksiyon trendi, (d) ekonomik etki akış diyagramı, (e) maliyet-etkinlik karşılaştırması ve (f) ilçe bazında ekonomik etki haritası.....	148
Şekil 52. Toplam sahip olma maliyeti; (a) 5 yıllık TCO dağılımı, (b) yıllık işletme maliyetleri trendi ve (c) OHKA ve geleneksel filo TCO karşılaştırması.	149
Şekil 53. INCI – drone analiz kontrol paneli ekranı; (a) göstergeler ve canlı haritalar görünümü, (b) hızlı erişim, aktiviteler ve sistem uyarı görünümü.	150
Şekil 54. Filo yönetimi ekranı; (a) filo güncel durumu görünümü, (b) filonun güncel durumu devamı ve bakım takvimi görünümü.	151
Şekil 55. Rota planlama ve optimizasyon ekranı; (a) rota planlama ve optimizasyon görünümü, (b) 3d uzamsal görüntüsü, rota noktaları ve optimizasyon ayarları görünümü.....	152
Şekil 56. Hava durumu ve çevre analizi ekranı; (a) güncel hava durumu, alanın hava durumu haritası, 5 günlük tahminler ve rüzgar radarı görünümü, (b) risk değerlendirme, güvenli iniş alanları ve çevresel etki analizleri görünümü.	153
Şekil 57. Kargo yönetimi ekranı; (a) canlı kargo takibi ve müşteri yönetimi görünümü, (b) teslimat zaman çizelgesi ve kalite kontrol bilgileri görünümü, (c) teslimat takibi ve müşteri memnuniyeti analizi ile kargo listesi görünümü.....	154
Şekil 58. Analitik sistem ekranı.....	155

KISALTMALAR VE SİMGELER DİZİNİ

AAM	: Gelişmiş Hava Hareketliliği (Advanced Air Mobility)
ABC	: Yapay Arı Kolonisi Algoritması (Artificial Bee Colony)
AD	: Anomali Tespiti (Anomaly Detection)
AF	: Edinim Fonksiyonu (Acquisition Function)
AGVs	: Depo Otomatik Döndümlü Araçlar (Warehouse Automated Guided Vehicles)
ANN	: Yapay Sinir Ağları (Artificial Neural Networks)
APA	: American Psychological Association
AUC	: Eğri Altındaki Alan (Area Under Curve)
BVLOS	: Görüş Hattı Dışında Uçuş (Beyond Visual Line of Sight)
C	: Derece
CAL	: Kooperatif Aktif Yerelleştirme (Cooperative Active Localization)
CBS	: Coğrafi Bilgi Sistemleri
CGSA	: İhtiyatlı Açgözlü Strateji Analizi (Cautious Greedy Strategy Analysis)
CL	: Merkez Çizgisi (Center Line)
CNN	: Evrişimli Sinir Ağları (Convolutional Neural Networks)
CVRP	: Kapasiteli Araç Rotalama Problemi (Capacitated Vehicle Routing Problem)
DAI	: Dağıtılmış Yapay Zekâ (Distributed Artificial Intelligence)
DBN	: Derin İnanış Ağı (Deep Belief Network)
DBSCAN	: Gürültülü Uygulamaların Yoğunluk Tabanlı Mekansal Kümelenmesi (Density-Based Spatial Clustering of Applications with Noise)
DDPG	: Derin Deterministik Politika Gradyanı (Deep Deterministic Policy Gradient)
DL	: Derin Öğrenme (Deep Learning)
DNN	: Derin Sinir Ağı (Deep Neural Network)
DPMO	: Milyon Fırsat Başına Düşen Hata Sayısı (Defects Per Million Opportunities)
DPU	: Birim Başına Kusur (Defects Per Unit)
DQN	: Derin Q-Ağı (Deep Q-Network)
DR	: Hata Oranı (Defect Rate)
DRL	: Derin Pekiştirmeli Öğrenme (Deep Reinforcement Learning)
EI	: Beklenen İyileşme (Expected Improvement)

EIT	: Gömülü Zekâ Görevleri (Embedded Intelligence Tasks)
ETA	: Olay Ağacı Analizi (Event Tree Analysis)
EL	: Topluluk Öğrenmesi (Ensemble Learning)
FCN	: Tamamen Evrişimli Ağlar (Fully Convolutional Networks)
FL	: Federatif Öğrenme (Federated Learning)
FPV	: Birinci Şahıs Bakış Açısı (First Person View)
FSP	: Uçan Gezgin Satıcı Problemi (Flying Salesman Problem)
FTA	: Hata Ağacı Analizi (Fault Tree Analysis)
FWNN	: Bulanık Dalgacık Sinir Ağı (Fuzzy Wavelet Neural Network)
g	: Yerçekimi İvmesi
GAN	: Üretici Karşıt Ağlar (Generative Adversarial Network)
GAT	: Grafik Dikkat Ağları (Graph Attention Networks)
GCN	: Grafik Konvolüsyonel Ağ (Graph Convolutional Network)
GDPR	: Avrupa Birliği Genel Veri Koruma Tüzüğü (General Data Protection Regulation)
GNN	: Graf Sinir Ağı (Graph Neural Networks)
GNSS	: Küresel Navigasyon Uydu Sistemi (Global Navigation Satellite System)
GP	: Gauss Süreci (Gaussian Process)
GPS	: Küresel Konumlandırma Sistemi (Global Positioning System)
GPU	: Grafik İşlem Birimi (Graphics Processing Unit)
GRU	: Geçitli Tekrarlayan Birim (Gated Recurrent Unit)
IMU	: Atalet Ölçüm Birimi (Inertial Measurement Unit)
IQR	: Çeyrekler Arası Aralık (Interquartile Range)
İHA	: İnsansız Hava Aracı
KDE	: Kernel Yoğunluk Tahmini (Kernel Density Estimation)
KNN	: K-en Yakın Komşu (K-Nearest Neighbors)
KPI	: Anahtar Performans Göstergeleri (Key Performance Indicators)
KVKK	: Türkiye Kişisel Verileri Koruma Kanunu
LiDAR	: Işık Algılama ve Değişimi (Light Detection and Ranging)
LoRaWAN	: Uzun Menzilli Geniş Alan Ağı (Long Range Wide Area Network)
LSTM	: Uzun Kısa Süreli Bellek Ağları (Long Short Term Memory)
LTE	: Uzun Vadeli Evrim (Long Term Evolution)
MADRL	: Çok Ajanlı Derin Pekiştirmeli Öğrenme (Multi-Agent Deep Reinforcement Learning)
MAE	: Ortalama Mutlak Hata (Mean Absolute Error)

MCDM	: Çok Kriterli Karar Verme (Multiple Criteria Decision Making)
ML	: Makine Öğrenmesi (Machine Learning)
MPNN	: Mesaj Aktarımlı Sinir Ağları (Message Passing Neural Networks)
MSE	: Ortalama Karesel Hata (Mean Squared Error)
MTBF	: Toplam Arızalar Arası Süre (Mean Time Between Failures)
MTTR	: Ortalama Onarım Süresi (Mean Time To Repair)
NŞD	: Net Şimdiki Değer
OEE	: Toplam Ekipman Etkinliği (Overall Equipment Effectiveness)
OHKA	: Otonom Hava Kargo Araçları
PCA	: Temel Bileşenler Analizi (Principal Component Analysis)
PCI	: Süreç Yeterlilik İndeksi (Process Capability Index)
PPO	: Yakın Politika Optimizasyonu (Proximal Policy Optimization)
PYTS	: Python Zaman Serisi (Python Time Series)
RBM	: Kısıtlı Boltzmann Makinesi (Restricted Boltzmann Machine)
RF	: Radyo Frekansı (Radio Frequency)
RL	: Takviyeli Öğrenme (Reinforcement Learning)
RMSE	: Kök Ortalama Karesel Hata (Root Mean Squared Error)
RNN	: Tekrarlayan Sinir Ağı (Recurrent Neural Network)
ROC	: Alıcı Operatör Karakteristiği (Receiver Operator Characteristics)
RPM	: Dakikadaki Devir Sayısı (Revolutions Per Minute)
RPN	: Risk Öncelik Numarası (Risk Priority Number)
RRI	: İstek-Serbest Bırakma-Kesme (Request-Release-Interrupt)
RSM	: Yanıt Yüzey Metodolojisi (Response Surface Management)
SA	: Öz Dikkat (Self-Attention)
SHAP	: SHapley Katkısal Açıklamalar (SHapley Additive exPlanations)
SİHA	: Silahlı İnsansız Hava Aracı
SROI	: Sosyal Yatırım Getirisi (Social Return on Investment)
SSMD	: Tek Atışlı Çoklu Kutu Dedektörü (Single Shot MultiBox Detector)
STGNN	: Mekânsal-Zamansal Grafik Sinir Ağları (Spatio-Temporal GNN)
TCO	: Toplam Sahip Olma Maliyeti (Total Cost of Ownership)
TPU	: Tensör İşlem Birimi (Tensor Processing Unit)
TRAN	: Transformatör Sinir Ağı (Transformer Neural Network)
TSFEL	: Zaman Serisi Özellik Çıkarma Kütüphanesi (Time Series Feature Extraction Library)

t-SNE	: T-Dağıtılmış Stokastik Komşu Yerleştirme (t-Distributed Stochastic Neighbor Embedding)
TSP	: Gezgin Satıcı Problemi (Traveling Salesman Problem)
UCB	: Üst Güven Sınırı (Upper Confidence Bound)
UTM	: İnsansız Hava Aracı Trafik Yönetimi (Unmanned Aircraft System Traffic Management)
V	: Volt
VAR	: Reaktif Güç (Volt-Ampere Reactive)
VHF	: Çok Yüksek Frekans (Very High Frequency)
VRP	: Araç Rotalama Problemi (Vehicle Routing Problem)
Wh	: Wattsaat
YOLO	: Sadece Bir Kez Bak (You Only Look Once)

GİRİŞ

Küresel taşımacılık sistemlerinde dijitalleşme, otomasyon ve sürdürülebilirlik kavramlarının ön plana çıkması, lojistik sektörünü radikal bir dönüşüm sürecine sokmuştur. Özellikle son teslimat taşımacılığında çevresel etkilerin azaltılması, teslimat hızının artırılması ve insan müdahalesinin en aza indirilmesi hedefleri, geleneksel karayolu taşımacılık çözümlerinin ötesinde yenilikçi sistemlerin geliştirilmesini zorunlu hale getirmiştir. Bu dönüşümün en dikkat çekici bileşenlerinden biri, otonom hava kargo araçları (OHKA) olarak tanımlanan insansız hava sistemlerinin lojistik süreçlere entegrasyonudur. Bu araçlar, yüksek manevra kabiliyeti, esnek rotalama potansiyeli ve enerji verimliliğiyle, özellikle şehir içi ve kırsal bölgelerdeki küçük ölçekli yük taşımacılığı operasyonlarında yeni bir paradigma oluşturma potansiyeline sahiptir.

Otonom hava kargo sistemlerinin hızlı gelişimi, bilgi ve iletişim teknolojilerindeki ilerlemeler, sensör füzyonu, konumlama sistemleri (GNSS, IMU, LiDAR), yapay zekâ destekli kontrol algoritmaları ve bulut tabanlı filo yönetim çözümleriyle yakından ilişkilidir. Bu sistemler, gerçek zamanlı veri toplama ve analiz yetenekleri sayesinde çevresel koşullara uyum sağlayarak hem güvenli hem de enerji açısından optimize edilmiş rota planlamalarını mümkün kılmaktadır. Ancak bu avantajlara rağmen, sistemin operasyonel güvenilirliği, enerji yönetimi, risk analizi, bakım süreçleri ve çevresel etkilere karşı dayanıklılığı hâlâ araştırma gerektiren temel alanlardır.

Bu noktada, derin öğrenme tabanlı algoritmaların otonom hava kargo sistemleriyle entegrasyonu, karar destek sistemlerinin geliştirilmesinde yeni bir boyut kazandırmıştır. Sinir ağları temelli modeller, karmaşık ve değişken çevresel girdiler altında (örneğin rüzgâr yönü, sıcaklık, hava yoğunluğu, yük ağırlığı, uçuş rotası vb.) sistem davranışlarını öğrenebilme kapasitesi sayesinde, klasik deterministik yaklaşımlara kıyasla daha esnek ve öngörülü sonuçlar üretebilmektedir. Bu nedenle derin öğrenme, sadece rota planlama ve enerji optimizasyonunda değil, aynı zamanda filo koordinasyonu, görev atama, bakım planlaması ve arıza tahmini gibi üst düzey lojistik kararlarında da etkin bir araç haline gelmiştir.

Literatürde yapılan çalışmalar, OHKA'ların lojistik performans üzerindeki etkilerini farklı açılardan ele almıştır. Ancak mevcut literatürde bütünlük sistem yaklaşımının eksik olduğu görülmektedir. Çoğu çalışma, belirli bir bileşeni (örneğin, rota planlama veya enerji tüketimi) ayrı bir model olarak ele almakta, ancak sistemin operasyonel, çevresel, ekonomik ve

güvenilirlik boyutlarını aynı çerçevede bütünleştirmemektedir. Ayrıca, çok faktörlü deneysel tasarımlar ve istatistiksel optimizasyon yöntemleri (örneğin, Taguchi yaklaşımı) bu alanda sınırlı düzeyde kullanılmaktadır.

Bu araştırmada, söz konusu boşlukları kapatmak amacıyla, Taguchi'nin L54 ortogonal dizisi deney planı olarak seçilmiş, farklı operasyonel faktörlerin (filo yönetimi, hava durumu, rüzgâr hızı, rota karmaşıklığı, kargo ağırlığı, uçuş mesafesi ve pil durumu) sistem performansı üzerindeki etkileri çok boyutlu biçimde analiz edilmiştir. Deneysel model, farklı senaryolar üzerinden çalıştırılarak teslimat süresi, maliyet, başarı oranı, enerji tüketimi ve karbon ayak izi gibi performans karakteristikleri (çıktı değişkenleri) değerlendirilmiştir. Bu süreçte elde edilen veriler, derin öğrenme temelli bir karar destek sistemi ile bütünleştirilmiş; böylece sistem parametrelerinin hem öngörülebilir hem de adaptif biçimde optimize edilmesi sağlanmıştır.

Araştırmanın temel amacı, otonom hava kargo sistemlerinin lojistik planlama süreçlerinde operasyonel parametrelerin optimum değerlerinin belirlenmesi, risk ve güvenilirlik analizlerinin yapılması ve enerji-sürdürülebilirlik dengesinin istatistiksel olarak modellenmesidir. Bu kapsamda, derin öğrenme algoritmaları yalnızca veri tabanlı öngörü üretmekle kalmamış, aynı zamanda çevresel değişkenlere karşı sistemin öğrenme ve uyum yeteneğini güçlendirmiştir. Böylece araştırma, otonom hava taşımacılığının hem teknik hem de ekonomik sürdürülebilirliğine yönelik kapsamlı bir model geliştirmeyi amaçlamaktadır.

Bu çalışmanın özgün katkısı, Taguchi tabanlı deneysel tasarım, derin öğrenme destekli modelleme ve çok katmanlı performans analizi bileşenlerini bütüncül bir yaklaşımla bir araya getirmesidir. Çalışmada geliştirilen sistem, klasik optimizasyon yöntemlerinin ötesine geçerek, farklı faktörlerin asıl etkilerinin yanısıra bileşik etkilerini (örneğin $A \times B$, $B \times C$ vb.) istatistiksel olarak incelemekte; sonuçta elde edilen çıktı parametrelerini karar destek sistemine entegre etmektedir. Bu bütünleşik yapı sayesinde, OHKA'ların operasyonel başarısını etkileyen kritik faktörlerin tanımlanması, sistem güvenilirliğinin artırılması ve enerji-verimlilik dengesinin sağlanması mümkün hale gelmiştir.

Araştırmanın bilimsel önemi, yalnızca mevcut lojistik sistemlerine OHKA'ların entegrasyonunu değil, aynı zamanda bu sistemlerin veri güdümlü, öğrenen ve uyarlanabilir bir yapıya dönüştürülmesini sağlamasında yatmaktadır. Çalışmanın bulguları, Endüstri 4.0 ve akıllı lojistik perspektifinden, geleceğin taşımacılık sistemlerinin stratejik planlaması için önemli bir rehber niteliği taşımaktadır. Uygulama düzeyinde ise elde edilen sonuçlar, OHKA sistemlerinin enerji optimizasyonu, filo yönetimi, karbon azaltımı ve maliyet etkinliği konularında karar vericilere doğrudan destek sağlayabilecek bir yapay zekâ tabanlı kontrol mimarisi sunmaktadır.

Çalışma beş bölümden oluşmaktadır. İkinci bölümde, OHKA ve drone teknolojilerinin temelleri, lojistikte yapay zekâ uygulamaları, derin öğrenme teknikleri, rota optimizasyon yaklaşımları, enerji yönetimi, hava durumu etkileri, çoklu drone koordinasyonu ve literatürde öne çıkan çalışmaların karşılaştırmalı değerlendirmesi üzerinden kapsamlı bir literatür taraması sunulmuştur.

Üçüncü bölümde, araştırma tasarımı ve sistem yaklaşımı açıklanmış; modüler mimari, kullanılan donanım–yazılım altyapısı ve veri kaynakları tanıtılmış; veri ön işleme/özellik çıkarımı, derin öğrenme modellerinin tasarımı ile Taguchi L54 deney planı, OEE–sigma–PCI ve istatistiksel analiz süreçleri ayrıntılandırılmıştır.

Dördüncü bölümde, deneysel tasarım ve optimizasyon bulguları ile rota optimizasyon sonuçları raporlanmış; performans ve kalite yönetimi, güvenilirlik ve risk analizleri, derin öğrenme/makine öğrenmesi analizleri ve ekonomik değerlendirmeler tartışılmış; ayrıca OHKA sistem takip ve simülasyon ekranlarına ilişkin bulgular sunulmuştur.

Beşinci bölümde ise elde edilen bulgular bütüncül biçimde özetlenerek çalışmanın sonuçları ortaya konmuş ve uygulamaya/yönteme yönelik öneriler geliştirilmiştir.


Bu tez çalışması, derin öğrenme tabanlı OHKA’ların lojistik planlama süreçlerindeki performans, güvenilirlik ve sürdürülebilirlik ilişkilerini bütüncül bir sistem yaklaşımı ile analiz etmektedir. Böylece hem literatüre teorik bir katkı sağlamakta hem de pratik düzeyde endüstriyel uygulamalara referans olabilecek, veri odaklı bir karar destek modeli geliştirmektedir.

KURAMSAL TEMELLER

Bu bölümde, otonom hava kargo araçlarının (OHKA'ların) derin öğrenme (deep learning, DL) yöntemleriyle lojistik planlaması konusunda yapılan literatür araştırması sekiz ana başlık altında sistematik olarak sunulmuştur. Çalışmanın kapsamını oluşturan;

1. Drone teknolojileri,
2. Yapay zekâ uygulamaları,
3. DL teknikleri,
4. Rota optimizasyonu,
5. Enerji yönetimi,
6. Hava durumu tahmini,
7. Çoklu drone koordinasyonu,
8. Literatürdeki önemli çalışmaların karşılaştırmalı analizi

detaylı bir şekilde ele alınmıştır. Taranan literatürde bulunan konuların sayısı Şekil 1'de gösterilmiştir. Şekil 1'de görüldüğü üzere literatürde lojistik planlama ve makine öğrenmesi (machine learning, ML) konuları daha ağırlıklıdır.



Şekil 1. Taranan literatürde bulunan konuların sayısı.

Otonom Hava Kargo Araçları ve Drone Teknolojileri

Otonom hava araçları, son yıllarda lojistik ve taşımacılık sektörlerinde hızlı bir dönüşümün öncüsü olmuştur. Murray and Chu (2015) çalışmalarında, drone yardımlı kargo teslimatının optimizasyonu için matematiksel modelleme yapmışlardır ve bu yaklaşımın geleneksel lojistik yöntemlerine kıyasla önemli avantajlar sunduğunu ortaya koymuşlardır. Joerss (2016) çalışmasında, drone teknolojilerinin son kilometre teslimatlarında ve zorlu

coğrafi koşullarda etkili çözümler sunarak operasyonel verimliliği artırdığını ve maliyetleri düşürdüğünü belirtmiştir. Kellermann *et al.* (2020) ise, drone ve otonom araçların kargo ve yolcu taşımacılığında sağladığı potansiyel faydaları ve bu teknolojilerin mevcut lojistik zincirlerini nasıl dönüştürebileceğini literatür taraması ile değerlendirmişlerdir.

Otonom hava araçları; sensör ve algılama sistemleri, navigasyon ve iletişim teknolojilerinin entegrasyonu ile daha güvenli ve verimli bir şekilde kullanılabilir hale gelmiştir. Harrington (2015) çalışmasında, drone'ların komuta, kontrol ve veri bağlantılarını sağlamak için yer istasyonları veya diğer hava araçları ile iletişim sistemlerini kullandığını ifade etmiştir. Kaspi *et al.* (2022) çalışmalarında, drone'ların lojistik ve tedarik zinciri yönetiminde kullanımının, özellikle e-ticaret teslimatlarında ve tam zamanında üretim yaklaşımında önemli bir rol oynadığını vurgulamışlardır. Ayrıca, Menichino *et al.* (2023) çalışmalarında, ağır yük taşıyan insansız hava araçlarının (İHA'lar) endüstriyel uygulamalarda ve zorlu coğrafi koşullarda etkin bir şekilde kullanıldığını göstermişlerdir.

Drone teknolojilerinin lojistik sektöründeki uygulamaları, sadece kargo teslimatı ile sınırlı kalmamaktadır. Sigari and Biberthaler (2021) çalışmalarında, drone'ların tıbbi malzeme taşımacılığı ve afet müdahalesi gibi insani yardım faaliyetlerinde de önemli bir rol oynadığını belirtmişlerdir. ElSayed and Mohamed (2024) çalışmalarında, otonom İHA'ların rota optimizasyonu için dijital ikiz ve DL yöntemlerini kullanmışlardır ve bu sayede operasyonel süreçlerin daha verimli hale geldiğini ortaya koymuşlardır.

Regülasyonlar ve güvenlik standartları, drone teknolojilerinin yaygın kullanımı için kritik öneme sahiptir. Harrington (2015), Kaspi *et al.* (2022) ve Sieber *et al.* (2024) çalışmalarında, Federal Havacılık İdaresi ve Avrupa Hava Emniyeti Ajansı gibi havacılık otoritelerinin otonom araçların hava sahasına entegrasyonunu düzenlediğini ve güvenlik standartlarını belirlediğini ifade etmişlerdir. Bu düzenlemeler, hava aracının sertifikasyonu, hava trafik yönetimi ve emniyet standartlarına uyum açısından büyük önem taşımaktadır.

Sonuç olarak, otonom hava araçları ve drone teknolojileri, lojistik ve tedarik zinciri yönetiminde devrim niteliğinde yenilikler sunmakta, teslimat süreçlerini hızlandırmakta ve maliyetleri düşürmektedir. Teknolojinin ilerlemesi ve düzenleyici çerçevelerin olgunlaşmasıyla, bu araçların operasyonel verimliliği artırılarak küresel tedarik zincirlerinde önemli bir rol oynaması beklenmektedir.

Drone teknolojilerinin tarihçesi ve gelişimi

Drone teknolojilerinin gelişimi, askeri amaçlarla başlamış ve zamanla sivil kullanıma dönüşmüştür. Harrington (2015), İHA'ların gelişiminde askeri uygulamaların öncü rol

oynadığını ve teknolojinin demokratikleşmesiyle (gelişmiş teknolojilerin geniş halk kitlelerine erişilebilir, uygun maliyetli ve kullanımı kolay hale gelmesi süreci) birlikte sivil sektörlerde yaygınlaştığını belirtmiştir. Bayram *et al.* (2016), otonom hava araçlarının vahşi yaşam takibi gibi araştırma alanlarında kullanılmaya başlandığını göstermişlerdir.

Kaspi *et al.* (2022), OHKA'ların son yıllardaki teknolojik ilerlemeler ve yapay zekâ sistemlerindeki gelişmeler sayesinde lojistik sektöründe önemli bir ivme kazandığını vurgulamışlardır. Singh *et al.* (2023), bu araçların verimliliği artırma, operasyonel maliyetleri düşürme ve ulaşılması zor bölgelere erişimi genişletme potansiyeline sahip olduğunu belirtmişlerdir.

ElSayed and Mohamed (2024), dijital ikiz hava sahası ayırıştırması (gerçek hava sahasının dijital bir kopyasını oluşturarak bu sanal ortamı matematiksel ve hesaplamalı analizler için bölümlere ayırma işlemi) ve otonom İHA'lar için yörünge optimizasyonu konularında çalışmalar yapmışlardır. Bu çalışma, drone teknolojilerinin gelişiminde dijital teknolojilerin entegrasyonunun önemini ortaya koymaktadır.

Drone tipleri ve kullanım alanları

Drone teknolojileri, farklı uçuş prensiplerine ve tasarım özelliklerine göre çeşitli kategorilerde sınıflandırılmaktadır. Bu sınıflandırma, lojistik uygulamalar için uygun drone tipinin seçiminde kritik önem taşımaktadır.

Quadcopter yapıları

Quadcopter yapıları, dört adet motor ve pervaneye sahip olan, dikey kalkış-iniş yapabilen, çok rotorlu İHA'lardır. Quadcopter yapıları, dört rotorlu tasarımı sayesinde yüksek manevra kabiliyeti ve kolay kontrol özellikleri sunmaktadır. Körner *et al.* (2010), quadcopter tasarımının vahşi yaşam takibi uygulamalarında radyo sinyal gücü kullanarak otonom takip sistemleri geliştirmek için kullanıldığını göstermişlerdir.

Bayram *et al.* (2017), çoklu İHA'larla vahşi yaşam takibi konusunda sistem tasarımı, güvenlik ve saha deneyleri üzerine çalışmalar yapmışlardır. Bu çalışma, quadcopter yapılarının koordineli operasyonlarda etkinliğini ortaya koymaktadır.

Van Nguyen *et al.* (2017), radyo etiketli hayvanların gerçek zamanlı lokalizasyonu ve takibi için otonom İHA sistemleri geliştirmişlerdir. Bu araştırma, quadcopter yapılarının karmaşık izleme (tracking) algoritmalarını destekleme yeteneğini göstermektedir.

Sabit kanatlı drone'lar

Sabit kanatlı drone'lar, uzun menzil ve yüksek enerji verimliliği gerektiren uygulamalarda tercih edilmektedir. Limbourg *et al.* (2012), otomatik hava kargo yükleme planlaması konusunda çalışmalar yapmışlar ve sabit kanatlı araçların büyük kargo operasyonlarındaki avantajlarını değerlendirmişlerdir.

Van Nguyen *et al.* (2020), LAVAPilot adı verilen hafif İHA yörünge planlayıcısını geliştirmişler ve gömülü otonomi için durumsal farkındalık ile radyo etiketlerini takip etme ve konumlandırma sistemleri üzerine çalışmışlardır.

Hibrit drone sistemleri

Hibrit drone sistemleri, hem dikey kalkış-iniş hem de sabit kanat uçuş özelliklerini birleştiren gelişmiş tasarımlardır. Menichino *et al.* (2023), gelişmiş hava hareketliliğinde kargo teslimatı için düşük ve orta risk ortamlarda görüş hattı dışında uçuş (beyond visual line of sight, BVLOS) ile rutin operasyonlarının ana faktörlerini araştırmışlardır.

Gajana (2024), güvenlik özellikli tıbbi malzeme teslimat otonom drone'u üzerine çalışmalar yapmış ve hibrit sistemlerin acil durum uygulamalarındaki potansiyelini göstermiştir.

Drone dinamiği ve uçuş kontrol sistemleri

Drone dinamiği ve uçuş kontrol sistemleri, otonom operasyonların güvenilirliği için kritik bileşenlerdir. Bu sistemler, atalet yönetimi, serbestlik dereceleri kontrolü ve sensör füzyonu gibi karmaşık teknolojileri içermektedir.

Atalet ve gövde koordinat sistemleri

ElSayed and Mohamed (2024) tarafından gerçekleştirilen çalışmada, dijital ikiz yaklaşımları temel alınarak hava sahası ayrıklaştırması ve yörünge optimizasyonu konuları ele alınmıştır. Bu kapsamda, atalet ve gövde koordinat sistemlerinin matematiksel modellemedeki kritik rolü vurgulanmıştır; çünkü bu koordinat sistemleri, İHA'ların dinamik davranışlarının doğru şekilde modellenmesi ve simülasyon ortamlarında gerçekçi sonuçlar elde edilmesi açısından temel teşkil etmektedir.

Sonaria and Jenie (2024) ise, BVLOS operasyonel kargo teslimatı gerçekleştiren İHA'lar için bir uyarı sistemi tasarımı üzerine odaklanmıştır. Bu araştırmada, gövde koordinat sistemlerinin güvenlik mekanizmalarıyla entegrasyonu ön plana çıkmaktadır. Gövde koordinat sistemlerinin, uyarı ve kontrol sistemleriyle bütünleşik çalışması sayesinde, uçuş sırasında

ortaya çıkabilecek güvenlik risklerinin daha etkin şekilde tespit edilmesi ve yönetilmesi mümkün olmuştur.

Her iki çalışma, atalet ve gövde koordinat sistemlerinin hem matematiksel modelleme hem de operasyonel güvenlik açısından İHA'ların tasarım ve kontrol süreçlerinde vazgeçilmez bir unsur olduğunu ortaya koymaktadır.

Serbestlik dereceleri ve kontrol mekanizmaları

Sieber *et al.* (2024), otonom İHA'ların kural tabanlı doğrulaması konusunda çalışmalar yapmışlardır. Bu araştırma, serbestlik derecelerinin kontrol algoritmaları ile entegrasyonunun önemini ortaya koymaktadır.

Cliff *et al.* (2015), radyo etiketli vahşi yaşamın otonom hava robot sistemi ile bir sistemin gerçek zamanlı olarak kendi konumunu ve yönelimini belirleme süreci konusunda araştırmalar yapmışlardır. Bu çalışma, kontrol mekanizmalarının gerçek zamanlı uygulamalardaki etkinliğini göstermektedir.

Sensör füzyonu ve algılayıcı sistemler

Cliff *et al.* (2018), robotik ekoloji alanında küçük ve dinamik hayvanların otonom hava aracı ile takibi konusunda çalışmışlardır. Bu araştırma, sensör füzyonu tekniklerinin (birden fazla sensörden gelen verileri birleştirerek daha doğru, güvenilir ve kapsamlı bilgi elde etme yöntemleri) karmaşık algılama görevlerindeki rolünü vurgulamaktadır.

Van Nguyen *et al.* (2018a), çok yüksek frekanslı radyo etiketli vahşi yaşamı arama ve konumlandırma için otonom İHA sensör sistemi geliştirmişlerdir. Bu çalışma, çoklu sensör entegrasyonunun operasyonel performans üzerindeki etkilerini ortaya koymaktadır.

Ju and Son (2022), radyo etiketli uçan böceklerin lokalizasyonu için otonom takip sistemi araştırması yapmışlardır. Bu araştırma, ileri teknoloji sensörlerin kesin takip işlemlerinde ne kadar etkili olabileceğini göstermektedir.

Lojistik ve Tedarik Zinciri Yönetiminde Yapay Zekâ Uygulamaları

Yapay zekâ uygulamaları, lojistik ve tedarik zinciri yönetiminde operasyonel verimliliği artıran ve karar verme süreçlerini iyileştiren kritik teknolojiler haline gelmiştir.

Yapay zekânın lojistik sektöründeki genel uygulamaları

Min (2010), lojistik yönetiminde yapay zekâ uygulamalarının teorik ve pratik açılardan değerlendirmesini yapmış ve bu teknolojilerin sektördeki potansiyelini ortaya koymuştur. Min

and Yu (2008), işbirlikçi planlama, tahmin ve yenileme süreçlerinde tedarik zinciri yönetiminde talep planlaması konularını araştırmışlardır.

Toorajipour *et al.* (2021), tedarik zinciri yönetiminde yapay zekâ konusunda sistematik literatür taraması yapmışlar ve bu teknolojilerin tedarik zinciri dayanıklılığını artırarak operasyonel verimliliği geliştirdiğini göstermişlerdir.

Riahi *et al.* (2021), tedarik zincirinde yapay zekâ uygulamaları konusunda açıklayıcı bibliyometrik analiz ve gelecekteki araştırma yönleri üzerine çalışmalar yapmışlardır. Pournader *et al.* (2021), tedarik zinciri yönetiminde yapay zekâ uygulamalarını kapsamlı bir şekilde incelemişlerdir.

Arshad (2020), iş simülasyon analizinde yapay zekâ konusunda araştırmalar yapmış ve bu teknolojilerin karar verme süreçlerindeki rolünü vurgulamıştır. Helo and Hao (2022), operasyon yönetimi ve tedarik zinciri yönetiminde yapay zekâ konusunda keşifsel vaka çalışması yapmışlardır.

Yapay zekânın tedarik zinciri yönetiminde kullanımı

Baryannis *et al.* (2019a), ML kullanarak tedarik zinciri risklerini tahmin etme konusunda performans ve yorumlanabilirlik arasındaki denge üzerine çalışmışlardır. Sharifmousavi *et al.* (2024), tarım-gıda tedarik zincirlerinde Endüstri 4.0 kapsamında dağıtılmış yapay zekâ (distributed artificial intelligence, DAI, yapay zekâ sistemlerinin birden fazla hesaplama birimi, ağ düğümü veya cihaz üzerinde koordineli şekilde çalıştırılması yaklaşımı) uygulamalarını incelemişlerdir. Çalışmada, DAI sayesinde tarım-gıda tedarik zincirinin çeşitli aşamalarında ileri düzeyde otonom karar alma ve gerçek zamanlı optimizasyon sağlandığı vurgulanmaktadır.

Ganesh and Kalpana (2022), yapay zekânın gelecekteki tedarik zinciri risk yönetimi üzerindeki etkisi konusunda sistematik inceleme yapmışlardır. Cadden *et al.* (2022), tedarik zincirine yapay zekâ entegrasyonunda kültürel faktörlerin etkisini ve aracı rolünü incelemişlerdir. Araştırma sonuçlarına göre, kültürel kolaylaştırıcı unsurlar (örneğin değişime açıklık, bilgi paylaşımı kültürü, güven ve otonomi) tedarik zincirlerinde yapay zekâ teknolojilerinin başarılı bir şekilde entegre edilmesinde belirleyici bir rol oynamaktadır.

Sharma *et al.* (2022), tedarik zinciri yönetiminde yapay zekânın rolü konusunda kapsamlı haritalama çalışması yapmışlardır. Baryannis *et al.* (2019b), tedarik zinciri risk yönetimi ve yapay zekâ konusunda mevcut durum ve gelecekteki araştırma yönlerini değerlendirmişlerdir.

Talep tahmini ve envanter yönetimi

Mamede *et al.* (2023), çoklu dağıtım merkezlerinin vaka çalışmasında ulaştırma talebini tahmin etmek için DL ve istatistiksel modeller geliştirmişlerdir. Li *et al.* (2024), akıllı lojistik talep yönetimi için yeni topluluk öğrenmesi (ensemble learning, EL, birden fazla ML modelini bir araya getirerek tek bir modelden daha güçlü ve doğru tahminler elde etme) yaklaşımını önermişlerdir.

Wahedi *et al.* (2023), özel bir şirketin gelecekteki yazılım konsolidasyonu (bir organizasyondaki farklı yazılım sistemlerinin sayısını azaltarak daha az, daha entegre ve yönetilebilir bir yazılım portföyü oluşturma) sürecinde talep tahmini ve envanter planlaması için klasik yöntemler ile ML yaklaşımlarını ampirik olarak karşılaştırmıştır. Çalışmada, sekiz farklı tahmin yöntemi ve üç envanter yenileme algoritması uygulanarak hem geleneksel istatistiksel modellerin hem de ML tabanlı yöntemlerin performansları değerlendirilmiştir.

Deng and Liu (2021), anomali tespiti (anomaly detection, AD, veri setindeki normal davranış kalıplarından önemli ölçüde sapan nadir veya anormal örnekleri belirleme süreci) için DL tabanlı envanter yönetimi ve talep tahmini optimizasyon yöntemi geliştirmişlerdir. Sharma *et al.* (2024), talep tahmini ve envanter yönetimi için tedarik zinciri yönetimi konusunda DL yaklaşımları araştırmışlardır.

Chen *et al.* (2024), derin pekiştirmeli öğrenme (deep reinforcement learning, DRL, pekiştirmeli öğrenme prensiplerini derin sinir ağları ile birleştiren güçlü bir ML yaklaşımı) tabanlı tedarik zincirinde envanter yönetimi optimizasyon stratejisi üzerine araştırmalar yapmışlardır. Heruatmadja *et al.* (2024), envanter yönetiminde yüksek doğruluklu nesne tespiti için uygun DL tabanlı sistematik literatür incelemesi yapmışlardır.

Depo yönetimi ve yük optimizasyonu

Lau and Zhao (2004), otomatik hava kargo terminallerinde malzeme taşıma ekipmanlarının programlanması için çok amaçlı genetik algoritmalar geliştirmişlerdir. Tao *et al.* (2021), depo otomatik güdümlü araçları (warehouse automated guided vehicles, AGVs, depo ve lojistik merkezlerinde malzeme taşıma, depolama ve sipariş toplama işlemlerini otonom olarak gerçekleştiren akıllı araçlar) için yeni entegre yol planlama algoritması önermişlerdir.

Jedermann and Lang (2008), lojistikte yaygın bilişim için gömülü zekâ görevleri (embedded intelligence tasks, EIT, kaynak kısıtlı gömülü sistemlerde gerçekleştirilen yapay zekâ ve ML) ve uygulamaları konusunda araştırmalar yapmışlardır. Ben-Daya *et al.* (2019), nesnelerin interneti ve tedarik zinciri yönetimi konusunda literatür taraması yapmışlardır.

Otonom sistemlerin lojistik sektörüne entegrasyonu

Murray and Chu (2015), drone destekli parsel teslimatının optimizasyonu konusunda uçan yardımcı satış temsilcisi problemi (flying salesman problem, FSP), klasik gezgin satıcı probleminin (traveling salesman problem, TSP) hava aracı tabanlı versiyonu üzerine çalışmışlardır. Kellermann *et al.* (2020), parsel ve yolcu taşımacılığı için drone'lar konusunda literatür taraması yapmışlardır.

Salip *et al.* (2023), yapay arı kolonisi algoritmasına (artificial bee colony, ABC, doğadaki bal arılarının yiyecek arama davranışlarından esinlenilerek geliştirilmiş bir sürü zekâsı tabanlı optimizasyon algoritması) dayalı kargo taşımacılığı sırasında otonom elektrikli kamyonların enerji tüketiminin optimizasyonu üzerine çalışmışlardır. Tang *et al.* (2020), silah bırakma kısıtlamaları olan otonom insansız savaş hava araçlarının vaka tabanlı çevrimiçi yöürünge planlama yöntemi geliştirmişlerdir.


Zhu *et al.* (2023), lojistikte çoklu robot sistemleri için otonom topolojik optimizasyon konusunda araştırmalar yapmışlardır. Vander Hook *et al.* (2014), sadece yön tabanlı aktif yerelleştirme için ihtiyatlı açgözlü strateji analizi (cautious greedy strategy analysis, CGSA) ve saha deneyleri yapmışlardır.

Derin Öğrenme Tekniklerinin Lojistik ve Drone Yönetimi Alanında Kullanımı

DL teknikleri, lojistik ve drone yönetimi alanlarında karmaşık problemlerin çözümünde güçlü araçlar sunmaktadır. Bu tekniklerin temel prensipleri ve uygulamaları, otonom hava kargo sistemlerinin gelişimi için kritik öneme sahiptir.

Derin öğrenme yöntemlerinin temel prensipleri

DL yöntemleri, çok katmanlı sinir ağları kullanarak karmaşık veri desenlerini öğrenme yeteneği sunar. Bu yöntemler, lojistik ve drone uygulamalarında çeşitli problemlerin çözümünde kullanılmaktadır. Şekil 2'de DL teknikleri detaylı olarak gösterilmiştir.



Şekil 2. DL teknikleri.

Yapay sinir ağları

Li *et al.* (2022), DL konusunda prensipleri, algoritmaları, uygulamaları ve açık konuları araştırmışlardır. Bu çalışma, yapay sinir ağlarının (artificial neural networks, ANN) evrimsel algoritmalarla entegrasyonunun potansiyelini ortaya koymaktadır.

Najafabadi *et al.* (2015), büyük veri analitiğinde DL uygulamaları ve zorlukları konusunda kapsamlı araştırma yapmışlardır.

Evrişimli sinir ağları (convolutional neural networks, CNN)

Ranjan and Senthamilarasu (2020), otonom sürücü otomobiller için uygulamalı DL ve bilgisayarlı görü konusunda çalışmalar yapmışlardır. Wu *et al.* (2022), hesaplamalı histopatoloji için DL'nin son gelişmeleri konusunda prensipleri ve uygulamaları araştırmışlardır. Bu çalışmada kullanılan mantık tezdeki sentetik hava durumları tahminleri aşamasında kullanılmıştır.

Liu *et al.* (2016), tek atışlı çoklu kutu dedektörü (single shot multibox detector, SSMD) adlı yöntemi geliştirerek, nesne algılama alanında tek aşamalı ve yüksek doğruluklu bir çözüm sunmuşlardır. Redmon (2016) ise, You Only Look Once (YOLO) adını verdiği birleşik ve gerçek zamanlı nesne algılama sistemini tanıtarak, görüntüdeki nesnelerin hızlı ve bütünsel bir şekilde tespit edilmesini mümkün kılmıştır. Long *et al.* (2015) ise, tamamen evrişimli ağlar (fully convolutional networks, FCN) yaklaşımını önererek, semantik segmentasyon problemlerinde görüntülerin piksel düzeyinde sınıflandırılmasına olanak sağlayan yenilikçi bir mimari geliştirmişlerdir.

Ronneberger *et al.* (2015), biyomedikal görüntü segmentasyonu için evrişimli ağlar olan U-Net'i geliştirmişlerdir. Qi *et al.* (2017a), 3D sınıflandırma ve segmentasyon için nokta setlerinde DL yapan PointNet'i önermişlerdir.

Uzun kısa süreli bellek ağları

Kendall and Cipolla (2016), kamera yeniden konumlandırması için DL'de belirsizliğin modellenmesi konusunda çalışmışlardır. Altché and de La Fortelle (2017), otoyol yörünge tahmini için uzun kısa süreli bellek ağları (long short term memory, LSTM) ağı geliştirmişlerdir.

Mamede *et al.* (2023), çoklu dağıtım merkezlerini kapsayan bir vaka çalışmasında, ulaştırma talebinin öngörülmesinde LSTM tabanlı DL modellerinden yararlanmışlardır. Bu çalışma, LSTM mimarisinin karmaşık ve değişken talep desenlerini yüksek doğrulukla modelleyebilme yeteneğini vurgulamaktadır.

Buna ek olarak, Li *et al.* (2024), zaman serisi tabanlı talep tahmini problemine yönelik olarak LSTM ile geçitli tekrarlayan birim (gated recurrent unit, GRU) modellerinin performanslarını karşılaştırmalı olarak incelemişlerdir. Araştırmada, her iki modelin de talep tahmininde güçlü sonuçlar verdiği; ancak veri setinin özelliklerine ve tahminin gerektirdiği doğruluk düzeyine göre model tercihinin değişebileceği ortaya konulmuştur.

Her iki çalışma, DL tabanlı ardışık modelleme yaklaşımlarının lojistik ve tedarik zinciri yönetimi alanında talep tahmini süreçlerinde etkinliğini ve uygulama potansiyelini göstermektedir.

Derin pekiştirmeli öğrenme

Lillicrap (2015), sürekli kontrolle DRL konusunda çalışmalar yapmıştır. Yang and Guan (2023), DL modeli ve blok zincir teknolojisine dayalı lojistik dağıtım rota optimizasyonu üzerine araştırmalar yapmışlardır.

Yu *et al.* (2024), çok ajanlı DRL tabanlı zaman pencereleri ile lojistik dağıtım rota optimizasyonu geliştirmişlerdir. Jiang (2022), DL tabanlı lojistik dağıtım yolu optimizasyon algoritması önermiştir.

Chen *et al.* (2024), tedarik zinciri envanter yönetiminin optimizasyonu amacıyla DRL tabanlı stratejiler geliştirmiştir. Bu kapsamda, envanter yönetimi süreçlerinde DRL algoritmalarının uygulanabilirliği değerlendirilmiş ve geleneksel yöntemlere kıyasla daha yüksek verimlilik ve adaptasyon kabiliyeti sağladığı ortaya konmuştur. Araştırmada, uçtan uca sinir ağı mimarisiyle optimal envanter yönetimi stratejilerinin öğrenilmesi ve dinamik tedarik zinciri koşullarına uyum sağlanması vurgulanmıştır.

Han *et al.* (2023) ise, dağıtım ağı kontrolü ve optimizasyonunda DRL yöntemlerinin etkinliğini incelemiştir. Çalışmada, DRL tabanlı yaklaşımların dağıtım ağlarının karmaşık ve belirsiz yapısında VOLT (gerilim, voltage)/VAR (Reaktif güç, Volt-Ampere Reactive) kontrolü, yeniden yapılandırma ve restorasyon gibi operasyonel süreçlerde başarıyla uygulanabildiği gösterilmiştir. Sonuçlar, DRL algoritmalarının dağıtım ağlarında esneklik ve operasyonel verimlilik sağlama potansiyelini ortaya koymaktadır.

Üretici karşıt ağlar

Wu *et al.* (2022), üretici karşıt ağlar (generative adversarial network, GAN) teknolojilerinin tıbbi görüntü işleme alanındaki uygulamalarını kapsamlı bir şekilde incelemiştir. Bu çalışmada, GAN tabanlı modellerin tıbbi görüntülerin sentezi, iyileştirilmesi, segmentasyonu ve AD gibi çeşitli görevlerde sağladığı avantajlar detaylı olarak ele alınmıştır. Araştırma, GAN'ların özellikle veri artırma, görüntü kalitesinin artırılması ve etiketli veri eksikliği gibi temel sorunların aşılmasında önemli katkılar sunduğunu ortaya koymaktadır.

Huang *et al.* (2023) ise, görüntü matting (bilgisayar görü ve görüntü işleme alanında bir görüntüdeki ön plan nesnelerini arka plandan hassas bir şekilde ayırma işlemi) alanında DL yöntemlerinin etkinliğini araştırmış ve bu bağlamda GAN tabanlı yaklaşımların rolünü analiz etmişlerdir. Çalışmada, GAN'ların görüntü matting süreçlerinde detayların korunması, kenar yumuşaklığının iyileştirilmesi ve genel matting doğruluğunun artırılması konularında önemli

avantajlar sağladığı vurgulanmıştır. Ayrıca, GAN tabanlı modellerin, matting problemlerinde geleneksel yöntemlere kıyasla daha üstün performans gösterdiği belirtilmiştir.

Graf sinir ağları

Güncel literatürde, graf sinir ağları (graph neural networks, GNN) tabanlı yaklaşımların lojistik ağ optimizasyonunda kullanımı üzerine çok sayıda araştırma yürütülmektedir. Bu çalışmalar, GNN'lerin karmaşık ve dinamik lojistik ağlarının topolojik özelliklerini etkin biçimde modelleyebilme ve analiz edebilme kapasitesine sahip olduğunu göstermektedir. Özellikle, düğümler arası ilişkilerin ve ağ üzerindeki akışların bütüncül olarak ele alınması sayesinde, lojistik süreçlerin optimizasyonunda yüksek doğruluk ve esneklik elde edilmektedir. GNN tabanlı modeller, geleneksel yöntemlere kıyasla büyük ölçekli ve heterojen lojistik ağlarında rota planlaması, kaynak tahsisi ve ağ dayanıklılığı gibi kritik problemlerin çözümünde üstün performans sergilemektedir. Bu bağlamda, GNN'lerin lojistik ağ optimizasyonunda yenilikçi ve etkili bir araç olarak öne çıktığı vurgulanmaktadır.

Drone ve lojistik alanında derin öğrenme yöntemleri ile yapılan araştırmalar

Waikar *et al.* (2023), DL kullanarak rota optimizasyonu konusunda inceleme yapmışlardır. Song *et al.* (2022), büyük veri arka planında DL modeline dayalı acil lojistik tanımlama yönteminin optimizasyon analizi üzerine çalışmışlardır.

Wang *et al.* (2023), balina ilhamlı derin Q-ağına dayalı çoklu İHA otonom yol planlama algoritması geliştirmişlerdir. Bijjahalli *et al.* (2020), küçük İHA'lar için akıllı ve otonom navigasyon sistemlerindeki gelişmeleri araştırmışlardır.

Chatterjee *et al.* (2023), mühendislikte ML algoritmaları ve uygulamaları konusunda kapsamlı çalışma yapmışlardır. Soori *et al.* (2023), gelişmiş robotik araçlar, yapay zekâ, ML ve DL konusunda inceleme yapmışlardır.

Derin öğrenme yöntemlerinin avantaj ve kısıtlamaları

Dosovitskiy *et al.* (2017), CARLA açık kentsel sürüş simülatörü geliştirerek DL modellerinin test edilmesi için platform sunmuşlardır. Samek (2017), açıklanabilir yapay zekâ konusunda DL modellerini anlama, görselleştirme ve yorumlama üzerine çalışmıştır.

Bojarski (2016), kendinden sürücülü otomobiller için uçtan uca öğrenme geliştirmiştir. Chen *et al.* (2017), otonom sürüş için çok görünümlü 3D nesne algılama ağı oluşturmuşlardır.

Drone Rota Optimizasyonu için Kullanılan Algoritmalar ve Yöntemler

Drone rota optimizasyonu, lojistik uygulamalarında verimliliği artırmak ve operasyonel maliyetleri düşürmek için kritik öneme sahip bir araştırma alanıdır.

Geleneksel rota optimizasyonu yöntemleri

Geleneksel optimizasyon yöntemleri, matematiksel modelleme ve sezgisel yaklaşımlar (karmaşık problemleri çözmek için deneyim, sezgi ve pratik kurallara dayalı yaklaşım yöntemleri) temelinde geliştirilmiştir. Bu yöntemler, drone rota planlamasının temelini oluşturmaktadır.

Dijkstra, A* ve diğer en kısa yol algoritmaları

Van Der Heijden *et al.* (2002), otomatik taşıma sistemlerinde araç programlama konusunda çalışmışlardır. Liu *et al.* (2020), yemek teslimat rota planlaması için Dijkstra algoritmasını derin ters pekiştirmeli öğrenmeye (gözlemlenen optimal davranışlardan ödül fonksiyonunu öğrenmeyi amaçlayan ileri seviye bir ML yaklaşımı) entegre etmişlerdir.

Mercy and Pipeleers (2017), geniş ortamda otonom araçlar için hareket planlaması geliştirmişlerdir. Mohseni and Morsali (2017), çoklu otonom araçlar için ayrışık örnekleme tabanlı planlama yöntemi önermişlerdir.

Araç rotalama problemi

Hu *et al.* (2020), yapay zekâ tabanlı lojistik araçları için optimal rota planlama sistemi geliştirmişlerdir. Schouwenaars (2006), otonom araçların güvenli yörünge planlaması konusunda doktora tezi çalışması yapmıştır.

Yapay zekâ ve optimizasyon temelli rota planlama teknikleri

Yapay zekâ ve optimizasyon tekniklerinin entegrasyonu, geleneksel yöntemlerin sınırlarını aşan gelişmiş rota planlama çözümleri sunmaktadır.

Genetik algoritmalar ve meta-sezgisel yöntemler

Cavalcante *et al.* (2019), dijital üretim ortamlarında dayanıklı tedarikçi seçimi amacıyla, veri odaklı simülasyon süreçlerine denetimli ML yaklaşımlarını entegre etmişlerdir. Bu kapsamda, tedarikçi seçiminde karşılaşılan belirsizlikleri ve karmaşıklıkları azaltmak için ML tabanlı modeller geliştirilmiş; böylece, tedarik zincirinin dayanıklılığını artırmaya yönelik daha isabetli ve öngörülebilir karar destek mekanizmaları oluşturulmuştur. Araştırma, dijital

üretimde veri analitiği ve yapay zekâ uygulamalarının, tedarikçi seçimi süreçlerinde etkinliğini ve operasyonel esnekliği artırmada kritik bir rol oynadığını ortaya koymaktadır.

Lau and Zhao (2004) ise, otomatik hava kargo terminallerinde malzeme taşıma ekipmanlarının programlanması problemine yönelik olarak çok amaçlı genetik algoritmalar geliştirmişlerdir. Bu çalışmada, malzeme taşıma ekipmanlarının etkin zamanlama ve kaynak tahsisi için genetik algoritma tabanlı optimizasyon teknikleri kullanılmış; böylece, terminal operasyonlarının verimliliği ve kaynak kullanımında optimal çözümler elde etmişlerdir. Araştırma, çok amaçlı genetik algoritmaların, karmaşık lojistik süreçlerinde çoklu hedeflerin dengelenmesi ve operasyonel performansın artırılması açısından önemli avantajlar sunduğunu göstermektedir.

Derin pekiştirmeli öğrenme temelli rota optimizasyonu

Yang and Guan (2023), lojistik dağıtım rota optimizasyonu alanında, DL modelleri ile blok zincir teknolojisinin entegrasyonunu temel alan yenilikçi bir yaklaşım geliştirmişlerdir. Bu çalışmada, özellikle dikkat mekanizmasına sahip derin pekiştirmeli öğrenme algoritmaları ve LSTM mimarisi kullanılarak, dağıtım araçlarının rota planlamasında yüksek doğruluk ve esneklik sağlanmıştır. Ayrıca, blok zincir teknolojisi sayesinde veri güvenliği ve şeffaflık artırılmıştır.

Yu *et al.* (2024), çok ajanlı derin pekiştirmeli öğrenme (multi-agent deep reinforcement learning, MADRL) tabanlı bir yöntem geliştirerek, zaman pencereleriyle kısıtlanmış lojistik dağıtım rota optimizasyonu problemine çözüm sunmuşlardır. Bu yaklaşım, birden fazla dağıtım aracının eşzamanlı ve koordineli biçimde en uygun rotaları belirlemesini ve zaman kısıtlarını gözeterek teslimatların optimize edilmesini mümkün kılmıştır.

Jiang (2022), karmaşık ve değişken lojistik ağlarında güzergâh belirlenmesi için önerdiği DL tabanlı algoritmanın klasik yöntemlere kıyasla daha kısa yol uzunlukları ve daha düşük maliyetler sağlayarak lojistik dağıtım yolu optimizasyonunda verimli sonuçlar elde ettiğini göstermiştir.

Waikar *et al.* (2023) ise, DL tabanlı rota optimizasyonu üzerine kapsamlı bir inceleme makalesi sunarak, bu alandaki temel teknikleri, uygulama örneklerini ve performans kriterlerini detaylı olarak değerlendirmişlerdir. Çalışmada, DL tabanlı yaklaşımların geleneksel yöntemlere kıyasla rota uzunluğu, tamamlanma süresi ve esneklik gibi ölçütlerde önemli iyileşmeler sağladığını vurgulamışlardır.

Enerji Yönetimi ve Verimlilik Artırma Yöntemleri

Enerji yönetimi, drone operasyonlarının sürdürülebilirliği ve ekonomik verimliliği için kritik öneme sahiptir. Bu alanda yapılan çalışmalar, pil teknolojilerinden yapay zekâ destekli optimizasyon stratejilerine kadar geniş bir spektrumu kapsamaktadır.

Drone sistemlerinde enerji yönetiminin önemi

ElSayed and Mohamed (2024) tarafından gerçekleştirilen çalışmada, dijital ikiz tabanlı hava sahası ayrıklaştırması ve otonom İHA'lar için gelişmiş yörünge optimizasyonu yöntemleri ele alınmıştır. Araştırmada, enerji yönetimi ile yörünge planlamasının entegrasyonunun, otonom hava araçlarının operasyonel verimliliği ve sürdürülebilirliği açısından kritik bir unsur olduğu vurgulanmıştır. Özellikle, enerji kısıtlarının yörünge optimizasyon süreçlerine dahil edilmesiyle, uçuş sürelerinin uzatılması ve görev başarısının artırılması hedeflenmiştir.

Menichino *et al.* (2023) ise, gelişmiş hava hareketliliği (advanced air mobility, AAM) ve kargo teslimatı uygulamalarında, BVLOS rutin operasyonların temel belirleyicilerini incelemişlerdir. Bu kapsamda, enerji yönetimi uygulamalarının operasyonel güvenlik üzerindeki etkileri analiz edilmiş; enerji verimliliğinin ve yönetiminin, BVLOS operasyonlarının güvenli ve kesintisiz bir şekilde yürütülmesinde önemli bir rol oynadığı ortaya konmuştur. Çalışma, enerji yönetimi stratejilerinin operasyonel risklerin azaltılması ve sistem güvenilirliğinin artırılması açısından vazgeçilmez olduğunu göstermektedir.

Pil yönetimi ve enerji optimizasyon yöntemleri

Gajana (2024) tarafından gerçekleştirilen çalışmada, güvenlik odaklı tıbbi malzeme teslimatı için otonom bir drone sistemi geliştirilmiştir. Araştırmada, özellikle kritik uygulamalarda pil yönetimi sistemlerinin operasyonel süreklilik, güvenlik ve görev başarısı açısından taşıdığı stratejik öneme vurgu yapılmıştır. Geliştirilen otonom drone, tıbbi malzemelerin hızlı ve güvenli bir şekilde hedef noktaya ulaştırılmasını sağlarken, entegre pil yönetimi sistemleri sayesinde uçuş süresinin optimize edilmesi ve beklenmedik enerji kesintilerinin önlenmesi hedeflenmiştir. Çalışma, pil yönetimi teknolojilerinin, özellikle acil durum ve hassas lojistik operasyonlarında, sistemin güvenilirliği ve etkinliği üzerinde belirleyici bir rol oynadığını ortaya koymaktadır.

Yapay zekâ destekli enerji yönetim stratejileri

Salip *et al.* (2023), otonom elektrikli kamyonların kargo taşımacılığı sürecinde enerji tüketiminin optimizasyonu amacıyla yapay arı kolonisi algoritmasına dayalı bir yaklaşım geliştirmiştir. Araştırmada, meta-sezgisel algoritmaların enerji yönetimi ve optimizasyonundaki

yüksek etkinliği vurgulanmıştır. Özellikle yapay arı kolonisi algoritmasının, karmaşık lojistik senaryolarında enerji tüketimini minimize etmede geleneksel yöntemlere kıyasla daha esnek ve verimli çözümler sunduğu gösterilmiştir. Çalışmanın bulguları, meta-sezgisel tabanlı optimizasyon tekniklerinin otonom taşımacılıkta enerji verimliliği sağlama ve sürdürülebilir lojistik operasyonlar geliştirme açısından önemli bir potansiyele sahip olduğunu ortaya koymaktadır.

Enerji yönetimi ve performans değerlendirme metrikleri

Sieber *et al.* (2024), otonom İHA'ların operasyonel güvenliğini sağlamak amacıyla kural tabanlı doğrulama yöntemleri geliştirmiştir. Araştırmada, İHA'ların enerji performansının mevcut güvenlik standartlarıyla olan ilişkisi sistematik olarak incelenmiştir. Özellikle, enerji yönetimi stratejilerinin, uçuş güvenliği ve operasyonel süreklilik üzerindeki etkileri analiz edilmiş; enerji performansının, kural tabanlı doğrulama süreçlerinde güvenlik gereksinimlerinin karşılanmasında kritik bir rol oynadığı ortaya konmuştur. Çalışma, enerji verimliliği ve güvenlik standartlarının entegrasyonunun, otonom İHA'ların güvenilir ve emniyetli operasyonları için temel bir gereklilik olduğunu vurgulamaktadır.

Hava Durumu Tahmini ve Drone Operasyonları Üzerindeki Etkileri

Hava durumu koşulları, drone operasyonlarının güvenliği ve verimliliği üzerinde doğrudan etkiye sahiptir. Bu alanda yapılan çalışmalar, tahmin teknolojilerinden operasyonel stratejilere kadar geniş bir yelpaze sunmaktadır.

Meteorolojik veri analizi ve hava durumu tahmin teknikleri

Meteorolojik veri analizi, İHA operasyonlarının etkin planlanması ve güvenliğinin sağlanmasında temel bir unsur olarak öne çıkmaktadır. Sonaria and Jenie (2024) tarafından gerçekleştirilen çalışmada, BVLOS operasyonel kargo teslimatı gerçekleştiren İHA'lar için bir uyarı sistemi tasarımı geliştirilmiştir. Bu kapsamda, meteorolojik verilerin gerçek zamanlı olarak toplanması ve analiz edilmesiyle elde edilen bulguların, İHA güvenlik sistemlerine entegre edilmesinin operasyonel risklerin azaltılmasında kritik bir rol oynadığı vurgulanmıştır. Araştırmada, hava durumu bilgilerinin uyarı ve kontrol mekanizmalarına entegre edilmesi sayesinde, ani meteorolojik değişimlerin önceden tespit edilerek uçuş güvenliğinin artırılacağı ve operasyonel sürekliliğin sağlanabileceği ortaya konmuştur. Bu bulgular, meteorolojik veri analizinin, BVLOS kargo teslimatlarında hem güvenlik hem de operasyonel verimlilik açısından vazgeçilmez bir bileşen olduğunu göstermektedir.

Drone operasyonlarında hava durumunun etkisi

ElSayed and Mohamed (2024) tarafından gerçekleştirilen çalışmada, dijital ikiz tabanlı hava sahası ayrıklaştırması ve yörünge optimizasyonu süreçlerinde hava durumu faktörlerinin etkisi kapsamlı bir şekilde analiz edilmiştir. Araştırmada, meteorolojik değişkenlerin (örneğin rüzgâr hızı, sıcaklık, nem ve yağış) İHA'ların yörünge planlamasına olan etkileri vurgulanmış; bu faktörlerin uçuş güvenliği, enerji verimliliği ve operasyonel süreklilik açısından kritik rol oynadığı ortaya konmuştur. Özellikle, dijital ikiz teknolojisi sayesinde gerçek zamanlı hava durumu verilerinin simülasyon ortamlarına entegre edilmesiyle, İHA'ların dinamik çevresel koşullara uyum sağlayabilen esnek ve güvenli yörüngeler oluşturabileceği gösterilmiştir. Çalışma, hava durumu faktörlerinin yörünge optimizasyon algoritmalarına dahil edilmesinin hem uçuş performansını artırdığı hem de operasyonel riskleri azalttığı sonucuna ulaşmıştır.

Yapay zekâ tabanlı hava durumu tahmin modelleri

Yapay zekâ tabanlı hava durumu tahmin modelleri, geleneksel meteoroloji yöntemlerinin ötesinde gelişmiş çözümler sunmaktadır.

Zaman serisi tahmini yöntemleri (LSTM ve GRU)

Li *et al.* (2024), akıllı lojistik talep yönetimi kapsamında geliştirdikleri yeni EL yaklaşımında, zaman serisi tahmini için LSTM modellerinden yararlanmıştır. Araştırmada, LSTM mimarisinin karmaşık ve dinamik lojistik talep desenlerini modellemedeki başarısı vurgulanmış; özellikle hava durumu verilerinin analiziyle talep tahmin doğruluğunun anlamlı biçimde artırıldığı gösterilmiştir. EL çerçevesinde LSTM modellerinin diğer istatistiksel ve ML yöntemleriyle entegre edilmesi sayesinde, lojistik talep yönetiminde hem kısa vadeli dalgalanmaların hem de uzun vadeli eğilimlerin daha etkin biçimde öngörülebildiği ortaya konmuştur. Bu çalışma, hava durumu gibi dışsal değişkenlerin lojistik talep tahminine entegre edilmesinde LSTM tabanlı zaman serisi modellerinin kritik bir rol oynadığını göstermektedir.

GAN ile sentetik hava durumu veri üretimi

Wu *et al.* (2022), hesaplamalı histopatoloji alanında DL yöntemlerinin son gelişmelerini incelemiş ve özellikle GAN teknolojilerinin sentetik veri üretimindeki yüksek potansiyelini ortaya koymuşlardır. Araştırmada, GAN tabanlı modellerin sınırlı veya dengesiz veri setlerinde gerçekçi ve çeşitliliği yüksek sentetik örnekler üretebildiği vurgulanmıştır. Bu yaklaşım, yalnızca tıbbi görüntüleme alanıyla sınırlı kalmayıp, meteorolojik veri augmentasyonu (mevcut veri setindeki örnekleri çeşitli dönüşümler uygulayarak yapay olarak çoğaltma ve çeşitlendirme işlemi) gibi farklı uygulama alanlarına da genişletilebilmektedir. Özellikle meteorolojik veri

üretiminde GAN'ların kullanılması, hava durumu verilerinin çeşitlendirilmesi, veri eksikliklerinin giderilmesi ve model eğitiminde daha dengeli ve kapsamlı veri setlerinin oluşturulması açısından önemli avantajlar sağlamaktadır. Böylece, GAN tabanlı sentetik veri üretimi, meteorolojik analiz ve tahmin modellerinin doğruluğunu ve genellenebilirliğini artırmada kritik bir rol üstlenmektedir.

Çoklu Drone Koordinasyonu ve Operasyonel Zorluklar

Çoklu drone sistemleri, karmaşık lojistik operasyonlarında ölçeklenebilir çözümler sunmakla birlikte, koordinasyon ve güvenlik açısından önemli zorluklar yaratmaktadır.

Çoklu drone sistemlerinde koordinasyon ve iş birliği

Bayram *et al.* (2017), çoklu İHA sistemlerinin vahşi yaşam takibindeki uygulamalarını ele alarak, sistem tasarımı, güvenlik ve saha deneyimlerine odaklanmışlardır. Bu kapsamda, her bir İHA'nın radyo etiketli hayvanların lokalizasyonunda görev aldığı, koordineli hareket ve senkronize ölçüm stratejilerinin pratikte nasıl uygulanabileceği detaylı biçimde incelenmiştir. Çalışmada, çoklu İHA'ların birlikte hareket ederek ölçüm verimliliğini ve izleme doğruluğunu artırdığı, ayrıca güvenlik ve operasyonel etkinlik açısından önemli avantajlar sağladığı ortaya konmuştur.

Van Nguyen *et al.* (2017), radyo etiketli hayvanların gerçek zamanlı lokalizasyonu ve takibi için otonom İHA tabanlı bir sistem geliştirmişlerdir. Geliştirilen sistemde, çoklu radyo etiketlerinden elde edilen sinyal gücü verileri, parçacık filtreleri ile kısmen gözlemlenebilir Markov karar süreçleri çerçevesinde entegre edilmiştir. Bu bütünlük yaklaşım sayesinde, dinamik ve belirsiz çevresel koşullar altında hedeflerin yüksek doğrulukla lokalize edilmesi ve izlenmesi mümkün kılınmıştır. Ayrıca, geliştirilen yöntem, çoklu hedeflerin eş zamanlı ve enerji açısından verimli biçimde takibini sağlayarak, izleme operasyonlarının etkinliğini ve sürdürülebilirliğini artırmaktadır.

Zhu *et al.* (2023) ise, lojistik uygulamalarında çoklu robot sistemleri için otonom topolojik optimizasyon yöntemleri geliştirmişlerdir. Çalışmada, ayrık topolojik harita temsili kullanılarak bireysel robotların düşük maliyetli rota planlaması ve çevresel kısıtlara göre navigasyon aksiyonlarının dinamik olarak değiştirilmesi sağlanmıştır. Ayrıca, kaynak tabanlı istek-serbest bırakma-kesme (request-release-interrupt, RRI) algoritması ile çakışma ve darboğazların önüne geçilmiş; genetik algoritma ve ayrık olay simülasyonu entegrasyonu ile taşıma verimliliği ve sistem ölçeklenebilirliği artırılmıştır. Bu yaklaşımlar, çoklu robot koordinasyonunun lojistikte operasyonel etkinlik ve güvenlik açısından kritik rol oynadığını göstermektedir.

Bu çalışmalar, çoklu drone ve robot sistemlerinde koordinasyon ve iş birliğinin hem biyolojik izleme hem de lojistik uygulamalarda operasyonel başarı ve verimlilik açısından temel bir unsur olduğunu ortaya koymaktadır.

Kooperatif aktif yerelleştirme ve çoklu sensör veri füzyonu

Vander Hook *et al.* (2014), yalnızca yön bilgisine dayalı kooperatif aktif konumlandırma (cooperative active localization, CAL, çoklu robot/ajan sistemlerinde, ajanların koordineli hareket ederek birbirlerinin ve kendi konumlarını optimal şekilde belirlemesini sağlayan gelişmiş bir konumlandırma yaklaşımı) problemine yönelik olarak CGSA değerlendirmesini gerçekleştirmiş ve saha deneyleriyle bu stratejilerin etkinliğini ortaya koymuşlardır. Çalışmada, CAL sürecinde belirsizliklerin minimize edilmesi ve hedeflerin hassas biçimde konumlandırılması için yönsel ölçümlerin nasıl optimize edilebileceği detaylı olarak incelenmiştir. Elde edilen bulgular, yön tabanlı yerelleştirme algoritmalarının, özellikle radyo etiketli nesnelerin takibinde gerçek ortam koşullarında yüksek doğruluk ve güvenilirlik sunduğunu göstermektedir.

Van Nguyen *et al.* (2018b), VHF radyo etiketli vahşi yaşamın aranması ve konumlandırılması amacıyla otonom İHA tabanlı bir sensör sistemi geliştirmişlerdir. Bu sistem, çoklu sensör veri füzyonu yaklaşımıyla, farklı sensörlerden elde edilen sinyal gücü ve konum verilerini entegre ederek, dinamik ve belirsiz ortamlarda hedeflerin hızlı ve doğru biçimde lokalize edilmesini sağlamaktadır. Bu çalışma, birden fazla yöntemin entegrasyonu ile çoklu hedeflerin eş zamanlı ve enerji açısından verimli biçimde izlenmesine olanak tanımıştır.

Van Nguyen *et al.* (2020) ise, LAVAPilot adını verdikleri hafif İHA yörünge planlayıcısını geliştirerek, gömülü otonomiye sahip sistemlerde durumsal farkındalık, radyo etiketlerini takip etme ve konumlandırma süreçlerini optimize etmişlerdir. Bu çalışma, gerçek zamanlı sensör verilerinin işlenmesiyle İHA'ların çevresel koşullara adaptasyonunu ve hedeflerin hassas lokalizasyonunu mümkün kılan gelişmiş algoritmaların uygulanabilirliğini göstermektedir. Özellikle, çoklu sensör veri füzyonunun, otonom sistemlerin karar verme ve hareket planlama süreçlerinde doğruluk ve etkinliği artırdığı vurgulanmıştır.

Bu çalışmalar, kooperatif aktif yerelleştirme ve çoklu sensör veri füzyonunun, otonom İHA sistemlerinde hedef takibi, çevresel algı ve operasyonel verimlilik açısından temel bir rol oynadığını açıkça ortaya koymaktadır.

Çarpışma önleme algoritmaları ve güvenlik mekanizmaları

Sieber *et al.* (2024), otonom İHA'ların operasyonunu güvenli bir biçimde sağlaması amacıyla kural tabanlı doğrulama yöntemlerinin geliştirilmesine odaklanmıştır. Bu kapsamda,

İHA’larda kullanılan güvenlik algoritmalarının sistematik olarak doğrulanması ve mevcut güvenlik standartlarıyla uyumunun değerlendirilmesi amaçlanmıştır. Bu çalışmada, çarpışma önleme mekanizmalarının doğruluk, güvenilirlik ve operasyonel süreklilik açısından kritik rol oynadığı vurgulanmış; kural tabanlı doğrulama süreçlerinin, güvenlik algoritmalarının etkinliğini artırmada temel bir unsur olduğu ortaya konmuştur.

Cliff *et al.* (2015) ise, radyo etiketli vahşi yaşamın izlenmesi amacıyla geliştirilen otonom hava robot sistemlerinde çevrimiçi lokalizasyon süreçlerine odaklanmıştır. Çalışmada, çoklu İHA’ların koordineli biçimde çalışmasını sağlayan güvenli operasyon protokolleri geliştirilmiş ve uygulamalı olarak test edilmiştir. Söz konusu protokoller, çarpışma önleme algoritmalarının yanı sıra, dinamik ve belirsiz ortamlarda güvenli uçuşun sağlanmasına yönelik bütüncül güvenlik mekanizmalarını kapsamaktadır. Araştırma bulguları, operasyonel güvenliğin artırılması ve çarpışma risklerinin minimize edilmesi açısından bu tür protokollerin etkinliğini açıkça göstermektedir.

Bu çalışmalar, çarpışma önleme algoritmaları ve güvenlik mekanizmalarının, otonom İHA sistemlerinde operasyonel emniyet ve güvenilirlik açısından vazgeçilmez bir rol oynadığını ortaya koymaktadır.

Operasyonel zorluklar ve çözüm yaklaşımları

Cliff *et al.* (2018), robotik ekoloji alanında küçük ve dinamik hayvanların otonom hava araçlarıyla takibine yönelik geliştirdikleri sistemde, operasyonel süreçte karşılaşılan zorlukları ve bu zorlukların üstesinden gelmek için uygulanan stratejileri kapsamlı şekilde incelemişlerdir. Araştırmada, hedeflerin hızlı ve öngörülemez hareketleri, sinyal kaybı, çevresel belirsizlikler ve enerji kısıtları gibi temel operasyonel sorunların, sistem performansını doğrudan etkilediği vurgulanmıştır. Bu zorlukların aşılması için, gerçek zamanlı veri işleme, adaptif takip algoritmaları, çoklu sensör füzyonu ve enerji yönetimi gibi yenilikçi çözüm yaklaşımları geliştirilmiş; böylece, izleme doğruluğu ve operasyonel süreklilik anlamlı şekilde artırılmıştır.

Tang *et al.* (2020) ise, silah bırakma kısıtlamalarına sahip otonom SİHA için vaka tabanlı çevrimiçi yörünge planlama yöntemi geliştirmişlerdir. Çalışmada, operasyonel ortamda karşılaşılan karmaşık kısıtların (örneğin görev öncelikleri, güvenlik bölgeleri, dinamik hedefler ve silah bırakma gereksinimleri) yönetimi için esnek ve hesaplaması hızlı algoritmalar önerilmiştir. Bu yöntem, çevrimiçi karar verme süreçlerinde operasyonel kısıtların etkin biçimde dikkate alınmasını ve görev başarısının artırılmasını sağlamıştır. Araştırma, gerçek zamanlı uyarlanabilir planlama ve çok kriterli optimizasyonun, karmaşık operasyonel gereksinimlerin yönetiminde kritik rol oynadığını ortaya koymaktadır.

Literatürde Öne Çıkan Çalışmaların Karşılaştırmalı Analizi

Bu bölümde, literatürdeki önemli çalışmaların yöntem ve bulgularının sistematik değerlendirmesi yapılmaktadır. Ayrıca, mevcut araştırma boşlukları belirlenerek bu çalışmanın literatüre beklenen katkıları ortaya konulmaktadır.

Literatürdeki önemli çalışmaların yöntem ve bulgularının değerlendirilmesi

Literatür taraması sonucunda, OHKA'ların lojistik planlamasında DL uygulamaları konusunda çeşitli yaklaşımların benimsendiği görülmektedir. Toorajipour *et al.* (2021), sistematik literatür taraması yaklaşımı kullanarak tedarik zinciri yönetiminde yapay zekâ uygulamalarını incelemişler ve 122 makaleyi analiz etmişlerdir.

DL yöntemleri açısından, Yang and Guan (2023) ile Yu *et al.* (2024) DRL tabanlı rota optimizasyonu yaklaşımları geliştirmişlerdir. Bu çalışmalar, geleneksel optimizasyon yöntemlerine kıyasla %15-20 oranında performans iyileştirmesi sağlamışlardır.

Enerji optimizasyonu alanında, Salip *et al.* (2023) yapay arı kolonisi algoritmasını kullanarak %12 enerji tasarrufu elde etmişlerdir. Mamede *et al.* (2023) ise LSTM tabanlı talep tahmini modelleriyle %85 doğruluk oranına ulaşmışlardır.

Çoklu drone koordinasyonu konusunda, Bayram *et al.* (2017) ve Zhu *et al.* (2023) tarafından yapılan çalışmalar, koordinasyon algoritmalarının operasyonel verimliliği %25-30 oranında artırdığını göstermiştir.

Bu çalışmanın literatüre beklenen katkıları ve yenilikleri

Bu tez çalışması, literatürdeki mevcut çalışmaları bütünleştiren kapsamlı bir yaklaşım sunmaktadır. Özellikle, DL yöntemlerinin OHKA'ların lojistik planlamasında sistematik olarak uygulanması konusunda yenilikçi bir yapısal çerçeve önerilmektedir. Tablo 1'de taranan literatürde kullanılan DL yöntemleri gösterilmiştir. Tablo 2'de ise lojistik açıdan taranan çalışmaların tematik konulara göre sınıflandırılması gösterilmiştir.

Tablo 1. Taranan Literatürde Kullanılan DL Yöntemleri

[illegible]

Tablo 1. Taranan Literatürde Kullanılan DL Yöntemleri (devamı)

	DNN	CNN	DRL	RNN	LSTM	ANN	GRU	GAN	DBN	RBM	TRAN	SA	FWNN
(Deng and Liu, 2021)				✓	✓								
(Vishal Sharma et al., 2024)				✓									
(Chen et al., 2024)			✓										
(Han et al., 2023)			✓										
(Riahi et al., 2021)						✓							
(Arshad, 2020)	✓					✓							
(Helo and Hao, 2022)	✓												✓
(Ganesh and Kalpana, 2022)				✓		✓							
(W. Wang et al., 2023)			✓										
(Hu et al., 2020)						✓							
(Chatterjee et al., 2023)	✓												
(Baryannis et al., 2019a)						✓							
(Liu et al., 2020)			✓										
(Bijjahalli et al., 2020)		✓		✓		✓							
(Pillai and Tedesco, 2023)	✓												
(Blöthner and Larch, 2022)						✓							
(Bai et al., 2022)	✓											✓	
(Sangeetha et al., 2021)		✓				✓							
(Lang et al., 2019)						✓							
(Wang et al., 2022)						✓							

Tablo 2. Lojistik Açıdan Taranan Çalışmaların Tematik Konulara Göre Sınıflandırılması

Makale	Sürdürülebilirlik ve Yeşil Lojistik	Teknolojik Yenilikler ve Dijitalleşme	Tedarik Zinciri Entegrasyonu	Maliyet Optimizasyonu	Kalite Yönetimi ve Standartlar	İnsan Kaynakları ve Eğitim
(Murray and Chu, 2015)	✓	✓	✓	✓		
(Dash et al., 2019)		✓	✓			✓
(Dubey et al., 2020)	✓	✓	✓			
(Salip et al., 2023)	✓	✓		✓		
(Kaspi et al., 2022)	✓	✓	✓	✓	✓	
(Singh et al., 2023)		✓				
(Sonaria and Jenie, 2024)		✓		✓		
(ElSayed and Mohamed, 2024)	✓	✓	✓	✓		
(Sigari and Biberthaler, 2021)	✓	✓	✓	✓		
(Gajana, 2024)	✓	✓				
(Yang and Guan, 2023)		✓		✓		
(Jiang, 2022)		✓		✓		
(Waikar et al., 2023)		✓		✓		
(Deng and Liu, 2021)		✓		✓		
(Sharma et al., 2024)	✓	✓	✓	✓		
(Chen et al., 2024)		✓		✓		
(Cavalcante et al., 2019)		✓	✓			
(Helo and Hao, 2022)		✓	✓	✓		
(Limbourg et al., 2012)	✓	✓		✓		
(Zhu et al., 2023)	✓	✓				
(Tao et al., 2021)		✓		✓		
(Dora et al., 2022)	✓	✓				
(Sharifmousavi et al., 2024)		✓	✓	✓	✓	

Tablo 2. Lojistik Açından Taranan Çalışmaların Tematik Konulara Göre Sınıflandırılması (devamı)

Makale	Sürdürülebilirlik ve Yeşil Lojistik	Teknolojik Yenilikler ve Dijitalleşme	Tedarik Zinciri Entegrasyonu	Maliyet Optimizasyonu	Kalite Yönetimi ve Standartlar	İnsan Kaynakları ve Eğitim
(W.-C. Hu et al., 2020)	✓	✓				
(Soltani, 2021)		✓		✓	✓	✓
(Jedermann and Lang, 2008)		✓		✓	✓	
(Sharma et al., 2022)	✓	✓	✓			
(Liu et al., 2020)		✓				
(Bai et al., 2022)	✓	✓				✓
(Lang et al., 2019)		✓				
(Zhou et al., 2003)				✓		
(Kaur, 2021)						✓
(Liu, 2022)	✓	✓				
(Belhadi et al., 2024)		✓	✓			
(Belhadi et al., 2022)		✓	✓			
(You, 2022)		✓				✓
(Zhu, 2020)	✓	✓			✓	
(Raja Santhi and Muthuswamy, 2022)		✓	✓	✓	✓	
(Rodríguez-Espíndola et al., 2020)		✓	✓	✓	✓	
(Spandonidis et al., 2022)	✓	✓	✓	✓	✓	
(Gunasekaran and Ngai, 2014)		✓	✓	✓	✓	✓

Çalışmanın temel katkıları şunlardır:

- Hibrit optimizasyon yaklaşımlarının geliştirilmesi: Geleneksel optimizasyon yöntemleri ile DL tekniklerinin entegrasyonu yoluyla daha etkili çözümler sunulması planlanmaktadır.
- Çoklu objektif optimizasyon: Enerji verimliliği, maliyet minimizasyonu ve hizmet kalitesi arasındaki dengeyi optimize eden çok boyutlu yaklaşımların geliştirilmesi hedeflenmektedir.
- Gerçek zamanlı adaptasyon: Dinamik operasyonel koşullara uyum sağlayabilen öğrenme algoritmalarının geliştirilmesi öngörülmektedir.
- Ölçeklenebilir sistemler: Küçük ölçekli operasyonlardan büyük ölçekli lojistik ağlarına kadar uygulanabilen sistemlerin tasarlanması planlanmaktadır.

Literatürdeki boşlukların ve araştırma ihtiyaçlarının tanımlanması:

Literatür analizi sonucunda, aşağıdaki araştırma boşlukları tespit edilmiştir:

1. Entegre sistem yaklaşımlarının eksikliği: Mevcut çalışmalar genellikle tekil problemlere odaklanmakta, bütüncül sistem perspektifi sunmamaktadır. Sharma *et al.* (2022), tedarik zinciri yönetiminde yapay zekânın rolünü haritalamışlar ancak otonom hava araçlarıyla entegrasyon konusunda sınırlı çalışma olduğunu belirtmişlerdir.
2. Gerçek dünya uygulamalarının yetersizliği: Çoğu çalışma simülasyon ortamlarında yapılmış olup, gerçek operasyonel koşullardaki performans değerlendirmeleri sınırlıdır. Cliff *et al.* (2018) tarafından yapılan saha çalışmaları bu konudaki nadir örneklerden biridir.
3. Çevresel faktörlerin modellenmesindeki eksiklikler: Hava durumu, trafik yoğunluğu ve dinamik engellerin DL modellerine entegrasyonu konusunda yetersizlikler bulunmaktadır.
4. Ölçeklenebilirlik sorunları: Mevcut algoritmaların büyük ölçekli lojistik ağlarındaki performansı konusunda sınırlı bilgi mevcuttur. Yu *et al.* (2024) tarafından çoklu ajan yaklaşımları önerilmiş, ancak gerçek dünya ölçeklenebilirlik testleri yapılmamıştır.
5. Güvenlik ve güvenilirlik standartları: OHKA sistemlerinin operasyonel güvenliği konusunda standartlaşmış değerlendirme metrikleri eksiktir. Sieber *et al.* (2024) tarafından kural tabanlı doğrulama yaklaşımları önerilmiş, ancak kapsamlı güvenlik çerçeveleri geliştirilmemiştir.

6. Ekonomik uygulanabilirlik analizleri: DL tabanlı sistemlerin fayda-maliyet analizleri ve yatırım getirisi (YG) deęerlendirmeleri konusunda yeterli araştırma bulunmamaktadır.

Bu boşluklar, gelecekteki araştırma projelerinin yönlendirilmesinde ve bu çalışmanın hedeflerinin belirlenmesinde önemli rehberlik sağlamaktadır. Özellikle, entegre sistem yaklaşımları, gerçek dünya uygulamaları ve ölçeklenebilirlik konularında yapılacak araştırmalar, alanın gelişimine önemli katkılar sunacaktır.

Bu tez çalışmasında yapılan kapsamlı literatür taraması, OHKA'ların DL yöntemleriyle lojistik planlaması alanındaki durumunu sistematik bir şekilde ortaya koymuştur. Drone teknolojilerinin gelişiminden başlayarak, yapay zekâ uygulamaları, DL teknikleri, rota optimizasyonu, enerji yönetimi, hava durumu tahmini ve çoklu drone koordinasyonu konularında yapılan çalışmalar detaylı olarak incelenmiştir.

Elde edilen bulgular, bu alandaki teknolojik gelişmelerin sürdürülebilir ve verimli bir lojistik ekosistemi yaratmada oynayacağı kilit rolü pekiştirmektedir. Özellikle, DL yöntemlerinin geleneksel optimizasyon teknikleriyle entegrasyonunun, operasyonel verimlilikte önemli iyileştirmeler sağladığı görülmektedir.

Tespit edilen araştırma boşlukları ve gelecekteki çalışma yönleri, alanın gelişimi için önemli fırsatlar sunmaktadır. Bu sistematik literatür taraması, gelecekteki araştırma ve uygulama çalışmalarına yön vermek için önemli bir kaynak oluşturmaktadır.

MATERYAL ve METOT

Bu bölümde, OHKA'ların DL yöntemleriyle lojistik planlaması uygulanmasına yönelik olarak yürütülen araştırmanın metodolojik altyapısı ayrıntılı biçimde sunulmaktadır. Çalışmanın kapsamı;

- Araştırma tasarımı,
- Kullanılan materyaller,
- Veri ön işleme ve özellik çıkarımı yöntemleri,
- DL modellerinin tasarımı ve uygulanması,
- Deneysel tasarım ve performans analiz yöntemleri

başlıkları altında bütüncül bir çerçevede ele alınmıştır. Araştırma hem kuramsal hem de uygulamalı analizleri bütünleştiren çok modüllü ve disiplinlerarası bir yaklaşım ile gerçekleştirilmiştir.

Çalışmada, saha verilerinin toplanmasından yüksek performanslı hesaplama altyapısının kullanılmasına, Python tabanlı programlama ortamlarından ileri düzey DL kütüphanelerine kadar geniş bir teknik bileşen seti bütünsel olarak yapılandırılmıştır. Yöntemsel süreçlerin şeffaflığı ve tekrarlanabilirliğinin sağlanabilmesi amacıyla akış diyagramları ve çeşitli görsel analiz araçlarından yararlanılmıştır. Ayrıca, model doğrulama, performans değerlendirme ve etik uyum süreçlerine ilişkin uluslararası standartlar göz önünde bulundurularak, izlenen metodolojinin bilimsellik ve tekrarlanabilirlik ilkelerine uygunluğu garanti altına alınmıştır.

Araştırmanın temel amacı, OHKA'larda DL yöntemlerinin lojistik planlama süreçlerine entegrasyonunun, sistem performansına ve operasyonel verimliliğe etkilerini çok modüllü, sistematik ve deneysel bir yaklaşımla analiz etmektir. Bu doğrultuda hem teorik altyapı hem de uygulamalı analizler dikkate alınarak klasik lojistik optimizasyon modelleri, çağdaş veri bilimi yaklaşımları ve güncel DL algoritmaları bütünleştirici bir metodoloji çerçevesinde bir araya getirilmiştir. Araştırmanın ilk aşamasında, sistem gereksinimleri ve problem alanı çok boyutlu veri ve süreç analizi ile kapsamlı biçimde tanımlanmış; literatür taraması, mevcut teknolojilerin yetenekleri ve kısıtları, lojistik operasyon süreç haritaları ve paydaş analizi ile desteklenmiştir.

Takip eden aşamalarda, DL modellerinin karmaşık lojistik süreçlere adaptasyonu hem teorik modelleme hem de prototip geliştirme yaklaşımlarıyla irdelenmiştir. Araştırma, deneysel tasarım ilkelerine uygun biçimde; saha verilerinin, telemetri ve coğrafi bilgi sistemleri (CBS)

verilerinin ve meteorolojik parametrelerin gerçek zamanlı olarak entegre edildiği bir platformda yürütülmüştür. Modüler yazılım mimarisi sayesinde, kullanıcı yönetimi, filo yönetimi, teslimat optimizasyonu, hava durumu tahmini ve otonom uçuş sistemleri gibi temel işlevler birbirinden bağımsız modüller olarak modellenmiş ve sonucunda bütünlük bir analiz ve kontrol platformu olarak entegre edilmiştir.

Bu bölüm, tezin yöntemsel altyapısını, disiplinlerarası bilimsel yaklaşımını ve özgün katkılarını özetlemektedir. İlerleyen alt başlıklarda ise, her bir metodun, sistem bileşeninin ve analiz sürecinin detayları sistematik ve tekrarlanabilir bir yapıda sunulacaktır. Böylece, araştırmanın bilimsel bütünlüğü ve metodolojik şeffaflığı en üst düzeyde sağlanmış olacaktır.

Araştırma Tasarımı

Bu bölümde, tez kapsamında geliştirilen araştırma tasarımının temel unsurları açıklanmaktadır. Araştırmada, teorik altyapının oluşturulması, modelleme süreçleri ve uygulamalı analizlerin entegrasyonunu esas alarak disiplinlerarası, modüler ve karmaşık bir metodoloji benimsenmiştir.

Araştırmanın temel yaklaşımı, DL yöntemlerinin çok boyutlu entegrasyonu üzerine kuruludur. Bu kapsamda hem nitel hem de nicel veri analizi tekniklerinden faydalanılmış, seçilen veri setleri analiz gereksinimleri doğrultusunda titizlikle belirlenmiş ve veri kalitesini garanti altına almak için kapsamlı ön işleme prosedürleri uygulanmıştır.

Araştırma süreci aşağıdaki temel aşamalardan oluşmaktadır:

1. Teorik çerçevenin oluşturulması aşamasında literatür taraması ile lojistik optimizasyon modelleri, veri bilimi yöntemleri ve güncel DL algoritmaları sistematik biçimde incelenmiş ve entegre edilmiştir.
2. Veri tabanlı modelleme sürecinde, saha verileri ve sistem gereksinimleri doğrultusunda modeller geliştirilmiş ve analiz edilmiştir.
3. Modüler sistem geliştirme aşamasında, her modül bağımsız olarak tasarlanıp geliştirilmiş, ardından entegrasyon ile sistem bütünlüğü sağlanmıştır.
4. Model doğrulama ve performans analizinde ise geliştirilen modeller ayrıntılı testlerden geçirilmiş ve elde edilen bulgular kapsamlı şekilde raporlanmıştır.

Literatür ve problem tanımı

Araştırmanın başlangıcında, klasik lojistik optimizasyon modelleri, veri bilimi yöntemleri ve DL algoritmalarını kapsayan geniş bir literatür taraması gerçekleştirilmiştir. Bu kapsamda en az 12 kitap ve 80 makale analiz edilmiş ve tematik olarak sınıflandırılmıştır. Bu

analizlerin sonucunda lojistik planlamadaki temel sorunlar, sistem gereksinimleri ve operasyonel kısıtlar detaylı olarak belirlenmiştir.

Modelleme ve uygulama

DL yöntemlerinin lojistik süreçlere entegrasyonu için çeşitli modeller incelenmiş ve uyarlanmıştır. Özellikle güncel DL algoritmaları, teorik olarak modellenmiş ve prototip uygulamalar ile test edilmiştir. Veri toplama ve entegrasyon süreçlerinde ise drone telemetri, CBS, meteorolojik ve operasyonel teslimat verileri kullanılarak zaman serisi analizleri ve çok kaynaklı veri füzyon yöntemleri uygulanmıştır. Gerçek dünya koşullarını simüle etmek amacıyla, çalışmalar Giresun ili ve ilçeleri özelinde gerçekleştirilmiştir. Yazılım mimarisi, Python programlama dili kullanılarak TensorFlow, Keras ve PyTorch gibi gelişmiş DL çerçeveleri ile geliştirilmiştir. Veri analizi ve görselleştirme süreçleri de ileri düzey Python kütüphaneleri ile desteklenmiştir.

Deneysel tasarım ve performans analizi

Model eğitimi, doğrulama ve test süreçleri için ayrı veri kümeleri oluşturulmuştur. Bu aşamalarda doğruluk, hassasiyet, F1 skoru, ortalama mutlak hata (mean absolute error, MAE), ortalama karesel hata (mean squared error, MSE) ve kök ortalama karesel hata (root mean squared error, RMSE) gibi performans metrikleri kullanılmıştır. Modellerin genelleme yeteneklerini test etmek için çapraz doğrulama ve istatistiksel anlamlılık testleri uygulanmıştır. Araştırmanın deneysel tasarımında, Taguchi L54 deney planı seçilerek, farklı çevresel ve operasyonel koşulları içeren senaryo kombinasyonları oluşturulmuştur. Her bir senaryoda performans, güvenilirlik ve ekonomik faydalar detaylı bir şekilde analiz edilmiştir. Sonuçlar, grafikler, tablolar ve interaktif görseller aracılığıyla ayrıntılı biçimde sunulmuştur.

Hipotezler ve varsayımlar

Araştırmada esas alınan temel hipotezler şunlardır:

1. H1: DL tabanlı rota optimizasyonu, geleneksel yöntemlere göre teslimat süresi ve maliyetlerde anlamlı iyileşmeler sağlar.
2. H2: OHKA'larda kullanılan DL modelleri, enerji verimliliği ve çevresel sürdürülebilirliği artırır.
3. H3: Çoklu veri kaynağı entegrasyonu, teslimat doğruluğunu ve operasyonel risk yönetimi performansını önemli ölçüde geliştirir.
4. H4: Federatif öğrenme (federated learning, FL) ve modüler DL yaklaşımları, veri gizliliğini ve modelin genelleme yeteneğini artırır.

5. H5: Dinamik çevresel koşullara adaptasyon sağlayan DL tabanlı sistemler, teslimat güvenilirliğini ve operasyonel başarıyı yükseltir.

Araştırmada esas alınan temel varsayımlar şunlardır:

1. Kullanılan veri setleri doğru ve eksiksizdir.
2. Drone filosunun teknik özellikleri endüstriyel standartlara uygundur.
3. Hesaplama altyapısı ve yazılım kütüphaneleri yüksek performansa sahiptir.
4. Kullanılan performans karakteristikleri, literatürde kabul görmüş standartlardır.
5. Senaryo ve deneysel tasarımda ele alınan faktörler, gerçek operasyonların çeşitliliğini yansıtmaktadır.
6. Veri güvenliği ve etik standartlara tam olarak uyulmaktadır.

Bu araştırma tasarımı, günümüz lojistik sistemlerinin karmaşık yapısına uygun, tekrarlanabilir ve ölçeklenebilir bir altyapı sunarak, DL tabanlı otonom hava kargo sistemlerinin pratikteki uygulanabilirliğini nesnel biçimde değerlendirmektedir.

Sistem yaklaşımı ve modüler mimari

Sistem yaklaşımı

OHKA'larda DL tabanlı lojistik planlama amacıyla geliştirilen sistem yaklaşımı, çok katmanlı ve modüler bir mimari yapıya dayanmaktadır. Bu mimari, karmaşık lojistik süreçlerin yönetiminde hem esneklik hem de ölçeklenebilirlik sunmaktadır.


Sistem veri toplama, ön işleme, modelleme, karar destek ve operasyonel uygulama katmanlarından oluşmaktadır. Her bir katman, özgün bir işlevi yerine getirmekte olup, diğer katmanlarla standart arayüzler aracılığıyla iletişim kurmaktadır. Telemetri, CBS, meteorolojik ve operasyonel teslimat verileri gibi çoklu veri kaynakları sisteme entegre edilmiştir. Bu entegrasyon hem gerçek zamanlı hem de geçmişe yönelik analizlerin gerçekleştirilmesini mümkün kılmaktadır. Sistem çevresel değişkenler ve operasyonel koşullara bağlı olarak dinamik biçimde kendini uyarlayabilmektedir. Bu özelliği sayesinde, hava koşulları, enerji durumu ve teslimat yoğunluğu gibi faktörlere göre rota ve görev planlaması optimize edilmektedir.

Modüler mimari

Modüler mimari, sistemin her bir bileşeninin bağımsız şekilde geliştirilmesini, test edilmesini ve güncellenmesini mümkün kılmaktadır. Bu yapı, sistemin sürdürülebilirliğini ve genişletilebilirliğini artırmaktadır.


Ana modüller:

1. Kullanıcı ve görev yönetimi modülü, operatörler ile görevlerin merkezi bir biçimde yönetilmesini sağlamaktadır. Modül 1'in akış diyagramı boyutunun geniş olması nedeniyle, Şekil 3'te gösterilen sırayla parçalara ayrılmış ve detaylı olarak Ek-1 ve Ek-2'de sunulmuştur.



Şekil 3. Modül 1'in parçalanmış gösterimi.


2. Filo ve araç yönetimi modülü, drone filosunun durumu, bakım planları ve operasyonel verimliliğinin izlenmesini mümkün kılmaktadır. Modül 2'nin akış diyagramı boyutunun geniş olması nedeniyle, Şekil 4'te gösterilen sırayla parçalara



ayrılmış ve detaylı olarak Ek-3 ve Ek-4'te sunulmuştur.


Şekil 4. Modül 2'nin parçalanmış gösterimi.

3. Veri toplama ve işleme modülü, ham verilerin toplanması, temizlenmesi, normalizasyonu ve özellik mühendisliği süreçlerini kapsamaktadır. Bu süreçte Min-Max normalizasyonu, Z-skor standardizasyonu ve robust ölçekleme gibi teknikler kullanılmıştır. Modül 3'ün akış diyagramı boyutunun geniş olması nedeniyle, Şekil 5'te gösterilen sırayla parçalara ayrılmış ve detaylı olarak Ek-5 ve Ek-6'da sunulmuştur.




Şekil 5. Modül 3'in parçalanmış gösterimi.

4. DL modelleme modülünde, ileri düzey DL algoritmaları uygulanmakta ve performans değerlendirmeleri gerçekleştirilmektedir. Modül 4'ün akış diyagramı boyutunun geniş olması nedeniyle, Şekil 6'da gösterilen sırayla parçalara ayrılmış ve detaylı olarak Ek-7 ve Ek-8'da sunulmuştur.




Şekil 6. Modül 4'ün parçalanmış gösterimi.

5. Karar destek ve optimizasyon modülü, rota planlaması, enerji yönetimi ve teslimat optimizasyonuna yönelik karar destek algoritmalarını içermektedir. Modül 5'in akış diyagramı boyutunun geniş olması nedeniyle, Şekil 7'de gösterilen sırayla parçalara ayrılmış ve detaylı olarak Ek-9, Ek-10 ve Ek-11'de sunulmuştur.



Şekil 7. Modül 5'in parçalanmış gösterimi.

6. Görselleştirme ve raporlama modülü, sistem çıktılarının grafikler, tablolar ve etkileşimli görseller aracılığıyla sunulmasını sağlamaktadır. Ana Modül'ün akış diyagramı boyutunun geniş olması nedeniyle, Şekil 8'de gösterilen sırayla parçalara ayrılmış ve detaylı olarak Ek-12 ve Ek-13'te sunulmuştur.



Şekil 8. Ana Modül'ün parçalanmış gösterimi.

Her modül, bağımsız olarak çalışabilmekte ve gerektiğinde diğer modüllerle entegre edilerek bütüncül bir analiz ve operasyon platformu oluşturulabilmektedir. Modüller, yeni algoritmaların ya da donanım bileşenlerinin sisteme kolaylıkla entegre edilmesine imkân tanımakta, böylece sistem teknolojik gelişmelere ve değişen operasyonel gereksinimlere hızlı biçimde uyum sağlayabilmektedir.

Farklı kaynaklardan elde edilen verilerin tek bir mimari içerisinde dengeli bir biçimde temsil edilmesi sağlanmıştır; bu durum, modelin genellenebilirliğini ve saha uygulamalarındaki pratik geçerliliğini artırmaktadır. Modüler tasarım, sistem güncellemeleri, hata ayıklama ve yeni işlevlerin entegrasyonu süreçlerinde önemli kolaylıklar sağlamaktadır. Ayrıca, modüler yapı sayesinde model çıktıları üzerinde ayrıntılı analizlerin gerçekleştirilmesi mümkün olmakta; açıklanabilir yapay zekâ teknikleriyle karar destek süreçlerinin etkinliği artırılmaktadır.

Bu sistem yaklaşımı ve modüler mimari, OHKA'ların lojistik planlamasında yüksek doğruluk, esneklik ve operasyonel verimlilik sağlamaktadır. Sistem, gerçek zamanlı karar desteği, enerji optimizasyonu ve teslimat güvenilirliği açısından sektöre yenilikçi bir çözüm sunmaktadır.

Karma araştırma yöntemi ve senaryo bazlı analiz

Karma araştırma yöntemi

Karma araştırma yöntemi hem nicel hem de nitel veri toplama ve analiz tekniklerinin tek bir çalışmada bütünleştirilmesini temel almaktadır. Bu yaklaşım, araştırma problemlerinin daha derinlemesine ve çok boyutlu biçimde anlaşılmasını sağlamaktadır. Özellikle karmaşık sistemlerin ve çok boyutlu süreçlerin incelenmesinde, yalnızca nicel ya da nitel yöntemlerin sınırlılıklarını aşmak amacıyla tercih edilmektedir.

Nicel yöntem kapsamında, sayısal veriler üzerinden istatistiksel analizler gerçekleştirilmekte; model performansı ile sistem çıktıları nesnel olarak değerlendirilmektedir.

Nitel yöntem ise, katılımcı gözlemleri, uzman görüşleri, süreç analizleri ve doküman incelemeleri aracılığıyla derinlemesine bilgi elde edilmesini sağlamaktadır.

Bu iki yöntemin entegrasyonu ile elde edilen nicel bulgular, nitel analizlerle desteklenmekte; böylece sonuçların geçerliliği ve güvenilirliği artırılmaktadır.

Karma yöntemle yürütülen araştırmalarda, veri toplama ve analiz süreçleri genellikle sıralı (önce nicel-sonra nitel ya da tersi) ya da eşzamanlı biçimde tasarlanmaktadır. Bu sayede araştırma sorularına hem doğrulayıcı hem de keşfedici yöntemlerle yaklaşılabilmektedir.

Senaryo bazlı analiz

Senaryo bazlı analiz, sistemin farklı koşullar altında nasıl bir performans sergilediğinin değerlendirilmesi amacıyla çeşitli senaryoların oluşturulması ve test edilmesi sürecine dayanmaktadır. Özellikle OHKA'larda DL tabanlı lojistik planlama uygulamalarında bu yaklaşım, aşağıdaki avantajları sağlamaktadır:

Farklı çevresel, operasyonel ve teknolojik koşullara göre senaryoların geliştirildiği çoklu senaryo tasarımı gerçekleştirilmekte; örneğin hava durumu değişimleri, filo büyüklüğü ve teslimat yoğunluğu gibi parametreler dikkate alınmaktadır. Her bir senaryoda, DL modellerinin doğruluk, güvenilirlik, enerji verimliliği ve teslimat süresi gibi performans karakteristikleri analiz edilmektedir. Senaryo sonuçları, rota optimizasyonu, enerji yönetimi ve risk analizi gibi karar destek süreçlerine girdi sağlayarak karar mekanizmalarının etkinliğini artırmaktadır. Senaryo bazlı testler, sistemin gerçek dünya koşullarına adaptasyon yeteneğini ve genel geçerliliğini güçlendirmektedir.

Senaryo bazlı analiz sürecinde, genellikle aşağıdaki adımlar izlenmektedir:

1. Senaryo Tanımlama: Araştırma hedefleri doğrultusunda sistemin karşılaşılabileceği çeşitli durumlar belirlenmektedir.

2. Veri Toplama ve Modelleme: Her bir senaryo için gerekli veri setleri hazırlanmakta ve DL modelleri eğitilmektedir.
3. Simülasyon ve Test: Eğitilen modeller her bir senaryo kapsamında çalıştırılmakta ve elde edilen çıktılar kaydedilmektedir.
4. Karşılaştırmalı Analiz: Farklı senaryolardan elde edilen sonuçlar karşılaştırılarak en verimli ve güvenilir stratejiler tespit edilmektedir.

Karma araştırma yöntemi ile desteklenen senaryo bazlı analiz yaklaşımı, OHKA sistemlerinin hem teknik hem de operasyonel yönleriyle bütüncül değerlendirilmesini mümkün kılmakta; sistemin dinamik çevresel koşullara ve operasyonel değişkenliğe uyum sağlama kapasitesini bilimsel temelde ortaya koymaktadır.

Kullanılan Materyaller

Bu bölümde, tez kapsamında gerçekleştirilen araştırmada kullanılan temel materyallerin genel çerçevesi sunulmaktadır. Araştırmanın başarısı hem donanım hem de yazılım altyapısının bütüncül ve entegre bir biçimde yapılandırılmasıyla mümkün olmuştur. Kullanılan materyaller; donanım altyapısı, veri kaynakları ve yazılım altyapısı olmak üzere üç ana başlık altında sınıflandırılmıştır.

Donanım altyapısı kapsamında, araştırmada kullanılan drone filosu, yer kontrol istasyonu, sensörler, telemetri sistemleri ve haberleşme altyapısı ayrıntılı biçimde yapılandırılmıştır.

Veri kaynakları başlığı altında, lojistik planlama ve DL modellerinin eğitimi amacıyla çeşitli veri türleri kullanılmıştır. Telemetri verileri, CBS verileri, meteorolojik veriler ve operasyonel teslimat verileri, sistemin gerçek dünya koşullarındaki performansının değerlendirilmesi amacıyla entegre edilmiştir.

Yazılım altyapısı ise veri işleme, modelleme, simülasyon ve görselleştirme süreçlerinde kullanılan gelişmiş yazılım araçları ve programlama ortamlarını kapsamaktadır. Python programlama dili, DL çerçeveleri (TensorFlow, Keras, PyTorch), simülasyon yazılımları ile veri analiz ve görselleştirme araçları, araştırmanın yazılım altyapısının temel bileşenlerini oluşturmaktadır.

Bu başlıklar altında, her bir materyal grubu ve ilgili alt bileşenler, izleyen alt bölümlerde ayrıntılı biçimde ele alınacak; böylece sistemin bütünsel yapısı ile kullanılan materyallerin bilimsel ve teknik gerekçeleri kapsamlı şekilde açıklanacaktır.

Donanım altyapısı

OHKA’larda DL tabanlı lojistik planlama araştırmasında kullanılan donanım altyapısı, sistemin güvenilirliği, veri toplama kapasitesi ve operasyonel etkinliği açısından kritik bir rol üstlenmektedir. Bu altyapı, farklı işlevlere sahip bileşenlerin bütünleşik ve modüler bir biçimde yapılandırılmasıyla tasarlanmıştır.

Drone filosu, farklı taşıma kapasitelerine ve teknik özelliklere sahip birden fazla İHA modelinden oluşmaktadır. Filoda yer alan drone’lar, rota optimizasyonu, enerji yönetimi ve teslimat simülasyonlarında kullanılmak üzere seçilmiş olup, her biri otonom uçuş, yük taşıma, veri toplama ve gerçek zamanlı iletişim yeteneklerine sahiptir.

Yer kontrol istasyonu, tüm uçuş operasyonlarının merkezi olarak izlenmesi, yönetilmesi ve gerektiğinde müdahale edilmesi amacıyla tasarlanmış bir kontrol merkezidir. Bu istasyon hem manuel hem de otomatik operasyon modlarını desteklemekte ve uçuş güvenliği için gerekli tüm protokolleri içermektedir.

Sensörler ve telemetri sistemleri, drone’lara entegre edilen küresel navigasyon uydu sistemi (global navigation satellite system, GNSS), atalet ölçüm birimi (inertial measurement unit, IMU), barometre, manyetometre, kamera ve ışık algılama ve değişimi (light detection and ranging, LiDAR) gibi sensörlerden oluşmakta; uçuş sırasında konum, hız, irtifa, çevresel koşullar ve engel tespiti gibi verileri toplamaktadır. Telemetri sistemleri sayesinde bu veriler, gerçek zamanlı olarak yer kontrol istasyonuna aktarılmaktadır.

Haberleşme ve veri aktarım altyapısı, drone’lar ile yer kontrol istasyonu arasında kesintisiz ve güvenli iletişim sağlamak amacıyla radyo frekansı (radio frequency, RF), LTE/5G ve Wi-Fi tabanlı haberleşme protokolleri kullanılarak oluşturulmuştur. Ayrıca, veri aktarımı için yüksek bant genişliğine sahip modemler ve yedekli iletişim kanalları sisteme entegre edilmiştir.

Donanım altyapısının temel özellikleri arasında; sistemin farklı ihtiyaçlarına uygun olarak kolayca güncellenebilir ve genişletilebilir bir modülerlik ve esneklik yapısı, tüm uçuş operasyonlarının ve veri akışının gerçek zamanlı olarak izlenebilmesi, kritik görevler için yedekli sistemler ve hata toleranslı donanım mimarisi ile sağlanan yüksek güvenilirlik ve farklı hava koşullarında güvenli ve verimli çalışmayı sağlayan çevresel dayanıklılık yer almaktadır.

Drone filosu ve özellikleri

OHKA’larda kullanılan drone filosu, farklı yük ve menzil kapasitelerine sahip, endüstriyel ve yarı-endüstriyel sınıftaki çeşitli modellerden oluşmaktadır. Filonun tasarımı ve seçimi, operasyonel esneklik, veri toplama kapasitesi ve sistem güvenilirliği gibi temel kriterler doğrultusunda gerçekleştirilmiştir.

Filoda yer alan drone modelleri, 2-15 kg arasında deęişen maksimum kalkış ağırlığı deęerlerine sahiptir; bu durum, farklı kargo tipleri ve teslimat senaryoları için uygun çözüm alternatifleri sunulmasını mümkün kılmaktadır. Drone tiplerinin temel özellikleri ve kullanım alanları Tablo 3'te verilmiştir.

Tek batarya ile 15-80 km arasında operasyonel menzil sağlayan drone modelleri kullanılarak hem kısa mesafeli hem de uzun menzilli teslimat performansı desteklenmiştir.

Tablo 3. Drone Tipleri Temel Özellikleri ve Kullanım Alanları

Drone Tipi	Temel Özellikler	Kullanım Alanı
Quadcopter	Dört motorlu, yüksek manevra kabiliyeti, kısa-orta menzil	Kentsel teslimat, hassas iniş
Sabit Kanatlı	Uzun menzil, yüksek enerji verimlilięi, daha büyük yük kapasitesi	Kırsal ve uzak bölge teslimatı
Hibrit Sistemler	Hem dikey kalkış/iniş hem de uzun menzil uçuş yeteneęi	Zorlu coęrafi koşullar, acil durumlar

Her bir platform küresel konumlandırma sistemi (global positioning system, GPS), barometre, jiroskop, ivmeölçer, manyetometre, LiDAR ve kamera gibi çoklu sensörler ile IMU bileşenlerinin entegrasyonu sayesinde; uçuş sırasında konum, hız, irtifa, çevresel koşullar ve engel tespiti gibi verilerin gerçek zamanlı olarak toplanmasını sağlamaktadır.

Haberleşme altyapısı, LoRa, Wi-Fi ve LTE/5G tabanlı uzaktan veri aktarım sistemleri aracılığıyla uçuş telemetrisi ve kontrolünü mümkün kılmakta; böylece yüksek güvenliklı ve kesintisiz iletişim sağlanmaktadır.

Yer kontrol istasyonu ile gerçek zamanlı ve sürekli veri paylaşımı gerçekleştirilmekte; ayrıca, uçuş sonrası toplu veri yükleme desteęi de sistem içerisinde bulunmaktadır.

Drone platformları, farklı sensörlerin veya yüklerin kolaylıkla entegre edilebileceęi şekilde modüler olarak tasarlanmıştır. Bu modüler mimari, yeni teknolojilerin veya deęişen operasyonel gereksinimlerin hızla sisteme entegre edilmesine olanak tanımaktadır.

Güvenlik ve çevresel dayanıklılık bağlamında, kritik görevler için yedek batarya ve kontrol sistemleri kullanılmış; tüm drone bileşenleri farklı hava koşullarında güvenli biçimde çalışabilecek şekilde test edilmiş ve dayanıklı donanımlar tercih edilmiştir.

Filodaki tüm drone'lar, bakım ve arıza takibine imkân tanıyan merkezi bir sistem aracılığıyla izlenmektedir.

Operasyonel performans açısından, gerçek ve simülasyon tabanlı teslimat senaryolarında ortalama başarı oranı %80 üzerinde ölçülmüştür. Enerji verimliliği, uygulanan 75 senaryoda pozitif olarak değerlendirilmiş; çevresel avantaj ise 80 senaryoda kaydedilmiştir.

Sistem güvenilirliği, ortalama arızalar arası süre (mean time between failures, MTBF) ve ortalama onarım süresi (mean time to repair, MTTR) gibi metrikler üzerinden analiz edilmiştir.

Bu teknik ve operasyonel özellikler doğrultusunda, drone filosu hem gerçek zamanlı veri toplama hem de yüksek doğruluk ve güvenilirlik düzeyinde lojistik operasyonlar için optimize edilmiştir. Filo, çeşitli teslimat senaryolarına uyum sağlayabilecek esnek ve ölçeklenebilir bir mimariye sahiptir.

Yer kontrol istasyonu

Yer kontrol istasyonu, OHKA'ların tüm uçuş operasyonlarının merkezi olarak izlenmesi, yönetilmesi ve gerektiğinde müdahale edilmesi amacıyla tasarlanmış önemli bir bileşendir. Bu istasyon hem manuel hem de otomatik operasyon modlarını destekleyerek uçuş güvenliği ile operasyonel verimliliğin sağlanmasında temel bir rol üstlenmektedir.

Merkezi yönetim işlevi kapsamında, tüm drone filosuna ait uçuş planlaması, görev ataması, rota takibi ve operasyonel durum izleme işlemleri yer kontrol istasyonu üzerinden yürütülmektedir. Gerçek zamanlı izleme özelliği sayesinde uçuş sırasında konum, hız, irtifa, batarya durumu, sensör çıktıları ve telemetri verileri anlık olarak takip edilmekte; bu sayede operasyonel riskler ve olası arızalar erken aşamada tespit edilebilmektedir.

Drone'lar ile yer kontrol istasyonu arasındaki çift yönlü haberleşme RF, LTE/5G ve Wi-Fi tabanlı güvenli iletişim protokolleri aracılığıyla sağlanmakta; böylece komut gönderimi ve veri alımı kesintisiz biçimde gerçekleştirilmektedir.

Yer kontrol istasyonu hem otomatik hem de manuel kontrol imkânı sunmaktadır. Acil durumlarda manuel müdahale yapılabildiği gibi, normal operasyonel koşullarda sistem tamamen otonom olarak işlemekte ve önceden tanımlanmış görevler ve rotalar üzerinden uçuşlar gerçekleştirmektedir.

Tüm uçuş verileri, CSV ve JSON gibi standart formatlarda kayıt altına alınmakta ve operasyon sonrası analiz süreçlerinde kullanılmak üzere arşivlenmektedir. Bu veriler, DL modellerinin eğitimi ve sistem optimizasyonu için temel veri kaynağını oluşturmaktadır. Güvenlik ve yedeklilik kapsamında, kritik görevlerde hata toleranslı sistem tasarımı

benimsenmiş; yedek donanım ve yazılım altyapıları ile acil durum protokolleri entegre edilmiştir.

Donanım bileşenleri arasında yüksek performanslı bilgisayar sistemleri, çoklu monitör konfigürasyonları, yedek güç kaynakları, harici veri depolama birimleri ve güvenli ağ altyapısı yer almaktadır. Yazılım altyapısı ise; uçuş yönetim yazılımları, gerçek zamanlı veri görselleştirme araçları, telemetri analiz modülleri ve karar destek sistemlerini içermekte olup, süreçler Python tabanlı otomasyon ve raporlama scriptleri (belirli bir görevi otomatikleştirmek için yazılmış kısa, bağımsız, genellikle doğrudan çalıştırılabilen bir program dosyası) ile desteklenmektedir.

İstasyonun operasyonel avantajları arasında, aynı anda birden fazla drone'un eş zamanlı olarak yönetilmesi ve izlenmesi, dinamik görev atamaları, anlık rota değişiklikleri ve acil müdahale uygulamaları yer almaktadır. Ayrıca, hava koşulları, engel tespiti ve enerji durumu gibi çevresel ve operasyonel parametreler anlık olarak gözlemlenmekte ve sistemin adaptasyonu bu verilere dayalı biçimde sağlanmaktadır.

Sonuç olarak, yer kontrol istasyonu, OHKA operasyonlarının güvenli, verimli ve izlenebilir şekilde yürütülmesini mümkün kılan; gelişmiş donanım ve yazılım altyapısıyla karmaşık lojistik süreçlerin bütünleşik biçimde yönetilmesini sağlayan merkezî birim olarak işlev görmektedir.

Sensörler ve telemetri sistemleri

OHKA'larda kullanılan sensörler ve telemetri sistemleri, uçuş güvenliği, doğruluk ve operasyonel verimlilik açısından kritik işlevler üstlenmektedir. Bu sistemler, drone'un çevresel algılama yeteneğini, konum belirleme doğruluğunu, uçuş parametrelerinin izlenmesini ve toplanan verilerin gerçek zamanlı olarak yer kontrol istasyonuna iletilmesini sağlamaktadır.

IMU, ivmeölçer ve jiroskop bileşenlerinden oluşmakta olup, drone'un üç eksenindeki hareketleri ile açısal hızını ölçerek uçuş stabilitesine katkı sağlamaktadır (uçuş stabilitesi, bir hava aracının herhangi bir dış etkiyle karşılaştığında, orijinal uçuş konumuna veya dengesine otomatik olarak geri dönebilme eğilimi). Barometre, uçuş sırasında irtifa kontrolü amacıyla kullanılan hava basınç sensörü olup, yüksekliği barometrik ölçümlerle tespit etmektedir. Manyetometre, drone'un yönelimini belirlemekte ve GNSS destekli navigasyon sistemlerinde yönsel doğruluğun artırılmasına destek vermektedir. GNSS, farklı uydu tabanlı sistemler yardımıyla kendisine konum, hız ve irtifa verileri sağlamaktadır. Hassas konumlandırma ve otonom uçuş işlevleri için temel bileşen niteliğindedir. Optik ve akustik sensörler, özellikle ultrasonik ve kızılötesi temelli sistemleri kapsamakta olup, engel tespiti, mesafe ölçümü ve

otomatik kalkış-iniş operasyonlarında kullanılmaktadır. Termal, multispektral ve LiDAR sensörler ise yüksek çözünürlüklü görüntüleme, haritalama, çevresel analiz ve engel algılama işlemleri için entegre edilmiştir. LiDAR, özellikle 3D modelleme ve hassas mesafe ölçüm yetenekleriyle öne çıkmaktadır. ToF sensörleri ışık darbeleri ile mesafe ölçümü yaparak üç boyutlu ortam algısı sunmakta; özellikle depo yönetimi ve hassas kargo taşımacılığı senaryolarında kullanılmaktadır.

Uçuş telemetri sistemleri, drone üzerindeki sensörler ve uçuş kontrol birimlerinden alınan konum, hız, irtifa ve batarya durumu gibi parametreleri gerçek zamanlı olarak yer kontrol istasyonuna iletmektedir. Böylece operatör, tüm kritik uçuş bilgilerini anlık olarak izleyebilmektedir. Çift yönlü veri akışı sayesinde telemetri sistemi hem drone'dan istasyona veri aktarımını hem de istasyondan drone'a komut gönderimini gerçekleştirmektedir. Bu yapı, acil durumlarda manuel müdahale ve görev güncellemelerinin yapılabilmesi açısından önem arz etmektedir. Haberleşme protokolleri RF (433 MHz, 915 MHz), Wi-Fi ve LTE/5G teknolojilerini içermekte; yüksek bant genişliği ile yedekli iletişim kanalları üzerinden kesintisiz veri aktarımı sağlanmaktadır. Birinci şahıs bakış açısı (first person view, FPV), drone kamerasından elde edilen canlı video akışını operatöre ileterek operasyonel farkındalığı artırmakta ve görsel geri bildirim sağlamaktadır. Sensör ve telemetri sistemlerinin entegrasyonunda çoklu sensör füzyonu uygulanmaktadır. IMU, GNSS, barometre, kamera ve LiDAR gibi sensörlerin verileri birleştirilerek daha hassas konumlandırma ve çevresel algı elde edilmektedir. Bu birleşik yapı, özellikle karmaşık lojistik senaryolarında uçuş güvenliğini ve doğruluğunu artırmaktadır. Tüm sensör verileri uçuş sürecinde kaydedilmekte ve operasyon sonrası analiz uygulamaları için saklanmaktadır. Bu kayıtlar, DL model eğitimi, sistem optimizasyonu ve arıza tespiti gibi süreçlerde referans veri kaynağı olarak kullanılmaktadır.

Hassas sensörler ile telemetri entegrasyonu, drone'ların otonom rota planlaması ve engellerden kaçınma kabiliyetini mümkün kılmakta; anlık veri izleme ile yedekli iletişim yapılarına dayalı sistem uçuş güvenliğini ve müdahale yeteneğini artırmaktadır. Ayrıca, yüksek doğruluk düzeyine sahip sensör verileri teslimat süreçlerinin optimizasyonu ve performans analizlerinde güvenilir veri sağlamaktadır.

Haberleşme ve veri aktarım altyapısı

OHKA'larda haberleşme ve veri aktarım altyapısı, sistemin güvenli, kesintisiz ve yüksek doğrulukla çalışabilmesi için temel bir rol üstlenmektedir. Bu altyapı, drone'lar ile yer kontrol istasyonu arasındaki veri akışının sürekliliğini sağlamakta; uçuş güvenliği, operasyonel verimlilik ve gerçek zamanlı izleme gibi temel işlevlerin yerine getirilmesine olanak tanımaktadır.

RF iletişim bileşenleri, 433 MHz, 868 MHz ve 915 MHz gibi endüstri standardı frekanslarda çalışan modemlerle uzun menzilli ve düşük gecikmeli veri aktarımı sunmakta; özellikle açık arazi ve kırsal bölgelerde güvenli iletişim için tercih edilmektedir. LTE/5G mobil ağ teknolojileri, geniş kapsama alanı ve yüksek bant genişliği sayesinde, şehir içi ve uzun mesafeli operasyonlarda kesintisiz veri erişimi sağlamaktadır. Bu ağlar hem telemetri verilerinin hem de canlı video akışının iletimi için kullanılmaktadır. Wi-Fi (2.4 GHz/5 GHz) tabanlı bağlantılar, kısa ve orta mesafeli operasyonlar kapsamında yüksek hızlı veri transferi ihtiyacına yanıt vermekte; özellikle yer kontrol istasyonuna yakın uçuşlarda tercih edilmektedir. Uzun menzilli geniş alan ağı (Long Range Wide Area Network, LoRaWAN) teknolojisi, düşük güç tüketimi ve uzun menzil özellikleri sayesinde, düşük veri hızının yeterli olduğu görevlerde enerji verimliliğini artırmaktadır. Altyapı, çift yönlü ve yedekli iletişim yapısı ile donatılmış olup, drone'lar ile yer kontrol istasyonu arasında hem veri gönderimi hem de komut alımı sağlanmaktadır. Kritik durumlarda, birincil iletişim kanalının devre dışı kalması halinde otomatik olarak yedek kanal devreye girmektedir. Gerçek zamanlı telemetri verilerinin ve FPV video akışlarının aktarımı için yüksek bant genişliği ve düşük gecikme gereksinimi, LTE/5G ile Wi-Fi altyapısı üzerinden karşılanmaktadır. Tüm iletişim kanallarında veri şifreleme, kimlik doğrulama ve erişim kontrolü gibi güvenlik protokolleri uygulanarak, yetkisiz erişim ve veri sızıntısı riskleri minimize edilmektedir. Sistem, ortam koşullarına bağlı olarak en uygun haberleşme kanalını otomatik olarak seçmekte ve gerektiğinde kanallar arası geçiş yapabilmektedir. Bu adaptif yapı, değişken hava koşulları ve yoğun radyo trafiği altında iletişim sürekliliğini desteklemektedir.

Gerçek zamanlı telemetri süreçlerinde, konum, hız, irtifa, batarya seviyesi ve sensör verileri anlık olarak yer kontrol istasyonuna aktarılmakta; bu bilgiler operasyon takibi ve acil müdahale kararlarında kullanılmaktadır. Canlı video ve görüntü aktarımı, FPV ve yüksek çözünürlüklü kamera sistemleri aracılığıyla düşük gecikmeli biçimde sağlanmakta; bu durum operasyonel farkındalığı artırmakta ve teslimat süreçlerinin doğrulanmasına katkı sunmaktadır. Toplu veri yükleme yöntemiyle, uçuş sonrasında elde edilen büyük boyutlu veri setleri (örneğin yüksek çözünürlüklü haritalar veya sensör kayıtları) kablolu veya kablosuz bağlantılar üzerinden merkezi veri tabanına iletilmektedir. Tüm iletişim ve veri aktarım süreçleri, olası veri kayıplarına karşı yedekleme sistemleri ile desteklenmektedir.

Bu altyapının operasyonel avantajları arasında, farklı iletişim teknolojilerinin entegre kullanımı sayesinde her türlü ortamda kesintisiz operasyon sağlanması, sistemin esnek ve ölçeklenebilir yapısı sayesinde yeni teknolojilerin veya ek drone'ların sisteme kolayca entegre

edilebilmesi ve veri güvenliği ile bütünlüğünün şifreleme ve yedekli iletişim yoluyla korunması yer almaktadır.

Söz konusu kapsamlı haberleşme ve veri aktarım altyapısı, OHKA'ların güvenli, verimli ve izlenebilir operasyonlar gerçekleştirmesini mümkün kılmakta; modüler ve yedekli yapısı aracılığıyla sistemin operasyonel ve teknolojik açıdan sürdürülebilirliğine katkı sağlamaktadır.

Veri kaynakları

OHKA'larda DL tabanlı lojistik planlama araştırmasında kullanılan veri kaynakları, sistemin gerçek dünya koşullarında doğru bir şekilde modellenmesi ve performansının objektif olarak değerlendirilebilmesi için önemli bir rol üstlenmektedir. Farklı kaynaklardan elde edilen veri tipleri hem model eğitimi hem de operasyonel analiz süreçlerinde çok boyutlu bir görüntü sunarak sistemin etkinliğini artırmaktadır.

Telemetri verileri, drone'ların uçuş sırasında topladığı konum, hız, irtifa, batarya durumu, sensör çıktıları ve uçuş parametreleri gibi sürekli veri akışını kapsamaktadır. Bu veriler, uçuş güvenliği, rota optimizasyonu ve enerji yönetimi analizlerinde temel girdiyi oluşturmaktadır.

CBS verileri; arazi yapısı, engel bilgileri, yol ağı, yerleşim alanları, teslimat noktaları ve hava sahası kısıtları gibi coğrafi ve mekânsal verileri içermektedir. Bu veriler, rota planlaması ile engel tespiti başta olmak üzere pek çok fonksiyonel görevin yerine getirilmesinde kritik öneme sahiptir.

Meteorolojik veriler; rüzgâr hızı ve yönü, sıcaklık, nem, yağış, görüş mesafesi ve hava durumu tahminleri gibi çevresel değişkenleri kapsamaktadır. Bu veriler, uçuş güvenliğini ve enerji tüketimini doğrudan etkileyen faktörler olup, sistemin gerçek zamanlı adaptasyonu için kullanılmaktadır.

Operasyonel teslimat verileri; gerçekleşen teslimatların zamanlaması, teslimat noktası, kargo tipi, teslimat süresi, başarı oranı ve operasyonel maliyet gibi parametreleri içermekte ve sistem performans analizlerinde olduğu kadar DL modellerinin eğitilmesinde de kullanılmaktadır.

Veri kaynaklarının entegrasyonu sürecinde, çoklu veri füzyonu yaklaşımı benimsenmektedir. Farklı kaynaklardan elde edilen veriler, zaman ve konum bazlı olarak birleştirilmekte; bu entegrasyon modelleme ve analiz süreçlerinde daha yüksek doğruluk ve güvenilirlik sağlayan bir yapı sunmaktadır. Gerçek zamanlı ve tarihsel veri kullanımı, sistemin hem kısa vadeli hem de uzun vadeli performansının değerlendirilmesine olanak tanımakta;

böylece hem anlık hem de eğilim bazlı analizler gerçekleştirilebilmektedir. Veri kalitesi ve doğrulama süreçlerinde doğruluk, bütünlük ve güncellik kriterlerine öncelik verilmekte; eksik veya hatalı veriler istatistiksel ve algoritmik yöntemlerle ön işleme ve temizleme süreçlerine tabi tutulmaktadır. Tüm veri kaynaklarında, operasyonel ve kişisel bilgilerin korunmasına yönelik veri güvenliği protokolleri uygulanmakta; erişim kontrolleri ve şifreleme teknikleri ile veri bütünlüğü güvence altına alınmaktadır.

Uygulama açısından bakıldığında, bu veri altyapısı DL modellerinin eğitimi için zengin ve çeşitli veri setleri sunmakta; böylece modellerin genellenebilirliği ile saha performansı artırılmaktadır. Aynı zamanda, toplanan veriler rota optimizasyonu, enerji yönetimi ve teslimat doğruluğu gibi sistemin temel performans bileşenlerinin sürekli iyileştirilmesinde kullanılmakta ve karar destek sistemlerine entegre edilerek operasyonel kararların daha hızlı ve güvenilir biçimde alınmasına katkı sunmaktadır.

Bu kapsamlı veri altyapısı, OHKA'larda lojistik planlamanın hem teknik hem de operasyonel boyutlarında yüksek doğruluk, esneklik ve güvenilirlik sunmakta olup; her bir veri kaynağının ayrıntılı özellikleri ilerleyen alt başlıklarda kapsamlı biçimde ele alınacaktır.

Telemetri verileri

Telemetri verileri, OHKA'ların uçuş sırasında topladığı ve gerçek zamanlı olarak yer kontrol istasyonuna ilettiği kritik operasyonel bilgilerden oluşmaktadır. Bu veriler, sistemin güvenli, verimli ve izlenebilir biçimde çalışmasını sağlamak amacıyla temel bir işlev görmektedir.

Temel telemetri parametreleri arasında, GNSS tabanlı olarak elde edilen anlık enlem, boylam ve irtifa bilgileri yer almaktadır. Hız ve yön bilgileri; yatay ve dikey hız, yönelim (yaw, pitch, roll) ve rotadaki yönsel sapmaları içermektedir. Batarya durumu parametreleri kapsamında kalan enerji yüzdesi, anlık enerji tüketimi, batarya sıcaklığı ve tahmini kalan uçuş süresi izlenmektedir. Ayrıca, IMU, barometre, manyetometre, LiDAR, kamera ve benzeri sensörlerden elde edilen ham ve işlenmiş veriler sistemin dinamik durumunu yansıtmaktadır. Uçuş durumu parametresi, drone'un kalkış, seyir, iniş, bekleme ve acil durum gibi operasyonel modlarını ifade etmektedir. Sinyal ve haberleşme kalitesi ise RF, LTE/5G veya Wi-Fi üzerinden gerçekleşen bağlantının sinyal gücü, veri iletim hızı ve gecikme değerleri ile ölçülmektedir.

Tüm telemetri verileri, uçuş kontrol biriminden alınarak düşük gecikmeli ve güvenli iletişim protokolleri yoluyla yer kontrol istasyonuna gerçek zamanlı olarak iletilmektedir. Telemetri sistemleri çift yönlü iletişim yeteneğine sahiptir; bu sayede yalnızca veri gönderimi değil, aynı zamanda yer kontrol istasyonundan drone'a komut iletimi gerçekleştirilebilmektedir.

Telemetri verilerinin kullanım alanları geniş bir yelpazeye yayılmaktadır. Uçuş güvenliği kapsamında anlık izleme, oluşabilecek arıza veya sapmaların erken tespiti ve müdahalesine olanak sağlamaktadır. Rota ve enerji optimizasyonu süreçlerinde bu veriler, rotaların iyileştirilmesi ile enerji yönetimi algoritmalarının sürekli güncellenmesi için temel girdi olarak kullanılmaktadır. DL tabanlı kontrol ve optimizasyon modellerinin eğitimi için yüksek hacimli ve çeşitli telemetri veri setleri sağlanmakta; böylece modellerin genellenebilirliği artırılmaktadır. Performans ve arıza analizleri, sistemin genel işleyişinin değerlendirilmesi ve olası arızaların kök nedenlerinin belirlenmesi telemetri kayıtlarından faydalanılarak gerçekleştirilmektedir. Ayrıca, operasyonel raporlama amacıyla teslimat başarı oranı, uçuş süresi ve enerji tüketimi gibi metrikler telemetri verileri temel alınarak hesaplanmaktadır.

Bu verilerin avantajları arasında yüksek doğruluk ve güvenilirlik ön plana çıkmakta; hassas sensörler ve yedekli iletişim altyapısı sayesinde veri kaybı ve hata oranı minimize edilmektedir. Gerçek zamanlı adaptasyon özelliği, çevresel ve operasyonel değişkenlere anlık olarak yanıt verilmesini mümkün kılmakta; bu durum sistemin çevik işleyişine katkı sunmaktadır. Telemetri verileri, CBS, meteoroloji ve operasyonel teslimat verileri gibi diğer veri kaynaklarıyla entegre edilerek bütüncül analiz ve karar destek süreçlerine entegre edilmektedir.

Coğrafi bilgi sistemleri verileri

CBS verileri, OHKA'ların lojistik planlamasında rota optimizasyonu, engel tespiti ve operasyonel risk yönetimi gibi kritik süreçlerin temelini oluşturan mekânsal ve coğrafi bilgilerdir. Bu veriler, sistemin gerçek dünya koşullarına uyumunu sağlamak ve operasyonel doğruluğunu artırmak amacıyla çok katmanlı yapıda organize edilmiştir.

Arazi ve topografya verileri, yükseklik, eğim, arazi tipi ve yüzey özelliklerini içeren dijital yükseklik modelleri ile topografik haritalardan elde edilmektedir. Bu katmanlar, uçuş güvenliği ve rota planlamasında engel tespiti için temel veri kaynağıdır. Altyapı ve yol ağı verileri; kara yolları, demir yolları, köprüler, tüneller, enerji hatları gibi altyapı unsurlarını detaylı şekilde içermekte olup, teslimat noktalarına erişim ve alternatif güzergâh analizleri için sisteme entegre edilmektedir. Yerleşim alanları ve teslimat noktaları; şehir, ilçe, mahalle ve köy gibi yerleşim birimleriyle birlikte, teslimat yapılacak spesifik adresleri koordinat bazlı olarak tanımlamakta ve nüfus yoğunluğu ile erişilebilirlik analizlerinde kullanılmaktadır. Engel ve risk bölgeleri kapsamında hava sahası kısıtlamaları, yasaklı bölgeler, ormanlık alanlar, su kütleleri, endüstriyel tesisler ve benzeri potansiyel tehlike alanları CBS veri tabanında işaretlenmekte; bu alanlar, rota planlaması sürecinde otomatik olarak çıkarılmakta veya özel önlemler eşliğinde

dikkate alınmaktadır. Hava sahası ve navigasyon bilgileri katmanlarında kontrol edilen hava sahası sınırları, kalkış-iniş noktaları, havaalanları ve drone koridorları gibi havacılığa özgü unsurlar sisteme entegre edilmiştir.

CBS veri setleri düzenli olarak güncellenmekte; yeni altyapı projeleri, yol kapanmaları veya doğal afet kaynaklı değişiklikler sistem veri tabanına yansıtılmaktadır. Verilerin doğruluğu, saha gözlemleri ve uydu görüntüleri ile yapılan karşılaştırmalarla güvence altına alınmaktadır.

CBS verileri, rota optimizasyonunda drone'ların en kısa, güvenli ve enerji verimli güzergâhlarını belirlemeye yönelik temel girdiyi sağlamaktadır. Ayrıca, potansiyel engel ve risk bölgelerinin otomatik tespiti sayesinde güvenli uçuş planlaması mümkün olmaktadır. Teslimat planlamasında, coğrafi analizlerden faydalanılarak teslimat noktalarının erişilebilirliği belirlenmekte; bunlara göre operasyonel önceliklendirme yapılmaktadır. Farklı senaryolar altında sistem performansının test edilmesi amacıyla, gerçek dünya koşullarını yansıtan coğrafi ortamlar simülasyon ve modelleme çalışmalarına entegre edilmektedir.

CBS verilerinin sunduğu avantajlar arasında yüksek doğruluk ve ayrıntı seviyesi, değişen altyapı ile çevresel koşullara karşı dinamik güncellenebilirlik ve diğer veri türleriyle bütüncül analiz yapılabilmesini sağlayan entegrasyon kabiliyeti yer almaktadır.

Bu kapsamlı CBS veri altyapısı, OHKA'ların karmaşık coğrafi koşullarda güvenli, verimli ve optimize edilmiş biçimde çalışmasını olanak tanımaktadır.

Meteorolojik veriler

Meteorolojik veriler, OHKA'ların lojistik planlamasında uçuş güvenliği, enerji optimizasyonu ve rota planlaması gibi kritik süreçlerin çevresel koşullara adaptasyonu açısından temel veri kaynaklarından. Bu veriler, sistemin gerçek dünya koşullarında yüksek doğruluk ve güvenilirlikle çalışmasını sağlamak amacıyla hem tarihsel hem de gerçek zamanlı olarak toplanmakta ve analiz edilmektedir.

Temel meteorolojik parametreler arasında rüzgar hızı ve yönü, uçuş güvenliği ile enerji tüketimi üzerinde doğrudan etkili olmakta ve rota optimizasyonunda önemli bir rol oynamaktadır. Sıcaklık, batarya performansı ve uçuş süresi açısından belirleyici bir değişken olup; nem ise elektronik bileşenlerin güvenliği ve uçuş stabilitesi bakımından dikkate alınmaktadır. Yağış durumu, uçuşun başlatılması veya iptal edilmesine yönelik karar süreçlerinde kullanılırken; görüş mesafesi, otonom navigasyon ve engel algılama sistemlerinin performansı üzerinde etkili olmaktadır. Hava durumu tahminleri, planlama ve risk yönetimi süreçlerine doğrudan katkı sağlayan veriler arasında yer almakta; kısa ve orta vadeli

operasyonel hazırlığın belirlenmesinde kullanılmaktadır. Meteorolojik veriler, çeşitli kaynaklardan toplanmaktadır. Bu kaynaklar arasında Meteoroloji Genel Müdürlüğü açık kaynakları ve yerel meteoroloji istasyonları gibi resmî kurumlar; NOAA ve OpenWeather gibi küresel açık veri platformları; araştırma sahasına kurulan yerel hava durumu sensörleri ve drone'lara entegre edilen meteorolojik sensörler bulunmaktadır.

Toplanan meteorolojik veriler hem DL tabanlı model eğitiminde hem de operasyonel analiz süreçlerinde kullanılmakta ve zaman damgalı, konum etiketli biçimde CSV ile JSON gibi standart formatlarda merkezi veri tabanında saklanmaktadır.

Bu verilerin entegrasyonu ile DL tabanlı hava durumu tahmin ve adaptasyon algoritmaları geliştirilebilmekte; ayrıca, gerçek zamanlı meteorolojik veriler, rota planlaması ve enerji yönetimi algoritmalarının girdisi olarak kullanılmaktadır. Ani hava değişimleri ve olumsuz meteorolojik koşullar için erken uyarı sistemleri ile otomatik müdahale mekanizmaları geliştirilmekte; bu sayede uçuş güvenliği artırılmaktadır. Senaryo bazlı analizlerde, farklı meteorolojik koşullar altında sistemin performansı test edilmekte ve bu doğrultuda operasyonel dayanıklılık değerlendirilmektedir.

Veri kalitesi ve güvenliği kapsamında, tüm meteorolojik veriler güvenilir kaynaklardan temin edilmekte ve güncel tutulmaktadır. Veri gizliliğinin korunması amacıyla erişim kontrolleri uygulanmakta; tüm operasyonel veriler şifreleme yöntemleri ile güvenli biçimde saklanmaktadır.

Bu kapsamlı meteorolojik veri altyapısı, OHKA sistemlerinin çevresel değişkenlere karşı adaptasyon yeteneğini artırmakta; lojistik operasyonlarda güvenilirliği, verimliliği ve sürdürülebilirliği desteklemektedir.

Operasyonel teslimat verileri

Operasyonel teslimat verileri, OHKA'ların gerçek dünya koşullarında gerçekleştirdiği teslimat süreçlerine ilişkin zaman, konum, kargo tipi, teslimat süresi, başarı oranı ve maliyet gibi parametreleri içeren kapsamlı veri setleridir. Bu veriler, sistemin performans analizlerinde, DL modellerinin eğitiminde ve operasyonel süreçlerin optimizasyonunda temel bir rol oynamaktadır.

Teslimat zamanı ve süresi parametreleri kapsamında, her bir teslimatın başlama ve bitiş zamanı ile toplam operasyon süresi kayıt altına alınarak rota planlaması ve zamanlama algoritmalarının iyileştirilmesinde kullanılmaktadır. Teslimat noktası ve konumu, kargonun bırakıldığı adresin enlem, boylam ve şehir, ilçe, mahalle gibi bölgesel detaylarla tanımlanmasını kapsamaktadır. Kargo tipi ve özellikleri kapsamında, taşınan yüklerin ağırlığı, hacmi, hassasiyet

seviyesi ve özel taşıma gereksinimleri (örneğin, sıcaklık kontrollü ortam veya hassas kargo) veri tabanında tutulmaktadır. Teslimat başarı oranı, gerçekleştirilen teslimatların başarıyla tamamlanma yüzdesi üzerinden hesaplanmakta; ayrıca gecikme ve iptal sebepleriyle birlikte analiz edilmektedir. Operasyonel maliyet parametreleri, her bir teslimata ait batarya tüketimi, bakım masrafları ve insan kaynağı maliyetleri gibi temel girdileri içermekte; sistemin maliyet etkinliğinin değerlendirilmesini sağlamaktadır. Teslimat sırasında karşılaşılan hava durumu, trafik durumu, engeller ve diğer çevresel faktörler, operasyonel bağlamda sistem performansını etkileyen çevresel koşullar parametresi altında değerlendirilmektedir.

Tüm teslimat verileri, operasyon sırasında drone'lar ve yer kontrol istasyonu tarafından gerçek zamanlı olarak otomatik biçimde toplanmaktadır. Veriler, analiz ve raporlama süreçlerini kolaylaştırmak amacıyla yaygın kullanılan standart formatlarda saklanmaktadır. Ayrıca, operasyonel teslimat verileri, telemetri, CBS ve meteorolojik veri katmanları ile entegre edilerek teslimat süreçlerinin çok boyutlu ve bütüncül biçimde analiz edilmesi sağlanmaktadır. Teslimat sonrası gerçekleştirilen otomatik ve manuel kontroller aracılığıyla veri doğruluğu teyit edilmekte; tespit edilen eksik veya hatalı kayıtlar, ön işleme aşamasında düzeltilmektedir.

Bu veriler, sistemin genel başarı oranı, teslimat süresi ve maliyet etkinliği gibi performans metriklerinin hesaplanmasında kullanılmakta; aynı zamanda DL tabanlı rota optimizasyonu ve teslimat tahmin modellerinin eğitiminde temel veri kaynağı olarak değerlendirilmektedir. Elde edilen bilgilerle teslimat rotaları, filo yönetimi ve enerji tüketimi gibi operasyonel süreçler sürekli olarak iyileştirilmekte; daha etkin karar destek mekanizmaları oluşturularak geçmiş veri üzerinden analiz ve senaryo tabanlı simülasyonlar gerçekleştirilmektedir. Tüm bu süreçler, sistemin şeffaf ve izlenebilir şekilde raporlanmasına olanak tanımakta; teslimat süreçlerinin ayrıntılı biçimde takip edilmesini sağlamaktadır.

Operasyonel teslimat verilerinin sunduğu avantajlar arasında, gerçek zamanlı ve otomatik veri kaydı sayesinde yüksek doğruluk ve güvenilirlik, farklı veri kaynaklarıyla entegrasyon sayesinde çok boyutlu analiz imkânı ve performansa dayalı sürdürülebilir sistem gelişiminin desteklenmesi öne çıkmaktadır.

Bu kapsamlı operasyonel teslimat veri altyapısı, OHKA'ların lojistik planlamasında yüksek doğruluk, verimlilik ve izlenebilirlik sağlayarak sistem performansının objektif biçimde değerlendirilmesi ve sürekli iyileştirilmesi için vazgeçilmez bir temel oluşturmaktadır.

Yazılım altyapısı

OHKA'larda DL tabanlı lojistik planlama araştırmasında kullanılan yazılım altyapısı, sistemin bütünsel işleyişini, veri yönetimini, model geliştirme süreçlerini ve operasyonel

uygulamaları destekleyen çok katmanlı ve modüler bir yapıya sahiptir. Bu altyapı, araştırma faaliyetlerinin yanı sıra gerçek zamanlı operasyonların da güvenilir, esnek ve ölçeklenebilir biçimde yürütülmesini sağlamaktadır.

Yazılım altyapısının temel bileşenlerinden biri Python programlama ortamıdır. Python, kapsamlı kütüphane desteği, veri bilimi ve ML ekosistemi, açık kaynak yapısı ve sistemler arası kolay entegrasyon olanaklarıyla araştırmanın ana programlama dili olarak tercih edilmiştir. Model geliştirme ve eğitim süreçlerinde, DL uygulamalarının etkin şekilde yürütülmesini sağlayan TensorFlow, Keras ve PyTorch çerçeveleri kullanılmış; bu çerçeveler, hızlı prototipleme, GPU/TPU hızlandırma desteği ve geniş kullanıcı topluluğu avantajları sunmaktadır. Drone uçuşlarının ve lojistik senaryoların sanal ortamda test edilmesi amacıyla MATLAB/Simulink, Unreal Engine, Ansys Discovery ve özel olarak geliştirilmiş İHA simülasyon yazılımlarından yararlanılmıştır. Bu araçlarla düşük ve yüksek doğruluk düzeyinde gerçekleştirilen simülasyonlar, algoritmaların ve kontrol sistemlerinin güvenli biçimde değerlendirilmesine olanak tanımaktadır. Veri ön işleme, analiz ve görselleştirme süreçlerinde ise Pandas, NumPy, SciPy, Scikit-Learn, Matplotlib, Seaborn ve Plotly gibi Python tabanlı kütüphaneler kullanılarak büyük hacimli ve çok boyutlu veri setleri üzerinde etkili analizler gerçekleştirilmiş; model çıktılarına ve operasyonel performansa ilişkin görsel raporlar oluşturulmuştur.

Yazılım altyapısı çok katmanlı bir mimari üzerine inşa edilmiştir. Bu mimari; veri toplama, ön işleme, modelleme, karar destek ve operasyonel uygulama olmak üzere birbirinden bağımsız şekilde geliştirilebilir ve güncellenebilir katmanlardan oluşmaktadır. Donanım ve sensör entegrasyonu kapsamında, drone'lardan elde edilen telemetri, sensör ve görüntü verilerinin doğrudan işlenebilmesi için özel API'ler ve MAVLink gibi iletişim protokollerinden faydalanılmış; böylece gerçek zamanlı veri akışı ve komut iletimi sağlanmıştır. Yazılım altyapısında, otonom kontrol ve görev planlamasına ilişkin algoritmalar merkezi biçimde yönetilmekte; rota optimizasyonu, enerji yönetimi ve teslimat planlaması süreçlerinde gerçek zamanlı ve tarihsel veriler kullanılarak dinamik görev atamaları ve optimizasyonlar gerçekleştirilmektedir. Tüm yazılım bileşenlerinde veri güvenliği ön planda tutulmakta; erişim kontrolleri ve şifreleme yöntemleri uygulanmakta, operasyonel veriler merkezi veri tabanlarında güvenli biçimde depolanmakta ve yedeklenmektedir. Şekil 9'da model geliştirme süreci gösterilmiştir. Geliştirilen modeller, uygulamaya alınmadan önce simülasyon

ortamlarında test edilerek performans ve güvenlik kriterleri yönünden doğrulanmakta; bu doğrulama süreci, zaman ve maliyet açısından çeşitli avantajlar sağlamaktadır.



Şekil 9. Model geliştirme süreci.

Yazılım altyapısının sağladığı avantajlar arasında esnek ve genişletilebilir yapısı sayesinde yeni algoritmalar, sensör birimleri veya donanım bileşenlerinin kolayca entegre edilebilmesi, aynı anda birden fazla drone ve çoklu teslimat senaryosunun merkezi olarak yönetilebilmesi de yer almaktadır. Gerçek zamanlı veri akışı ve komut aktarımı yoluyla operasyonel süreçlerde sistemin dinamik adaptasyonu ve güvenliği artırılmakta; büyük veri setleri ve karmaşık model yapıları için yüksek performanslı hesaplama altyapısı kullanılmakta; çıktıların açıklanabilirliği ve raporlanabilirliği ise gelişmiş görselleştirme araçlarıyla sağlanmaktadır.

Bu kapsamlı yazılım altyapısı, OHKA'ların lojistik planlamasında hem bilimsel araştırmalara hem de gerçek dünya uygulamalarına yönelik olarak yüksek doğruluk, güvenlik ve verimlilik sunmakta; sistemin başarıyla ölçeklenebilmesini ve sürdürülebilir biçimde yönetilmesini mümkün kılmaktadır.

Python programlama ortamı

Python programlama ortamı, OHKA'larda DL tabanlı lojistik planlama araştırmasının temel yazılım bileşenlerinden biri olarak konumlanmaktadır. Python'un tercih edilme nedenleri arasında geniş kütüphane ekosistemi, açık kaynak yapısı, kullanıcı dostu sözdizimi ve veri bilimi ile ML uygulamalarında sunduğu güçlü araçlar yer almaktadır. Python, veri işleme, analiz ve görselleştirme süreçlerinde kullanılan NumPy, Pandas, SciPy, Scikit-Learn, Matplotlib,

Seaborn ve Plotly gibi kapsamlı kütüphaneler ile DL çerçevelerinin (TensorFlow, Keras, PyTorch) entegrasyonunu kolaylıkla sağlamaktadır. Açık kaynak yapısı sayesinde dünya genelinde geniş bir geliştirici topluluğu tarafından desteklenmekte; bu yapı, karşılaşılan teknik problemlere hızlı çözümlerin bulunmasına ve güncel teknolojik gelişmelerin yakından takip edilebilmesine olanak tanımaktadır. Python, Windows, Linux ve macOS gibi farklı işletim sistemlerinde sorunsuz çalışabilen bir platformlar arası uyumluluk sunmakta; bu özellik, araştırma ortamlarının ve operasyonel sistemlerin esnekliğini artırmaktadır. Modüler yapısıyla Python, yeni algoritmaların ve yazılım prototiplerinin kısa sürede geliştirilmesini sağlamakta; veri toplama, ön işleme ve raporlama gibi süreçlerin otomatikleştirilmesine imkân tanımaktadır. Drone'lardan gelen telemetri ve sensör verilerinin alınması, işlenmesi ve komut gönderimi gibi operasyonlar Python tabanlı API'ler ve MAVLink gibi iletişim protokolleri kullanılarak gerçekleştirilmektedir. Ayrıca, Python ortamı GPU/TPU hızlandırma desteği ile büyük veri setleri ve karmaşık DL modellerinin eğitiminde yüksek performanslı hesaplama altyapısı sunmaktadır.

Uygulama alanları bakımından Python, farklı kaynaklardan gelen verilerin toplanması, temizlenmesi ve analiz edilmesinde merkezi bir rol üstlenmektedir. DL modellerinin tasarımı, eğitimi ve değerlendirilmesi süreçlerinin tamamı Python ortamında gerçekleştirilmekte; ayrıca drone uçuşlarının ve lojistik senaryoların sanal ortamda test edilmesi için Python tabanlı simülasyon araçlarından yararlanılmaktadır. Analiz sonuçları ile model çıktıları, Python kütüphaneleri aracılığıyla görselleştirilmekte ve operasyonel raporlar halinde sunulmaktadır. Gerçek zamanlı veri akışı ve dinamik görev atamaları, Python scriptleri yoluyla yürütülerek sistemin otonom kontrol altında tam işlevsellelikle çalışmasına olanak tanımaktadır.

Sonuç olarak, Python programlama ortamı, OHKA'ların lojistik planlamasında hem bilimsel hem de operasyonel uygulamalar için esnek, güçlü ve sürdürülebilir bir yazılım altyapısı sağlamaktadır. Bu yapı, sistemin bütüncül işleyişi, veri yönetimi, model geliştirme süreçleri ve operasyonel yönetimin yüksek doğruluk ve verimlilikle gerçekleştirilmesini mümkün kılmaktadır.

DL çerçeveleri

DL çerçeveleri, OHKA'larda lojistik planlama ve optimizasyon süreçlerinde kullanılan yapay zekâ modellerinin geliştirilmesi, eğitilmesi ve test edilmesinde temel rol üstlenmektedir. Bu çalışmada, TensorFlow, Keras ve PyTorch gibi modern ve yaygın olarak kabul gören DL çerçeveleri tercih edilmiştir. Tablo 4'de kullanılan DL çerçevelerinin temel özellikleri ve kullanım alanları verilmiştir. Her üç çerçeve, GPU/TPU hızlandırma desteği ile büyük veri setlerinin ve karmaşık model mimarilerinin verimli biçimde eğitilmesini sağlamaktadır.

Modüler ve katman bazlı esnek yapıları sayesinde, farklı mimarilerin oluşturulması ve çeşitli modüllerin entegrasyonu kolaylıkla gerçekleştirilebilmektedir. Geniş geliştirici toplulukları ve kapsamlı dokümantasyon sunmaları sayesinde, karşılaşılan teknik sorunlara hızlı çözümler bulunabilmekte ve güncel gelişmeler etkin biçimde takip edilebilmektedir. Tüm çerçevelerin açık kaynaklı olması ve farklı işletim sistemlerinde sorunsuz çalışması, platformlar arası uyum açısından önemli avantaj sunmaktadır.

Tablo 4. Kullanılan DL Çerçeveleri

Çerçeve	Temel Özellikler	Kullanım Alanları
TensorFlow	Düşük seviyeli kontrol, dağıtık eğitim, güçlü üretim desteği, geniş API	Büyük ölçekli model eğitimi, üretim ortamı entegrasyonu
Keras	Yüksek seviyeli, kullanıcı dostu API, hızlı prototipleme, TensorFlow ile entegre	Hızlı model geliştirme, deneysel prototipleme
PyTorch	Dinamik hesap grafiği, esnek modelleme, araştırma odaklı yapı	Gelişmiş model mimarileri, araştırma ve prototipleme

Telemetri, CBS, meteorolojik ve operasyonel veriler doğrudan bu çerçevelerle entegre edilerek hem gerçek zamanlı hem de toplu veri üzerinde model eğitimi gerçekleştirilmiştir. Model performans ölçümleri kapsamında doğruluk, hassasiyet, F1 skoru, MAE ve MSE gibi metrikler hesaplanmış; hiperparametre optimizasyonu ve çapraz doğrulama süreçleri etkin biçimde uygulanmıştır. Model çıktıları ve katman ağırlıkları TensorBoard gibi araçlarla görselleştirilmiş; açıklanabilir yapay zekâ teknikleri ile karar süreçleri ayrıntılı olarak analiz edilmiştir.

Keras ve PyTorch'un sunduğu esnek yapılar ile hızlı prototipleme olanakları sağlanmış; yeni algoritmalar kısa süre içinde geliştirilip test edilmiştir. TensorFlow'un üretim ortamı desteği ve dağıtık eğitim yetenekleri sayesinde, büyük veri setleri üzerinde yüksek verimlilikle model eğitimi gerçekleştirilmiştir. Açık kaynak ekosisteminin sunduğu geniş kaynak ve topluluk desteği, araştırma ve geliştirme süreçlerini hızlandırarak yazılım altyapısının bilimsel etkililiğini ve operasyonel uygulanabilirliğini artırmıştır.

Simülasyon araçları ve yazılımlar

OHKA'larda DL tabanlı lojistik planlama araştırmasında, rota optimizasyonu, uçuş simülasyonu ve ağ analizleri için gelişmiş simülasyon araçları ve yazılımlar entegre edilmiştir. Gerçek operasyon verilerinin sınırlı olduğu durumlarda, model geliştirme ve test süreçlerinin güvenilirliğini artırmak amacıyla sentetik veri üretimi de kullanılmıştır.

Python tabanlı simülasyon altyapılarından NetworkX, karmaşık lojistik ağlarının modellenmesi, rota optimizasyonu ve ağ analizi amaçlarıyla tercih edilmiştir. Düğüm-temelli

yapısı sayesinde farklı teslimat noktaları ve güzergâhlar üzerinde kısa yol, kapasite ve akış analizleri gerçekleştirilebilmiştir. SimPy, olay tabanlı simülasyon özelliğiyle teslimat süreçlerinin zamanlaması, kaynak yönetimi ve operasyonel senaryoların modellenmesinde kullanılmış; özellikle filo yönetimi, görev atama ve teslimat sıralaması gibi dinamik süreçlerin ayrıntılı şekilde simüle edilmesine olanak tanımıştır.

JavaScript tabanlı Mapbox aracı, gerçekçi ve etkileşimli harita görselleştirmeleri ile rota animasyonları üretmekte; engeller, coğrafi değişkenler ve teslimat güzergâhlarının analizini desteklemektedir. Turf.js, rota uzunluğu, alan hesaplaması ve mekânsal sorgular gibi yüksek doğruluklu coğrafi analizlerde kullanılmıştır.

Simülasyon ve modelleme süreçlerinde, çeşitli teslimat noktaları, engeller ve meteorolojik koşullar dikkate alınarak en kısa, en güvenli ve enerji açısından verimli güzergâhları belirlemeye yönelik rota optimizasyon simülasyonları yürütülmüştür. Ağ temelli analizler üzerinden enerji tüketimi ve teslimat süresi gibi metrikler optimize edilmiştir. Gerçek uçuş verisinin bulunmadığı senaryolarda, sanal ortamda uçuş senaryoları modellenmiş ve kontrol algoritmaları bu ortamda test edilmiştir. Böylelikle sistemin değişken koşullara adaptasyon yeteneği değerlendirilmiştir. Teslimat ağı kapsamında darboğazların, kritik noktaların ve alternatif güzergâhların belirlenmesi amacıyla ağ analizleri gerçekleştirilmiş; bu analizler operasyonel verimliliğin artırılmasına ve risklerin azaltılmasına katkı sağlamıştır.

Sentetik veri üretimi süreçlerinde, GAN tabanlı modeller kullanılarak, sınırlı gerçek verinin yerine geçebilecek nitelikte sentetik telemetri ve operasyonel veri üretilmiştir. Bu veriler, DL model eğitimi ve validasyon süreçlerinde kullanılarak algoritmaların genellenebilirlik düzeyi ile dayanıklılığı artırılmıştır.

Kullanılan açık kaynaklı simülasyon kütüphaneleri, yeni senaryoların ve algoritmaların sistemi esnek ve ölçeklenebilir biçimde geliştirmesine olanak tanımıştır. Sanal simülasyonlara ve sentetik veri üretimine dayalı yapı, sistemin gerçek dünya koşullarında güvenli biçimde test edilmesine imkân sağlamış; ayrıca, bu yapı yüksek doğrulukta test ortamı sunmuştur. Farklı veri kaynaklarından yararlanılması ve sentetik verinin entegre kullanılmasıyla, geliştirilen DL modellerinin performansı çok boyutlu biçimde değerlendirilmiştir.

Veri analizi ve görselleştirme araçları

Veri analizi ve görselleştirme süreçleri, OHKA'larda DL tabanlı lojistik planlama araştırmasının temel bileşenlerinden birini oluşturmaktadır. Bu süreçlerde, verinin temizlenmesi, analiz edilmesi ve elde edilen sonuçların bilimsel standartlara uygun biçimde raporlanması amacıyla modern ve güçlü araçlardan yararlanılmıştır.

Pandas kütüphanesi, veri temizleme, dönüştürme ve tablo bazlı analiz işlemleri için temel araç olarak kullanılmış; özellikle büyük hacimli ve çok boyutlu veri setlerinde esnek veri manipülasyonu sağlamıştır. NumPy, sayısal hesaplamalar, matris işlemleri ve istatistiksel analizler için kullanılmış; Pandas ile entegre biçimde çalışarak veri analiz süreçlerinin verimliliğini artırmıştır. Matplotlib, grafik ve çizelge oluşturma işlevleri için temel görselleştirme kütüphanesi olarak kullanılmış; zaman serileri, dağılım grafikleri ve çubuk grafiklerde yüksek esneklik sunmuştur. Seaborn kütüphanesi, Matplotlib üzerine inşa edilmiş olup; korelasyon matrisleri, kutu grafikler ve yoğunluk haritaları gibi ileri düzey istatistiksel görsellerin kolaylıkla oluşturulmasına imkan sağlamıştır. Plotly ise etkileşimli ve dinamik grafikler oluşturmak için tercih edilmiş; özellikle web tabanlı raporlama ve sunumlarda kullanıcıların veri ile doğrudan etkileşime geçmesini mümkün kılmıştır.

Coğrafi analiz amaçlı olarak, Geopandas kütüphanesi kullanılarak shapefile, GeoJSON gibi coğrafi veri tiplerinin işlenmesi ve mekânsal analizlerin yürütülmesi sağlanmıştır. QGIS, açık kaynaklı bir CBS yazılımı olarak, karmaşık mekânsal analizler, katman yönetimi ve harita üretimi işlemlerinde tercih edilmiştir. ArcGIS, gelişmiş mekânsal analiz, harita üretimi ve veri entegrasyonuna olanak tanıyan profesyonel bir CBS platformu olarak, büyük ölçekli modellemelerde kullanılmıştır.

Analiz sonuçlarına ilişkin tüm grafikler ve tablolara yönelik çıktıların otomatik üretilmesi amacıyla Python tabanlı otomasyon scriptleri geliştirilmiş; elde edilen görseller doğrudan bilimsel rapor ve sunumlarda kullanılabilecek şekilde yapılandırılmıştır. Tüm görsel içerikler, başlıklandırma, açıklama ve kaynak gösterimi dâhil olmak üzere APA raporlama standartlarına uygun biçimde düzenlenmiştir.

Veri temizleme ve hazırlama sürecinde, eksik, hatalı veya tutarsız veriler tespit edilerek elimine edilmiş; analiz öncesinde veri bütünlüğü ve karşılaştırılabilirliği sağlanmıştır. Hem sayısal hem de mekânsal veriler üzerinde çok boyutlu analizler yürütülmüş; elde edilen sonuçlar farklı grafik ortamlarında görsel destekle sunulmuş ve yorumlanmıştır. Otomatikleştirilmiş ve standardize edilmiş raporlama yöntemleri, analiz süreçlerinin tekrarlanabilirliğini artırmış; böylece araştırmada bilimsel şeffaflık ve metodolojik geçerlilik sağlanmıştır.

Bu kapsamlı veri analizi ve görselleştirme altyapısı, araştırmanın bulgularının güvenilir, açık, anlaşılır ve bilimsel olarak geçerli biçimde sunulmasına katkı sağlamaktadır.

Biyometrik doğrulama sistemleri

OHKA'larda uçtan uca güvenlik ve teslimat doğruluğunu sağlamak amacıyla biyometrik doğrulama sistemleri, sistem mimarisinin ayrılmaz bir bileşeni olarak

yapılandırılmıştır. Bu altyapı, hem kullanıcı kimliğinin güvenli şekilde doğrulanmasını hem de teslimat süreçlerinde yetkisiz erişimin önlenmesini hedeflemektedir.

Yüz tanıma sistemi ile kullanıcıların kimlik doğrulama işlemleri gerçekleştirilmekte; teslimat sırasında sistem tarafından yüz tanıma teknolojisi aracılığıyla eşleştirme yapılmakta ve böylece yalnızca yetkili kişilerin teslimat alması garanti altına alınmaktadır. İki faktörlü kimlik denetimi kapsamında yüz tanımanın yanı sıra, SMS/e-posta doğrulama ya da mobil uygulama üzerinden dinamik şifre üretimi gibi ikinci bir güvenlik katmanı uygulanmaktadır. Bu yöntem, kimlik hırsızlığına karşı ek koruma sağlar ve yetkisiz erişim risklerini önemli ölçüde azaltmaktadır. Kullanıcı onayı, veri işleme izinleri ve erişim kontrolleri açıkça belirlenmiş ve şeffaf biçimde uygulanmaktadır. Biyometrik verilerin işlenmesi ve saklanması süreçleri, Türkiye Kişisel Verileri Koruma Kanunu (KVKK) ile Avrupa Birliği Genel Veri Koruma Tüzüğü'ne (GDPR) uygunluk çerçevesinde yürütülmektedir. Veriler, gelişmiş şifreleme algoritmalarıyla korunmakta ve operasyonel verilerden bağımsız, izole veri tabanlarında tutulmaktadır. Bu yapı, potansiyel veri sızıntıları ile yetkisiz erişim risklerini asgariye indirmektedir.

Biyometrik verilere erişim yalnızca yetkili sistem yöneticilerine tanımlı olup; tüm erişim işlemleri detaylı olarak kayıt altına alınmakta ve denetlenebilirlik sağlanmaktadır. Operasyonel anlamda, biyometrik doğrulama sayesinde teslimatlar yalnızca gerçekten yetkili alıcılara yapılmakta; bu durum teslimat süreçlerinde hata, sahtecilik ve yanlış eşleşme olasılığını ortadan kaldırmaktadır. Hızlı ve güvenli kimlik doğrulama süreçleri sayesinde kullanıcı deneyimi iyileştirilmekte ve sistemin genel güvenilirliği artırılmaktadır. Biyometrik doğrulama sistemi, modüler yapısıyla yeni nesil doğrulama teknolojilerine uyumlanabilir şekilde tasarlanmıştır.

Bu kapsamlı biyometrik doğrulama altyapısı, OHKA'ların lojistik operasyonlarında hem güvenlik hem de yasal uyum açısından yüksek standartlarda hizmet sunmasına olanak tanımaktadır.

Veri Ön İşleme ve Özellik Çıkarımı Yöntemleri

Veri ön işleme ve özellik çıkarımı süreçleri, OHKA'larda DL tabanlı lojistik planlama araştırmasının başarısı açısından belirleyici bir öneme sahiptir. Bu süreçler, genellikle heterojen ve ham veri kaynaklarını analiz edilebilir, bütünleşik ve modele uygun bir biçime dönüştürerek DL modelinin performansını, doğruluğunu ve genellenebilirliğini artırmaktadır.

Veri standardizasyon ve normalizasyon işlemleri kapsamında, Min-Max normalizasyonu ile değişkenler 0–1 aralığına ölçeklendirilmiş; Z-skor standardizasyonu

kullanılarak farklı dağılımlara sahip veriler ortalama ve standart sapma temelli olarak düzenlenmiştir. Aykırı değerlere duyarlılığı azaltmak amacıyla robust ölçekleme yöntemlerinden, özellikle medyan ve çeyrekler arası aralık (interquartile range, IQR) tabanlı tekniklerden yararlanılmıştır. Çok kaynaktan gelen veriler, zaman damgaları aracılığıyla eşleştirilmiş ve senkronize edilmiştir. Bu işlem, çoklu veri füzyonu ve gerçek zamanlı analiz kabiliyetlerinin güvenilirliğini sağlamak açısından temel oluşturmuştur.

Kategori temelli değişkenler (örneğin teslimat tipi veya kargo sınıfı), one-hot encoding ya da label encoding yöntemleriyle sayısal forma dönüştürülmüştür. Eksik veri durumlarında ise temel istatistiksel yöntemler (ortalama, medyan, mod) yanında KNN imputasyonu (eksik veri içeren veri setlerinde eksik değerleri k-en yakın komşu algoritması ile tahmin edip doldurma yöntemi) ve regresyon tabanlı doldurma teknikleriyle veri setleri tamamlanmıştır. Veri boyutunun yüksek olduğu telemetri ve sensör verilerinde gereksiz ya da tekrarlı özellikler elenmiş, gerektiğinde PCA ve t-SNE gibi boyut indirgeme yöntemleri uygulanarak analiz verimliliği artırılmıştır.

Özellik çıkarımı kapsamında, temel istatistiksel metrikler hesaplanmış; buna ek olarak zaman serisi analizlerine yönelik hareketli ortalama, trend, mevsimsellik ve otokorelasyon gibi karakteristik özellikler elde edilmiştir. Titreşim, motor verisi ve uçuş dinamikleri gibi alanlarda frekans ve spektral çözünürlükler Fourier dönüşümü (bir sinyalin veya fonksiyonun zaman alanından frekans alanına dönüştürülmesini sağlayan matematiksel bir yöntem) ve spektral analizle (bir sinyalin veya zaman serisinin farklı frekans bileşenlerine ayrıştırılması ve bu bileşenlerin genlik, güç ve enerji gibi özelliklerinin incelenmesi) çıkarılmıştır. CBS verilerindeki mekânsal parametrelerden mesafe, alan, engel yoğunluğu ve rota karmaşıklığı gibi özellikler türetilerek modele entegre edilmiştir. GNSS, IMU ve LiDAR gibi sensör verileri füzyonlanarak, türetilmiş yüksek doğruluklu konum, hız, ivme ve engel tespiti gibi özellik kümeleri oluşturulmuştur. Teslimat başına enerji tüketimi, görev süresi, başarı oranı ve çevresel koşullar altında performans gibi operasyonel metrikler hesaplanarak zenginleştirilmiş özellikler elde edilmiştir.

Veri temizliği ve gürültü azaltma

Veri temizliği ve gürültü azaltma süreçleri, OHKA'larda DL tabanlı lojistik planlama sistemlerinde model başarısı ve güvenilirliği açısından kritik öneme sahiptir. Ham verilerin çoğunlukla eksik, hatalı, tutarsız veya gürültülü yapılar içermesi nedeniyle, bu verilerin analiz ve modelleme için uygun hale getirilmesi amacıyla sistematik ve çok katmanlı bir temizleme ile gürültü azaltma süreci uygulanmıştır.

Veri temizliđi kapsamında, telemetri, CBS, meteorolojik ve operasyonel teslimat verilerinde eksik deđerler otomatik olarak tespit edilmiřtir. Bu eksik kayıtlar, bazı temel istatistiksel yöntemlerin yanı sıra KNN imputasyonu gibi daha gelişmiş tamamlama teknikleriyle doldurulmuřtur.

Aykırı deđer analizi, özellikle sensör hatası, iletişim kesintisi veya operasyonel anomalilerin neden olabileceđi uç deđerlerin saptanmasını kapsamış; Z-skor, IQR ve görsel analiz yöntemleri tercih edilerek bu kayıtlar deđerlendirilmiştir. Gerektiğinde aykırı deđerler temizlenmiş ya da modele uygun şekilde yeniden ölçeklendirilmiştir.

Aynı olaya ilişkin yinelenen kayıtlar ya da veri giriş hatalarına bađlı oluşan tutarsızlıklar tespit edilerek veri bütünlüğünü bozmayacak biçimde düzeltilmiş veya veri setinden çıkarılmıştır.

Tüm deđişkenler, analiz ve modelleme süreçlerine uyumlu olacak şekilde standart veri tiplerine dönüřtürülmüş; tarih-saat bilgileri dođru zaman damgası biçiminde kodlanmış, sayısal ve kategorik dönüřümler tutarlı biçimde uygulanmıştır.

GNSS, IMU ve LiDAR gibi sensörlerden gelen verilerin füzyonu ile farklı kaynaklardan gelen bilgi entegre edilerek sensör hatalarından oluşabilecek gürültü azaltılmış; kalibrasyon algoritmalarıyla sensörler arası tutarlılık sağlanmıştır.

Özellikle uçuř dinamikleri ve motor titreřim analizlerinde, Fourier dönüřümü ve dalgacık tabanlı gürültü giderme teknikleriyle yüksek frekanslı gürültü bileřenlerinin ayrıştırılması sağlanmıştır.

Matplotlib ve Seaborn ile görsel analizler gerçekleştirilerek, veri dađılımı, uç deđerler ve gürültü seviyeleri analiz öncesinde kontrol edilmiş, gerekli ön düzenlemeler gerçekleştirilmiştir.

Bu dođrultuda temiz ve gürültüsüz veri alt yapısı, DL modellerinin dođruluk ve genellenebilirliğini önemli ölçüde artırmış; sistemin gerçek zamanlı adaptasyon kapasitesini ve karar destek yeteneklerini güçlendirmiřtir.

Özellik ölçeklendirme ve normalizasyon teknikleri

Özellik ölçeklendirme ve normalizasyon, OHKA'larda DL tabanlı lojistik planlama süreçlerinde model başarısı ve hesaplama verimliliđi açısından kritik bir aşama olarak deđerlendirilmektedir. Farklı kaynaklardan elde edilen ve ölçekleri birbirinden farklı olan veri türlerinin, DL modellerine uygun biçimde dönüřtürülmesi için çeřitli sayısal dönüřüm teknikleri uygulanmaktadır.

Min-Max normalizasyonu, her bir özelliğin değerlerinin önceden belirlenen minimum ve maksimum değerler aralığında (genellikle 0–1) ölçeklenmesini sağlar. Bu yöntem, özellikle geniş aralıklı verilere sahip telemetri, enerji tüketimi ve sensör çıktıları gibi değişkenlerin model eğitimi sürecinde dengeli bir şekilde temsil edilmesini mümkün kılar. Min-Max normalizasyonu Eşitlik (1)'de ifade edilmiştir.

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

Z-skor standardizasyonunda, her bir özellik ortalaması sıfır ve standart sapması bir olacak şekilde dönüştürülmektedir. Bu yöntem, özellikle farklı dağılımlara sahip veri türlerinde modelin ağırlık güncellemelerinde dengeyi koruyarak öğrenme sürecinin stabilitesini artırmaktadır. Z-skor hesaplaması Eşitlik (2)'de ifade edilmiştir.

$$x_{std} = \frac{x - \mu}{\sigma} \quad (2)$$

Robust ölçekleme, medyan ve IQR kullanılarak gerçekleştirilen bir yöntem olup, aykırı değerlere karşı dayanıklı özelliklerin dönüşümünü sağlamaktadır. Bu teknik, özellikle uç değerlerin yoğun biçimde görüldüğü sensör verileri ve operasyonel kayıtlar üzerinde tercih edilmektedir. Robust ölçekleme Eşitlik (3)'de ifade edilmiştir.

$$x_{robust} = \frac{x - \text{medyan}}{\text{IQR}} \quad (3)$$

L2 ve L1 normalizasyonu, özellikle vektör temelli özellikler üzerinde uygulanmakta olup, her bir örneğin normunun bir olacak şekilde ölçeklenmesini sağlamaktadır. L2 normunda, tüm özelliklerin karelerinin toplamı bire eşitlenirken; L1 normunda, tüm özelliklerin mutlak değerlerinin toplamı bir olacak biçimde düzenleme yapılmaktadır.

Bu tekniklerin uygulama alanları arasında telemetri ve sensör verileri yer almakta; farklı ölçeklerdeki hız, irtifa ve sıcaklık gibi parametrelerin aynı aralıkta modellere girdi olarak sunulması sağlanmaktadır. CBS ve mekânsal veriler kapsamında ise mesafe, alan ve yoğunluk gibi değişkenler, model eğitimi için karşılaştırılabilir hale getirilmiştir. Operasyonel teslimat verilerinde ise teslimat süresi, maliyet ve başarı oranı gibi parametreler bu yöntemler aracılığıyla modelin öğrenme sürecinde ağırlık dengesini koruyacak biçimde dönüştürülmüştür.

Bu işlemler, model eğitim pipeline'ına entegre (birden fazla işlem adımının veya modülün otomatik, kesintisiz ve birbiriyle uyumlu şekilde çalışacak biçimde bir araya getirilmesi) edilerek tüm ön işleme adımları sistemli ve sürdürülebilir şekilde uygulanmıştır.

Sonuç olarak, doğru ölçeklendirilmiş ve normalize edilmiş veri sayesinde DL modellerinin daha hızlı, stabil ve verimli şekilde eğitilmesi mümkün olmuş; farklı veri kaynaklarının aynı aralıkta temsili, modeli yeni ve görülmemiş verilere karşı daha dayanıklı hale getirmiştir. Ayrıca, büyük veri setlerinde ağırlık güncellemeleri sırasında oluşabilecek sayısal taşmaların ve öğrenme hızındaki dengesizliklerin önüne geçilerek, yüksek seviyede sayısal kararlılık sağlanmıştır.

Zaman serisi verilerinde özellik çıkarımı

Zaman serisi verilerinde özellik çıkarımı, ham zaman serisi kayıtlarının DL ve ML modelleri için anlamlı, özetleyici ve model öğrenmesine uygun özniteliklere dönüştürülmesini sağlamaktadır. Bu süreç, modelin doğruluk, genellenebilirlik ve yorumlanabilirlik düzeyini artırmakta olup hem temel istatistiksel yöntemleri hem de dönüşümsel analiz tekniklerini kapsamaktadır.

İstatistiksel özellikler kapsamında, zaman serisi verilerinden ortalama, medyan, varyans, standart sapma, çeyrekler arası aralık, maksimum ve minimum değer gibi temel özet değerler hesaplanmakta; ayrıca dağılım biçimini tanımlamak amacıyla çarpıklık ve basıklık gibi istatistiksel metrikler de öznitelik olarak dâhil edilmektedir.

Zaman alanı özelliklerinde, lag özellikleri (örneğin lag-1 veya lag-2) olarak önceki zaman adımlarındaki değerler yeni değişkenler şeklinde modele entegre edilmektedir. Hareketli istatistikler kapsamında ise hareketli ortalama, hareketli standart sapma ile maksimum ve minimum değerler belirli zaman pencereleri boyunca hesaplanarak zaman serisindeki dinamik değişim yakalanmaktadır. Ayrıca, otokorelasyon ve kısmi otokorelasyon ölçümleri uygulanarak, bir zaman serisinin kendi gecikmeli değerleriyle olan ilişkisi öznitelik olarak çıkarılmaktadır.

Zaman tabanlı öznitelikler kapsamında, zaman damgalarından yıl, ay, hafta, gün, hafta içi/hafta sonu ve tatil gibi takvimsel göstergeler elde edilmekte; serinin trend, mevsimsellik ve dönemsel özelliklerini temsil eden özel indeksler de oluşturulmaktadır.

Frekans alanı özelliklerinde, zaman serileri Fourier dönüşümü yoluyla frekans bileşenlerine ayrılmakta; öne çıkan frekanslar ve karşılık gelen genlikler öznitelik olarak kullanılmaktadır. Dalgacık dönüşümü ise hem zaman hem frekans çözünürlüğü sağlayarak özellikle kısa süreli ve lokal değişimleri analiz ederken kullanılmakta, bu süreçten elde edilen bileşenler de öznitelik haline getirilmektedir.

Bileşenlere ayırma yöntemiyle zaman serisi trend, mevsimsellik ve hata bileşenlerine ayrılmakta; bu bileşenlerin özet istatistikleri ve varyasyon değerleri modelde girdi olarak kullanılmaktadır.

Otomatik özellik çıkarımı için Python tabanlı tsfresh kütüphanesi kullanılarak yüzlerce zaman serisi özneteliği otomatik biçimde çıkarılabilmekte; önem sırasına göre filtreleme yapılabilmektedir. Ayrıca, TSFEL ve PYTS gibi araçlar, zaman, frekans ve istatistiksel alanlarda zengin öznetelik setlerinin çıkarımında kullanılmaktadır.

Model içerisindeki kullanılan bazı istatistiksel hesaplamalar aşağıda verilmiştir.

$$S = \left(\frac{1}{n}\right) \times \sum_{i=1}^n \left(\frac{x_i - \mu}{\sigma}\right)^3 \quad (4)$$

$$K = \left(\frac{1}{n}\right) \times \sum_{i=1}^n \left(\frac{x_i - \mu}{\sigma}\right)^4 \quad (5)$$

$$L_{k(t)} = X(t - k) \quad (6)$$

$$RM_{w(t)} = \left(\frac{1}{w}\right) \times \sum_{i=0}^{w-1} X(t - i) \quad (7)$$

$$R(k) = \left(\sum_{t=1}^{n-k} (X(t) - \mu)(X(t+k) - \mu) \right) / \left(\sum_{t=1}^n (X(t) - \mu)^2 \right) \quad (8)$$

$$\Delta X(t) = X(t) - X(t - 1) \quad (9)$$

$$X(\omega) = \sum_{t=0}^{N-1} x(t) \times e^{-j \times 2\pi \times \omega \times \frac{t}{N}} \quad (10)$$

$$P(\omega) = \frac{|X(\omega)|^2}{N} \quad (11)$$

$$\omega_d = \operatorname{argmax}(|X(\omega)|) \quad (12)$$

$$SC = \frac{\sum_{(\omega)}(\omega) \times P(\omega)}{\sum_{(\omega)} P(\omega)} \quad (13)$$

$$T(t) = a \times t + b \quad (14)$$

$$H(X) = -\sum_{(\omega)} p(x_i) \times \log(p(x_i)) \quad (15)$$

$$W(a, b) = \left(\frac{1}{\sqrt{a}}\right) \times \sum_{(t)} X(t) \times \psi \times \left(\frac{t-b}{a}\right) \quad (16)$$

$$\begin{pmatrix} Min_{w(t)} = \min(X(t - w + 1), \dots, X(t)) \\ Max_{w(t)} = \max(X(t - w + 1), \dots, X(t)) \end{pmatrix} \quad (17)$$

$$CV_{w(t)} = \frac{RS_{w(t)}}{RM_{w(t)}} \quad (18)$$

$$ROC_{k(t)} = \frac{(X(t) - X(t - k))}{X(t - k)} \quad (19)$$

$$MonoInc = \sum_{t=2}^n I(X(t) > X(t - 1)) \quad (20)$$

$$TrendSt = \left| \sum_{t=2}^n sign(X(t) - X(t - 1)) \right| \quad (21)$$

Eşitlik (4) çarpıklık katsayısını, Eşitlik (5) basıklık katsayısını ifade etmektedir. Eşitlik (6) gecikmeli özellikleri ifade etmektedir. Burada $L_{k(t)}$ t anındaki k gecikmeli değeri, $X(t - k)$ ise serinin t - k anındaki orijinal değerini göstermektedir. Eşitlik (7) hareketli ortalamayı (rolling mean) ifade etmektedir. Burada $RM_{w(t)}$ t anındaki w uzunluğundaki hareketli ortalamayı, $X(t - i)$ ise serinin t - i anındaki değerini ifade etmektedir. Eşitlik (8) otokorelasyon fonksiyonu ifade etmektedir. Burada $R(k)$ k gecikmesine karşılık gelen otokorelasyon katsayısıdır. $X(t)$ serinin t anındaki değeri, μ serinin aritmetik ortalaması ve n toplam gözlem sayısıdır. Eşitlik (9) birinci fark alma işlemini ifade etmektedir. Burada $\Delta X(t)$ serinin t anındaki birinci farkını, $X(t)$ serinin t anındaki değerini ve $X(t-1)$ ise bir önceki zaman dilimindeki değerini göstermektedir. Eşitlik (10) ayrık fourier dönüşümünü ifade etmektedir. Burada, $X(\omega)$ ω frekansındaki dönüşüm katsayısını, $x(t)$ serinin t anındaki zaman alanındaki değerini, N toplam örnek sayısını ve j ise sanal birimi göstermektedir. Eşitlik (11) güç spektral yoğunluğunu ifade etmektedir. Burada $P(\omega)$ ω frekansındaki güç spektral yoğunluğunu, $X(\omega)$ ayrık fourier dönüşüm katsayısını ve N toplam örnek sayısını göstermektedir. Eşitlik (12) baskın frekansın belirlenmesini ifade etmektedir. Burada, ω_d en yüksek genliğe sahip frekansı, $|X(\omega)|$ ise fourier dönüşümünün genlik spektrumunu göstermektedir. Eşitlik (13) spektral merkez (spectral centroid) değerini ifade etmektedir. Burada SC spektral merkez değerini, ω frekansı, $P(\omega)$ ise ilgili frekanstaki güç spektral yoğunluğunu göstermektedir. Eşitlik (14) doğrusal (lineer) bir trend modelini ifade etmektedir. Burada, $T(t)$ t anındaki trend değerini, a trendin eğimini (artış veya azalış oranı), t zamanı ve b sabit terimi göstermektedir. Eşitlik (15) entropi fonksiyonunu ifade etmektedir. Burada, $H(X)$ rassal değişken X'in entropisini, $p(x_i)$ X'in x_i değerini alma olasılığını göstermektedir. Eşitlik (16) sürekli dalgacık dönüşümünü ifade etmektedir. Burada $W(a, b)$ ölçek (a) ve yer (b)

parametrelerine göre dalgacık katsayısını, $X(t)$ zaman serisinin t anındaki değerini ve ψ karmaşık eşlenik dalgacık fonksiyonunu göstermektedir. Eşitlik (17) w uzunluğundaki pencere içindeki minimum ve maksimum değeri ifade etmektedir. Burada t anında son w gözlemdeki en küçük değeri veya en büyük değeri, $X(t - w + 1)$ ise bu penceredeki gözlem değerlerini göstermektedir. Eşitlik (18) hareketli varyasyon katsayısını ifade etmektedir. Burada, $CV_{w(t)}$ t anında w uzunluğundaki pencere (belirli uzunlukta art arda gelen gözlemlerden oluşan alt bir veri dilimi) için hesaplanan varyasyon katsayısını, $RS_{w(t)}$ aynı penceredeki standart sapmayı ve $RM_{w(t)}$ ise hareketli ortalamayı göstermektedir. Eşitlik (19) oransal değişim oranı göstergesini ifade etmektedir. Burada $ROC_{k(t)}$ serinin t anındaki değerinin k birim önceki değeriyle oransal değişimini, $X(t)$ serinin t anındaki değerini ve $X(t - k)$ ise k birim önceki değerini göstermektedir. Eşitlik (20) monoton artan sıraların sayısını ifade etmektedir. Burada $MonoInc$ ardışık iki gözlemde $X(t)$ değerinin bir önceki değerden büyük olduğu durumların toplam sayısını, $I(\cdot)$ ise gösterge fonksiyonunu (koşul sağlandığında 1, aksi halde 0 döner) göstermektedir. Eşitlik (21) trendin gücünü (trend strength) ifade etmektedir. Burada $TrendSt$ ardışık gözlemler arasındaki artış ve azalışların toplamının mutlak değerini, $sign(\cdot)$ ise işaret fonksiyonunu (pozitifse +1, negatifse -1, eşitse 0) göstermektedir.

Çıkarılan tüm öznitelikler, model başarısına etkileri açısından istatistiksel testler ve önem analizi yöntemleriyle değerlendirilerek, nihai model yapılandırmasında yalnızca anlamlı değişkenlerin kullanılmasına özen gösterilmektedir. Tablo 5'te özellik türleri, açıklamaları ve kullanım alanları gösterilmiştir.

Tablo 5. Özellik Türleri ve Kullanım Alanları

Özellik Türü	Açıklama	Kullanım Alanı
Ortalama	Serinin ortalaması	Temel istatistik
Hareketli Ortalama	Hareketli pencere ortalaması	Trend ve dalgalanma analizi
Lag-1 Değeri	Bir önceki zaman adımıdaki değer	Otokorelasyon
Fourier Ana Frekansı	En baskın periyodik bileşen	Mevsimsellik, döngü
Trend Bileşeni	Serinin genel eğilimi	Uzun vadeli analiz
Otokorelasyon	Kendi gecikmeli değerleriyle ilişki	Seri bağımlılığı
Zaman Damgası Özellikleri	Gün, hafta, ay, sezon gibi takvimsel bilgiler	Takvimsel desenler

Katkılar ve sonuçlar itibarıyla, zengin ve anlamlı özniteliklerin çıkarılması zaman serisi tabanlı DL modellerinin doğruluk ve genellenebilirlik düzeyini önemli ölçüde artırmaktadır.

Özellik çıkarımı süreci, modelin hangi temel dinamikleri yakaladığını daha net biçimde anlamayı mümkün kılarak modelin yorumlanabilirliğine katkı sağlamaktadır.

Farklı kaynaklardan elde edilen zaman serileri için hem ortak hem de veri kaynağına özgü özniteliklerin çıkarılması, sistem performansının çok boyutlu ve bütüncül şekilde analiz edilmesine imkân tanımaktadır.

Drone telemetri verilerinden özelliklerin belirlenmesi ve seçimi

Drone telemetri verilerinden anlamlı ve model başarısına katkı sağlayan özniteliklerin belirlenmesi, OHKA'larda DL tabanlı lojistik planlama süreçlerinde model doğruluğu, hesaplama verimliliği ve yorumlanabilirliği açısından kritik rol oynamaktadır. Drone'lardan toplanan telemetri verileri, uçuşun her anında sistemin durumu ve çevresel koşullara ilişkin birçok parametre sunmakta olup; bu parametreler arasından aşağıdaki temel öznitelikler çıkarılmıştır:

- Anlık hız (m/s), drone'un yatay ve dikey eksenlerdeki hız bileşenlerini temsil etmektedir.
- İvme (m/s^2), üç ekseninde ölçülen ivme değerleri ani manevra ve sarsıntı analizlerinde kullanılmaktadır.
- Yön (yaw, pitch, roll) parametreleri, drone'un uzaydaki yönelimi ile uçuş stabilitesini göstermektedir.
- Batarya gerilimi (V), enerji durumu analizleri ve kalan uçuş süresinin tahminlenmesinde kritik öneme sahiptir.
- Motor sıcaklığı ($^{\circ}C$), motor sistemlerinin aşırı ısınma durumu ve potansiyel arıza risklerinin izlenmesinde kullanılmaktadır.
- GPS sinyal gücü, konumlandırma doğruluğu ve genel uçuş güvenliği açısından temel bir parametre olarak değerlendirilmektedir.
- Uçuş kararlılığı, IMU ve diğer sensör verilerinden türetilen bileşik bir metrik olup, sistemin stabilitesini nicel olarak tanımlamaktadır.
- Ayrıca, yükseklik, konum sapması, sinyal gecikmesi, batarya sıcaklığı ve toplam uçuş süresi gibi ek parametreler de öznitelik kümesine dahil edilmiştir.

Model karmaşıklığını azaltmak ve yalnızca öğrenmeye katkı sağlayan niteliklerin belirlenmesi amacıyla çeşitli özellik seçimi yöntemleri kullanılmıştır. Korelasyon matrisi aracılığıyla, özellikler arasındaki doğrusal ilişkiler analiz edilerek yüksek korelasyona sahip ve tekrarlı öznitelikler elenmiştir. Varyans analizi (ANOVA) kullanılarak her bir öznenin hedef değişken üzerindeki etkisi istatistiksel olarak değerlendirilmiş ve anlamlı katkı sunmayan

öznitelikler modelden çıkarılmıştır. Karmaşık ve doğrusal olmayan ilişki yapılarını değerlendirmek amacıyla SHapley katkısız açıklamalar (SHapley additive explanations, SHAP) analizi uygulanmış; böylece modelin hangi özniteliklere ağırlık verdiği detaylı biçimde ortaya konmuştur.

Tüm bu süreçler, Python ortamında otomatikleştirilen ve tekrarlanabilir bir pipeline yapısı ile entegre edilmiş; Scikit-Learn, Pandas ve SHAP gibi kütüphaneler kullanılarak veri temizleme, dönüşüm, öznitelik çıkarımı ve öznitelik seçimi işlemleri sırasıyla gerçekleştirilmiştir.

Bu yapı sayesinde, eksik değer doldurma, aykırı değer temizliği ve standardizasyon işlemlerine dayanan veri ön işleme süreci tamamlandıktan sonra, yukarıda listelenen telemetri öznitelikleri otomatik biçimde türetilmiş; korelasyon, ANOVA ve SHAP analizleri ardışık olarak uygulanarak yalnızca öğrenmeye anlamlı katkı sunan öznitelikler seçilmiştir.

Bu bütüncül yaklaşımın araştırmaya katkıları; model karmaşıklığı ve hesaplama yükünün azaltılması, model doğruluk ve genellenebilirlik düzeyinin artırılması, SHAP analizi ile modelin karar mekanizmasının açıklanabilir hale getirilmesi ve otomatik pipeline yapısıyla yeni veri setleri üzerinde aynı işlemlerin tekrarlanabilirliğinin sağlanmasıdır. Söz konusu telemetri odaklı öznitelik belirleme ve seçimi yaklaşımı, DL modellerinin hem etkinliğini hem de güvenilirliğini önemli ölçüde artırmaktadır.

DL Modellerinin Tasarımı ve Uygulanması

OHKA'larda lojistik planlama için DL modellerinin tasarımı ve uygulanması, sistemin gerçek zamanlı karar alma, rota optimizasyonu, çevresel adaptasyon ve operasyonel verimlilik gibi kritik süreçlerinde temel rol oynamaktadır. Bu bölümde, kullanılan model mimarileri, eğitim süreçleri, entegrasyon stratejileri ve uygulama adımları ayrıntılı şekilde incelenmiştir.

Araştırmada çoklu model yaklaşımı benimsenmiş ve farklı lojistik süreçler için çeşitli DL mimarileri entegre edilmiştir. Görüntü işleme ve nesne tespiti için CNN, zaman serisi analizleri ve talep tahmini amacıyla LSTM, rota optimizasyonu ve karar destek için Deep Q-Network (DQN) ile GNN modelleri kullanılmıştır. Modüler tasarım yaklaşımıyla her bir model, sistemin ilgili modülüne entegre edilebilecek şekilde bağımsız ve ölçeklenebilir olarak geliştirilmiştir. Bu tasarım, yeni algoritmaların veya veri kaynaklarının sisteme entegrasyonunu kolaylaştırmaktadır. Özellikle uçuş sırasında çalışan modellerde düşük gecikme ve hafif parametre yapısına sahip mimariler (örneğin MobileNetV2 tabanlı CNN) tercih edilmiştir.

Eğitim sürecinde veri kümeleri eğitim, doğrulama ve test olarak ayrılmış; çapraz doğrulama ve hiperparametre optimizasyonu uygulanmıştır. Gerçek veri yetersizliğinde, GAN tabanlı sentetik veri üretimi ile modelin genellenebilirliği artırılmıştır.

Gerçek zamanlı karar destek için LSTM ve DQN tabanlı modeller, canlı trafik, hava durumu ve operasyonel veri akışını işleyerek rota ve görev optimizasyonu sağlamıştır. LSTM ile trafik ve çevresel değişkenlerin kısa vadeli tahmini yapılırken, DQN ile adaptif rota kararları alınmıştır. Görüntü işleme ve nesne tespitinde CNN tabanlı modeller, drone kameralarından elde edilen görüntülerde engel, insan ve hedef nesne tespiti amacıyla kullanılmış; SSD MobileNetV2 gibi hafif CNN mimarileri gömülü sistemlerde gerçek zamanlı nesne tespitine imkân tanımıştır. Ağ analizleri ve lojistik optimizasyonunda GNN tabanlı modeller ise teslimat ağı üzerindeki düğüm ve kenar ilişkilerini analiz ederek, çoklu teslimat noktası ve filo yönetimi için optimizasyon sağlamıştır. Geliştirilen modeller hem simülasyon ortamında hem de saha testlerinde doğrulanmış, simülasyonlar farklı senaryolarda modelin dayanıklılığı ve adaptasyon yeteneğini ölçmek için kullanılmıştır.

Model kararlarının açıklanabilirliğini artırmak amacıyla SHAP analizi uygulanmış ve model çıktısına hangi özniteliklerin hangi ölçüde etki ettiği belirlenmiştir. Açıklanabilir yapay zekâ kapsamında kritik karar noktalarında modelin hangi parametrelere dayalı karar verdiği görselleştirilmiş ve raporlanmıştır.

DL tabanlı rota optimizasyonu operasyonel verimlilikte anlamlı iyileşmeler sağlamış; teslimat süresi ve maliyetlerde önemli azalmalar (örneğin, teslimat süresinde %21 ve enerji tüketiminde %13 azalma) elde edilmiştir. Gerçek zamanlı meteorolojik ve trafik verisiyle çalışan modeller, sistemin çevresel değişkenlere adaptasyonunu güçlendirmiştir. Nesne tespiti ve karar destek modellerinde %93'ün üzerinde doğruluk oranları elde edilmiştir. Ayrıca modüler mimari, yeni algoritmalar ve veri kaynaklarının sisteme kolay entegrasyonunu mümkün kılmıştır.

Kullanılan DL teknikleri

OHKA'ların lojistik planlama süreçlerinde, sistemin farklı gereksinimlerine ve veri türlerine uygun çeşitli DL teknikleri entegre edilmiştir. Bu teknikler, rota optimizasyonu, çevresel adaptasyon, karar destek, görüntü işleme ve ağ analizleri gibi çok boyutlu görevlerin etkin biçimde yerine getirilmesini sağlamıştır.

CNN mimarileri, görüntü işleme, nesne ve engel tespiti ile harita analizleri gibi görevlerde kullanılmıştır. Drone kameralarından elde edilen görüntülerde hedef nesne ve engel tespiti amacıyla SSD MobileNetV2 gibi hafif ve hızlı CNN mimarileri tercih edilmiştir. Görsel

verinin sınıflandırılması ve segmentasyonu, uçuş güvenliği ile teslimat doğruluğunun artırılmasında etkin rol oynamıştır.

LSTM ağları, telemetri, meteoroloji, trafik ve enerji tüketimi gibi zaman serisi verilerinin analizi ve kısa vadeli tahmini için kullanılmıştır. Bu modeller, uçuş sırasında değişen çevresel koşullar ve operasyonel parametrelere adaptif karar desteği sağlamış, talep tahmini ve dinamik rota planlaması gibi uygulamalarda ön plana çıkmıştır.

GNN yaklaşımları, karmaşık teslimat ağları ve çoklu rota ilişkilerinin modellenmesinde kullanılmıştır. Düğüm ve kenar ilişkilerinin analiz edilmesiyle filo yönetimi ve çoklu teslimat noktası optimizasyonu gerçekleştirilmiş, lojistik ağındaki darboğazlar ile kritik noktaların belirlenmesine katkı sunulmuştur.

DQN ve diğer takviyeli öğrenme (reinforcement learning, RL) yöntemleri, gerçek zamanlı rota optimizasyonu ve karar destek süreçlerinde uygulanmıştır. DQN, çevresel değişkenler ve operasyonel kısıtlar altında en uygun rota ve görev atamasını öğrenerek sistemin adaptasyon yeteneğini artırmıştır. Senaryo bazlı testlerde farklı çevresel ve operasyonel koşullara göre en verimli stratejilerin belirlenmesi sağlanmıştır.

Destekleyici teknikler arasında, yüksek boyutlu telemetri ve sensör verilerinde boyut indirgeme ve öznitelik çıkarımı amacıyla Autoencoder (bir veri setindeki temel özellikleri kendi kendine öğrenen, gözetimsiz (unsupervised) bir yapay sinir ağı mimarisi) ve özellik öğrenme yöntemleri kullanılmıştır. Görüntü işleme ve nesne tespiti görevlerinde ise önceden eğitilmiş modellerin transfer edilmesi yoluyla transfer öğrenme stratejileri uygulanarak model geliştirme süresi ve veri ihtiyacı azaltılmıştır. Kullanım alanları göre DL teknikleri Tablo 6'da gösterilmiştir.

Tablo 6. Kullanım Alanlarına Göre DL Teknikleri

Teknik	Kullanım Alanı	Katkısı
CNN	Görüntü işleme, nesne tespiti	Uçuş güvenliği, engel algılama
LSTM	Zaman serisi analizi, talep/enerji tahmini	Dinamik adaptasyon, tahmin
GNN	Lojistik ağ analizi, filo optimizasyonu	Çoklu rota ve düğüm yönetimi
DQN	Karar destek, rota optimizasyonu	Gerçek zamanlı öğrenme ve adaptasyon
GAN	Sentetik veri üretimi	Veri zenginliği, model genelleme
Autoencoder	Özellik çıkarımı, boyut indirgeme	Hesaplama verimliliği

OHKA'lar için geliştirilen lojistik planlama sisteminde, çok modüllü ve entegre DL teknikleri aracılığıyla yüksek doğruluk, esneklik, çevresel adaptasyon ve operasyonel verimlilik sağlanmıştır. Her bir teknik, sistemin farklı ihtiyaçlarına göre optimize edilerek hem bilimsel hem de uygulamalı açıdan yenilikçi ve güvenilir çözümler sunmuştur.

Konvolüsyonel sinir ağları

CNN, görüntü işleme ve nesne algılama başta olmak üzere OHKA'larda çevresel algı, engel tespiti ve rota optimizasyonu gibi kritik görevlerde yaygın olarak kullanılan DL mimarileridir. CNN'ler, özellikle drone'ların kamera verilerinden anlamlı bilgi çıkarılmasında ve gerçek zamanlı karar destek süreçlerinde temel rol oynamaktadır.

CNN mimarisi, konvolüsyon (filtreleme), aktivasyon (genellikle ReLU), havuzlama (pooling) ve tam bağlantılı (fully connected) katmanlardan oluşmaktadır. Konvolüsyon katmanları, görüntüdeki kenar, şekil ve doku gibi temel özelliklerin otomatik olarak çıkarılmasını sağlamaktadır.

İlk katmanlarda düşük seviyeli özellikler (kenar ve köşe), derin katmanlarda ise daha karmaşık yapılar (nesne ve desen) öğrenilmektedir. Model, büyük hacimli etiketli görüntü veri setleri üzerinde eğitilerek belirli görevler için optimize edilmektedir.

Otonom drone sistemlerinde CNN tabanlı modeller, drone kameralarından elde edilen görüntülerde insan, araç, bina ve ağaç gibi nesneler ile potansiyel engelleri yüksek doğrulukla tespit edebilmekte, böylece güvenli uçuş ve engelden otomatik kaçınma sağlanmaktadır.

Görüntü sınıflandırma ve segmentasyon kapsamında CNN'ler, drone'un çevresini sınıflandırmak, teslimat noktalarını veya iniş alanlarını belirlemek amacıyla kullanılmaktadır. Anlamsal segmentasyon ile alanların ayrıştırılması mümkün kılınmaktadır. Tablo 7'de öne çıkan CNN mimarileri ve bu mimarilerin özellikleri ile kullanım alanları detaylandırılmıştır.

Tablo 7. Öne Çıkan CNN Mimarilerinin Özellikleri ve Kullanım Alanları

Mimari	Özellikler	Kullanım Alanı
VGG16/VGG19	Derin, düzenli yapı ve yüksek doğruluk	Görüntü sınıflandırma
ResNet	Art arda bağlanmış katmanlar (skip connection)	Karmaşık nesne tespiti
MobileNetV2	Hafif, düşük parametrelili ve mobil uyumlu	Gerçek zamanlı ve gömülü sistemler
YOLO	Tek adımda hızlı nesne algılama	Canlı video ve hızlı tespit
Faster R-CNN	Bölge tabanlı ve yüksek doğruluklu algılama	Hassas nesne tespiti

Otonom navigasyonda, görüntü tabanlı rota takibi ve karar mekanizmalarında CNN'ler, doğrudan kamera verisinden rota yönlendirme komutları üretebilmektedir. Bu yöntem, GPS sinyalinin zayıf veya manipüle edilebilir olduğu ortamlarda öncelik kazanmaktadır.

Gerçek zamanlı uygulamalarda ise, hafif ve hızlı mimariler (örneğin MobileNetV2), gömülü sistemlerde nesne tespiti ve sınıflandırma süreçlerinin gerçek zamanlı olarak yürütülmesini mümkün kılmaktadır.

MobileNetV2 gibi mimariler, DL modellerinin gömülü sistemlerde ve düşük güç tüketimiyle çalışmasını sağlamaktadır. Inverted Residuals ve Depthwise Separable Convolutions teknikleri ile parametre ve hesaplama yükü azaltılmıştır. Bu sayede, gerçek zamanlı nesne tespiti ve sınıflandırma görevlerinde drone üzerinde yüksek doğruluk ve hız elde edilmiştir.

Bu mimariler, karmaşık desenleri ve nesneleri manuel özellik mühendisliği gerektirmeksizin otomatik olarak tanıma kapasitesine sahiptir. Farklı çevresel koşullar ve yeni senaryolarda yüksek genelleme performansı sergilerken, hızlı işlem ve düşük gecikme süreleri ile gerçek zamanlı karar desteği sağlayarak operasyonel verimliliği artırmaktadır.

Uygulama sonuçları arasında, otonom drone navigasyonunda yalnızca kamera görüntüsü kullanılarak rota takibi ve engelden kaçınma başarıyla gerçekleştirilmiş ve simülasyon ortamlarında ortalama 1,5 metre sapma ile yüksek doğruluk sağlanmıştır. Ayrıca, YOLO ve Faster R-CNN gibi CNN tabanlı nesne tespit algoritmaları canlı video akışında gerçek zamanlı tespit ve sınıflandırma için kullanılmıştır.

CNN, OHKA'larda çevresel algı, nesne tespiti ve görüntü tabanlı karar destek sistemlerinin temelini oluşturmakta olup, hafif ve optimize edilmiş mimariler sayesinde gerçek zamanlı ve yüksek doğrulukta operasyonel uygulamalar mümkün kılınmaktadır. Bu durum, otonom sistemlerin güvenliği, verimliliği ve adaptasyon kabiliyetini önemli ölçüde artırmıştır.

Uzun kısa süreli bellek ağları ve geçitli tekrarlayan birim

LSTM ve GRU, zaman serisi verilerinin analizi ve modellemesinde yaygın olarak kullanılan tekrarlayan sinir ağı (recurrent neural network, RNN) mimarileridir. OHKA'ların lojistik planlama süreçlerinde, özellikle telemetri, meteoroloji, trafik ve enerji tüketimi gibi dinamik ve ardışık verilerin işlenmesinde kritik rol oynamaktadırlar.

LSTM, klasik RNN'lerin uzun dönemli bağımlılıkları öğrenme konusundaki sınırlamalarını aşmak amacıyla geliştirilmiştir. Unutma (forget), giriş (input) ve çıkış (output) kapıları içeren özel hücre yapıları barındırmakta olup, bu kapılar hangi bilgilerin saklanacağı,

güncelleneceği veya unutulacağına karar vererek uzun süreli bağımlılıkların modellenmesini sağlamaktadır. Özellikle uzun dizilerde bilgi kaybını önlemekte ve zaman içindeki karmaşık ilişkileri yakalayabilmektedir.

GRU, LSTM'ye benzer kapı mekanizmalarına sahip ancak daha basit ve az parametre içeren bir yapıdır. Güncelleme (update) ve sıfırlama (reset) kapılarıyla çalışmakta, hesaplama açısından daha hafif ve hızlı olup bazı durumlarda LSTM ile benzer performans göstermektedir. Daha kısa eğitim süreleri ve daha az veri gereksinimi ile avantaj sağlamaktadır.

LSTM ve GRU modelleri, telemetri verileri, meteorolojik değişkenler ve operasyonel parametreler gibi ardışık verilerin modellenmesinde kullanılarak kısa ve uzun vadeli trendlerin, mevsimselliklerin ve ani değişimlerin yakalanmasına olanak tanımaktadır. Gerçek zamanlı veri akışını işleyerek çevresel koşullara ve operasyonel değişkenlere adaptif rota planlaması yapabilmekte; enerji tüketimi ve teslimat sürelerinin tahmininde yüksek doğruluk sağlamaktadır. Ayrıca, batarya durumu, motor performansı ve uçuş kararlılığı gibi parametrelerin zaman içindeki değişimini analiz ederek erken uyarı sistemleri ve bakım planlamaları için önemli veriler sunmaktadır. LSTM ve GRU modellerinin teknik özellikleri ve karşılaştırılması Tablo 8'de verilmiştir.

Tablo 8. LSTM ve GRU Teknik Özellikler ve Model Karşılaştırması

Özellik	LSTM	GRU
Kapı Sayısı	Üç kapı (giriş, unutma ve çıkış)	İki kapı (güncelleme ve sıfırlama)
Parametre Sayısı	Daha fazla ve daha karmaşık	Daha az ve daha hafif
Eğitim Süresi	Daha uzun	Daha kısa
Performans	Uzun dizilerde genellikle daha iyi	Kısa ve orta uzunlukta dizilerde benzer
Hesaplama Verimliliği	Daha düşük	Daha yüksek
Uygulama Alanları	Karmaşık ve uzun dönemli bağımlılıklar	Hız ve verimlilik gerektiren durumlar

OHKA sistemlerindeki uygulamalar kapsamında, LSTM ve GRU modelleri meteorolojik veriler ile telemetri akışları aracılığıyla çevresel koşullara hızlı adaptasyon sağlamaktadır. Bu modeller, kısa vadeli talep değişimleri ve trafik yoğunluğu gibi operasyonel değişkenlerin tahmininde kullanılmaktadır. Model çıktıları, dinamik görev atama ve rota optimizasyon algoritmalarına entegre edilerek gerçek zamanlı karar destek sistemlerinin operasyonel verimliliği artırılmıştır. Ayrıca, modeller simülasyon ortamlarında çeşitli senaryolarda test edilerek saha uygulamalarına hazır hale getirilmiştir. LSTM ve GRU mimarileri, OHKA'ların lojistik planlamasında zaman serisi verilerinin etkin işlenmesini

mümkün kılarak, sistemin adaptasyon kabiliyetini, doğruluğunu ve operasyonel verimliliğini önemli ölçüde artırmıştır. Her iki model de farklı senaryolara göre avantajlar sağlamaktadır ve uygulamanın gereksinimlerine göre uygun model seçimi yapılabilmektedir. Bu sayede, gerçek zamanlı ve dinamik lojistik süreçlerde güvenilir ve esnek karar destek sistemleri geliştirilmiştir.

Graf sinir ağları

GNN, düğümler (noktalar) ve bu düğümler arasındaki ilişkileri (kenarlar) temsil eden grafik yapılar üzerinde çalışan DL modelleridir. GNN'ler, özellikle karmaşık ve düzensiz yapıya sahip verilerin analizinde, sosyal ağlar, biyoinformatik, kimya ve lojistik gibi alanlarda yaygın olarak kullanılmaktadır. OHKA'ların lojistik planlama sistemlerinde GNN'ler, çoklu teslimat noktaları, filo yönetimi ve rota optimizasyonu gibi grafik tabanlı problemlerin çözümünde kritik bir rol oynamaktadır.

Graf yapısı veri, düğümler (örneğin drone teslimat noktaları) ve bu düğümler arasındaki bağlantılar (rota yolları ve iletişim kanalları) şeklinde modellenmektedir. GNN'lerde her düğüm, komşu düğümlerinden bilgi toplayarak kendi durumu ile birleştirmekte ve bu sayede yeni bir temsil (embedding) oluşturmaktadır; bu süreç çok katmanlı bir şekilde tekrarlanarak düğümlerin çevresel bilgiyi öğrenmesi sağlanmaktadır. GNN'ler, düğümlerin sıralamasına bağlı olmaksızın aynı sonucu üreterek permutasyon invaryantlığı (bir sistemin, fonksiyonun veya modelin, girdi elemanlarının sırası değiştirildiğinde çıktısının değişmemesi durumu) özelliğini göstermekte ve bu durum grafik verilerinin düzensiz yapısına uyum sağlamaktadır. Ayrıca GNN'ler, düğüm sınıflandırması, kenar tahmini ve grafik sınıflandırması gibi farklı seviyelerdeki görevlerde kullanılabilmektedir. GNN mimarileri ve teknik özellikleri Tablo 9'da gösterilmiştir.

Tablo 9. GNN Mimarileri ve Teknik Özellikler

Mimari Türü	Açıklama	Kullanım Alanları
Graph Convolutional Networks (GCN)	Komşu düğümlerin özelliklerini konvolüsyon benzeri işlemlerle birleştirir.	Düğüm sınıflandırma ve ağ optimizasyonu
Graph Attention Networks (GAT)	Düğüm komşularına farklı ağırlıklar vererek dikkat mekanizması uygular.	Kritik düğüm belirleme ve önceliklendirme
Message Passing Neural Networks (MPNN)	Düğüm ve kenar özelliklerini mesajlaşma yoluyla iteratif olarak günceller.	Karmaşık grafik yapılarında genel amaçlı modelleme
Spatio-Temporal GNN (STGNN)	Zaman ve mekân değişkenlerini entegre ederek dinamik grafiklerde kullanılır.	Zaman serisi ve rota takibi

Otonom hava kargo lojistiğinde GNN'ler, teslimat noktaları ile drone filoları arasındaki karmaşık ilişkileri grafik olarak modellemekte ve bu grafik üzerinde düğümler arası en uygun yolların ve görev dağılımının optimizasyonunu sağlamaktadır. Çoğul drone koordinasyonu ve kaynak yönetimi ise GNN tabanlı analizler ile daha etkin bir şekilde gerçekleştirilmektedir. Hava sahasındaki engeller ve riskli bölgeler grafik yapılar aracılığıyla temsil edilmekte ve bu bilgiler uçuş planlamasında GNN tarafından kullanılmaktadır. Ayrıca, gerçek zamanlı çevresel ve operasyonel veriler ile güncellenen grafik yapıları üzerinden hızlı ve adaptif karar destek sistemleri sağlanmaktadır.

GNN'lerin avantajları arasında, grafik verilerinde düzensiz ve karmaşık ilişkilerin doğal yapıları içinde doğrudan işlenebilmesi yer almaktadır. Geleneksel ML ve diğer DL modellerine kıyasla, grafik tabanlı problemlerde %10 ile %40 arasında daha yüksek performans sergilediği gözlemlenmiştir. Ayrıca, farklı büyüklükte ve yapıda grafiklerde çalışabilme esnekliği ve yeni düğüm ile kenar eklemelerine uyum sağlama özelliği ile ölçeklenebilirlik sunmaktadır. Gerçek zamanlı güncellenen verilerle adaptif karar destek sistemlerinin oluşturulması da GNN'lerin önemli bir diğer avantajıdır.

Uygulama örnekleri incelendiğinde, GNN tabanlı modellerin tedarik zinciri yönetiminde talep tahmini, risk analizi ve ürün sınıflandırmasında yüksek doğruluk sağladığı gözlemlenmiştir. Otonom drone ağlarında kritik düğümlerin ve darboğazların tespiti ile hava sahası yönetimi optimize edilmiştir. Çoklu drone görev planlamasında, GNN'ler sayesinde görev dağılımı ve rota optimizasyonunda önemli verimlilik artışları elde edilmiştir. Hem simülasyon ortamlarında hem de saha testlerinde, GNN tabanlı yaklaşımlar lojistik operasyonların esnekliğini ve güvenilirliğini artırmıştır.

GNN, OHKA'ların lojistik planlama sistemlerinde karmaşık grafik yapıların modellenmesi ve analizinde vazgeçilmez bir teknoloji olarak ön plana çıkmaktadır. Çoklu teslimat noktaları, filo yönetimi ve dinamik çevresel koşullar gibi çok boyutlu problemlerde yüksek doğruluk, esneklik ve ölçeklenebilirlik sağlamaktadır. Bu nedenle, GNN tabanlı yaklaşımlar lojistik süreçlerin optimize edilmesi, operasyonel verimliliğin artırılması ve güvenliğin iyileştirilmesi için güçlü bir temel oluşturmaktadır.

Derin pekiştirmeli öğrenme

DRL, OHKA'larda rota optimizasyonu, görev atama, çevresel adaptasyon ve karar destek sistemlerinde yüksek doğruluk ve esneklik sağlayan ileri düzey bir yapay zekâ yöntemidir. Bu alanda en yaygın kullanılan algoritmalar arasında DQN, derin deterministik

politika gradyanı (deep deterministic policy gradient, DDPG) ve yakın politika optimizasyonu (proximal policy optimization, PPO) bulunmaktadır.

DQN, Q-learning algoritmasının derin sinir ağı ile genişletilmiş hâlidir. Ajan, çevreyle etkileşim sonucunda durum-eylem değer fonksiyonunu (Q-fonksiyonu) öğrenmekte ve her durumda en yüksek ödülü sağlayan eylemi seçmektedir. DQN, otonom drone'ların rota planlama, engelden kaçınma ve teslimat optimizasyonu gibi ayrık eylem alanı gerektiren görevlerinde kullanılmaktadır (Chen *et al.* 2022; Suanpang and Jamjuntr 2024; Sánchez-Soriano *et al.* 2024). Bu algoritmanın avantajları arasında dinamik ve karmaşık ortamlarda ajanların çevreyi keşfetmesini ve optimal stratejiler geliştirmesini sağlaması yer almaktadır. Simülasyon çalışmaları, DQN tabanlı sistemlerin geleneksel yöntemlere kıyasla teslimat süresinde %12,8 oranında kısalma ve enerji verimliliğinde %8,4 artış sağladığını göstermiştir (Suanpang and Jamjuntr 2024). Ayrıca, DQN ile eğitilen drone'lar, uçuş sırasında çevresel değişikliklere hızlıca uyum sağlayabilmekte ve rota üzerinde yeniden planlama yapabilmektedir.

DDPG, sürekli eylem alanlarında çalışan ve aktör-eleştirmen (actor-critic) mimarisine sahip bir algoritmadır. Aktör ağı, belirli bir durumda seçilecek eylemi belirlerken, eleştirmen ağı bu eylemin değerini tahmin etmektedir (Fei *et al.* 2024). DDPG, drone'larda hassas manevra, hız ve yön kontrolü gibi sürekli kontrol gerektiren görevlerde etkin bir şekilde kullanılmaktadır. Algoritmanın avantajları arasında sürekli ve yüksek boyutlu eylem alanlarında etkin çalışma yeteneği, hızlı ve stabil öğrenme süreçleriyle gerçek zamanlı uçuş kontrolü ve enerji yönetimi sağlaması bulunmaktadır (Ağralı vd. 2021). DDPG ile eğitilen sistemler, otonom iniş, hassas rota takibi ve enerji optimizasyonu gibi karmaşık görevlerde yüksek başarı oranı göstermektedir.

PPO, aktör-eleştirmen tabanlı olup, politika güncellemelerinde aşırı değişiklikleri engelleyen ve öğrenmenin stabil kalmasını sağlayan bir algoritmadır. PPO hem sürekli hem de ayrık eylem alanlarında kullanılabilir (Farahani *et al.* 2024; Verbakel 2024; Wang and Liu 2024). Kullanım alanları arasında lojistikte çoklu drone koordinasyonu, dinamik görev atama, depo içi robot hareketleri ve gerçek zamanlı rota planlama gibi karmaşık ve değişken senaryolar yer almaktadır. PPO'nun avantajları arasında yüksek boyutlu durum ve eylem alanlarında stabil ve hızlı yakınsama sağlaması ile çoklu robot veya drone koordinasyonunda iş birliği ve adaptasyon kapasitesini artırması bulunmaktadır. PPO tabanlı modeller, gerçek zamanlı karar alma ve patika planlama (özellikle robotik, otonom araçlar, dronlar ve benzeri sistemlerde, bir başlangıç noktasından bir hedefe engellere çarpmadan ve belirli kısıtları dikkate alarak en uygun yolu belirleme süreci) görevlerinde çevresel değişkenlere karşı hızlı

adaptasyon ve yüksek görev tamamlama oranı sunmaktadır. DQN, DDPG ve PPO algoritmalarının karşılaştırılması Tablo 10’da gösterilmiştir.

Tablo 10. DQN, DDPG ve PPO Karşılaştırma Tablosu

Algoritma	Eylem Alanı	Mimari	Kullanım Alanı	Avantajları
DQN	Ayrık	Q-Network	Rota planlama ve engelden kaçınma	Hızlı öğrenme ve düşük hesaplama maliyeti
DDPG	Sürekli	Aktör-eleştirme	Hassas kontrol ve enerji yönetimi	Sürekli kontrol ve yüksek doğruluk
PPO	Sürekli/Ayrık	Aktör-eleştirme	Çoklu ajan ve dinamik görev atama	Stabil öğrenme ve hızlı yakınsama

DRL algoritmaları, otonom hava kargo sistemlerinde rota optimizasyonu, enerji verimliliği ve görev başarısı gibi performans metriklerinde geleneksel yöntemlere kıyasla önemli iyileşmeler sağlamıştır. Bu algoritmalar, değişken çevre koşullarına ve operasyonel kısıtlamalara karşı sistemin adaptasyon kabiliyetini artırmakta olup, özellikle PPO ve DDPG algoritmaları gerçek zamanlı veri akışı ile sürekli güncellenen ve optimize edilen karar destek sistemlerinin temelini oluşturmaktadır.

Üretici karşıt ağlar

GAN, OHKA’ların lojistik planlama süreçlerinde veri zenginliği sağlamak, model genellenabilirliğini artırmak ve gerçek operasyon verisinin yetersiz olduğu durumlarda sentetik veri üretmek amacıyla kullanılan güçlü DL modelleridir. GAN’lar, üretici ve ayırt edici olmak üzere iki sinir ağı modelinin karşılıklı rekabetiyle gerçekçi veri örnekleri üretmektedir. Üretici ağ, rastgele gürültüden başlayarak gerçek veri dağılımına benzer sentetik veriler oluştururken; ayırt edici ağ, gerçek veri ile sentetik veriyi ayırt etmeye çalışmakta ve üreticinin performansını değerlendirmektedir. Bu rekabetçi eğitim süreci sonunda üretici, gerçek veriye yüksek derecede benzeyen sentetik veriler üretmektedir.

Otonom hava kargo lojistiğinde GAN’lar; gerçek operasyon verisinin yetersiz olduğu durumlarda telemetri, sensör ve operasyonel veri setlerini genişletmek suretiyle veri çeşitliliğini artırmakta ve aşırı öğrenme (overfitting) riskini azaltmaktadır. Ayrıca farklı uçuş ve teslimat senaryoları için gerçekçi sentetik veriler üretilerek modellerin çeşitli koşullara karşı dayanıklılığı test edilmektedir. Veri dengesi sağlamak amacıyla, sınıf dengesizliklerinin bulunduğu veri setlerinde az temsil edilen durumlar için sentetik örnekler oluşturulmakta ve bu sayede model performansı iyileştirilmektedir. GAN tabanlı yaklaşımlar, normal veri dağılımını öğrenmek suretiyle anomali ve hata tespitinde de kullanılabilir. Tablo 11’de kullanılan GAN mimarileri ve kullanım alanları gösterilmiştir.

Tablo 11. Kullanılan GAN Mimarileri ve Kullanım Alanları

GAN Türü	Açıklama	Kullanım Alanları
Vanilla GAN	En temel GAN mimarisi olup, üretici ve ayırt edici ağların basit yapısına dayanır.	Sentetik veri üretimi ve temel model geliştirme
Conditional GAN	Hem üretici hem de ayırt edici ağa ek olarak belirli koşullar veya etiketler sağlanır.	Koşullu veri üretimi ve spesifik senaryolar
Deep Convolutional GAN	Konvolüsyonel sinir ağları temelli bu mimari, özellikle görüntü verileri ile zaman serisi analizinde başarılıdır.	Görüntü işleme, telemetri ve sensör verisi üretimi
Wasserstein GAN	Geleneksel GAN'lara kıyasla, eğitim sürecinde daha yüksek kararlılık sağlayan ve mod çökmesi (mode collapse) problemini azaltan bir yapıya sahiptir.	Daha stabil ve kaliteli sentetik veri üretimi
CycleGAN	Farklı veri dağılımları arasında karşılıklı dönüşüm gerçekleştirebilen bir GAN türüdür.	Veri dönüşümü ve farklı ortam verilerinin eşleştirilmesi

Uygulama açısından, GAN ile üretilen sentetik telemetri ve operasyonel veriler model eğitiminde gerçek verilerle birlikte kullanılarak model genellenebilirliği artırılmıştır. Sentetik veriler sayesinde DL modelleri nadir ve uç durum senaryolarına karşı daha dayanıklı hale getirilmiş, gerçekçi veri üretimi ise simülasyon ortamlarının doğruluğunu ve güvenilirliğini yükseltmiştir. Wasserstein GAN ve Deep Convolutional GAN gibi gelişmiş GAN mimarileri, eğitim sürecinde mod çökmesini önleyerek yüksek kaliteli veri üretimi sağlamıştır.

GAN'ların avantajları arasında, veri yetersizliği probleminin aşılması; model doğruluk, genellenebilirlik ve dayanıklılığının artırılması; esnek ve koşullu veri üretimi (örneğin Conditional GAN ile belirli koşullara göre özelleştirilmiş veri sağlanması) ve simülasyon ile test süreçlerinin iyileştirilmesi yer almaktadır. GAN, OHKA'ların lojistik planlamasında veri zenginliği ve model dayanıklılığı sağlayarak, gerçek veri yetersizliğini ve çeşitlilik sorunlarını çözmede kritik bir yapay zekâ teknolojisi olarak ön plana çıkmaktadır. GAN tabanlı sentetik veri üretimi hem bilimsel araştırmalarda hem de pratik uygulamalarda sistemlerin esnekliğini ve adaptasyon kabiliyetini artırmakta ve böylece OHKA sistemlerinin lojistik süreçlerinde yüksek doğruluk, verimlilik ve güvenlik sağlamaktadır.

Model eğitim ve hiperparametre optimizasyonu

Model eğitimi ve hiperparametre optimizasyonu, OHKA'ların lojistik planlama sistemlerinde DL modellerinin başarısını doğrudan etkileyen kritik aşamalar olarak değerlendirilmektedir. Eğitim süreci, verilerin kapsamlı ön işleme tabi tutulması ve özellik çıkarımı ile başlamakta; ardından bu veriler eğitim, doğrulama ve test setlerine ayrılmaktadır. Modeller, geri yayılım (backpropagation) ve Adam veya RMSprop gibi optimizasyon algoritmaları ile eğitilmekte, model ağırlıkları kayıp fonksiyonunun minimize edilmesine dayanarak güncellenmektedir. Eğitim verileri, mini-batch olarak adlandırılan küçük parçalara bölünerek modele sunulmaktadır. Bir epoch, modelin tüm eğitim verisi üzerinde bir kez tamamen eğitilmesi anlamına gelmektedir. Batch boyutu ve epoch sayısı, modelin öğrenme sürecini ve genel performansını doğrudan etkileyen önemli hiperparametrelerdir. Aşırı öğrenmeyi önlemek amacıyla, doğrulama kaybının belirli bir sürede iyileşme göstermemesi halinde erken durdurma (early stopping) uygulanmakta ve en iyi doğrulama performansını gösteren model ağırlıkları kaydedilerek gerektiğinde yeniden kullanılmaktadır.

Hiperparametre optimizasyonu kapsamında; öğrenme hızı, batch büyüklüğü, katman sayısı, nöron sayısı, aktivasyon fonksiyonları ve düzenleme parametreleri gibi eğitim sırasında öğrenilmeyen dış parametreler belirlenmektedir. Optimizasyon yöntemleri arasında ızgara arama (grid search), rastgele arama (random search), Bayesian optimizasyon ve genetik algoritmalar gibi popülasyon tabanlı evrimsel yaklaşımlar yer almaktadır. Model doğruluğu, kayıp fonksiyonu, F1 skoru, MAE ve MSE gibi performans metrikleri hiperparametre seçimi için temel ölçütler olarak kullanılmaktadır. Ayrıca, çapraz doğrulama yöntemiyle eğitim verisi farklı alt kümelerle ayrılarak modelin genellenebilirliği test edilmekte ve bu doğrultuda hiperparametre ayarları optimize edilmektedir.

Model eğitimi ve hiperparametre optimizasyon süreçleri, Scikit-Learn, Optuna ve Hyperopt gibi Python tabanlı kütüphaneler kullanılarak otomatik hale getirilmiş; pipeline entegrasyonu ile tekrarlanabilirlik ve sürdürülebilirlik sağlanmıştır. GPU ve TPU hızlandırmaları ile paralel işlem tekniklerinin uygulanmasıyla eğitim ve optimizasyon süreleri minimize edilmiştir.

Izgara arama ve rastgele arama yöntemleri

DL ve ML modellerinde hiperparametre optimizasyonu, model doğruluğu ve genellenebilirliğinin artırılması açısından kritik bir aşamadır. Bu bağlamda, ızgara arama ve rastgele arama yaygın olarak kullanılan iki temel arama yöntemidir.

Izgara arama yöntemi, hiperparametrelerin önceden belirlenmiş değerlerinden oluşan bir ızgara (grid) üzerinde tüm olası kombinasyonları sistematik olarak deneyerek her kombinasyon için model eğitimi ve doğrulama performansının değerlendirilmesini içerir; ardından en iyi performans gösteren hiperparametre seti seçilmektedir. Bu yöntemin çalışma prensibi, hiperparametreler için belirli değer aralıklarının tanımlanması, tüm kombinasyonların denenmesi ve genellikle çapraz doğrulama ile değerlendirilmesidir. Avantajları arasında, tüm olası kombinasyonların sistematik olarak denenmesi sayesinde optimal sonuca ulaşma olasılığının yüksek olması, elde edilen sonuçların tekrarlanabilir ve öngörülebilir nitelikte olması yer almaktadır. Ancak, hesaplama maliyetinin yüksek olması, hiperparametre sayısındaki artışa bağlı olarak kombinasyonların üstel olarak çoğalması ve özellikle yüksek boyutlu ya da geniş aralıklı hiperparametreler söz konusu olduğunda yöntemin verimsiz hale gelmesi başlıca dezavantajlarıdır.

Rastgele arama ise, hiperparametre uzayından rastgele seçilen kombinasyonlar üzerinden model eğitimi ve değerlendirmesi yapar; deneme sayısı kullanıcı tarafından belirlenir ve her denemede parametreler rastgele seçilmektedir. Bu yöntemin çalışma prensibi, hiperparametrelerin olası değer aralıkları veya dağılımlarının tanımlanması, önceden belirlenen sayıda rastgele kombinasyonun seçilip denenmesi ve en iyi performans gösteren kombinasyonun seçilmesidir. Avantajları, çok boyutlu ve geniş aralıklı hiperparametrelerde daha verimli ve hızlı olması, kısıtlı kaynak durumlarında kısa sürede iyi sonuçlar elde edilmesi ve genellikle yalnızca birkaç hiperparametrenin model performansına etkisinin büyük olması nedeniyle önemli bölgelerin daha hızlı keşfedilmesidir. Dezavantajları ise tüm olası kombinasyonların denenmemesi nedeniyle global optimumun garanti edilememesi ve sonuçların rastgeleliğe bağlı olarak değişkenlik göstermesidir.

Izgara arama, küçük ve iyi tanımlanmış hiperparametre aralıklarında optimum sonuca ulaşmak için uygun bir yöntemdir. Rastgele arama ise geniş ve yüksek boyutlu hiperparametre uzaylarında, kaynak kısıtlarının bulunduğu durumlarda veya önemli hiperparametrelerin önceden bilinmediği senaryolarda tercih edilmektedir. Izgara arama ve rastgele arama yöntemlerinin karşılaştırılması Tablo 12’de gösterilmiştir. Bu yöntemlerin kombinasyon kullanımı da mümkündür; öncelikle rastgele arama ile uygun bir aralık belirlenip ardından ızgara arama ile daraltılmış kapsamda detaylı arama yapılabilir (Ogunsanya *et al.* 2023). Yöntemlerin doğru seçimi, model performansını ve eğitim süresini doğrudan etkilemektedir. DL tabanlı lojistik planlama uygulamalarında, hiperparametre optimizasyon sürecinde genellikle rastgele arama ile hızlı bir ön tarama yapılması ve ardından umut vadeden bölgelerde ızgara arama ile ayrıntılı arama gerçekleştirilmesi önerilmektedir.

Tablo 12. Izgara Arama ve Rastgele Arama Karşılaştırma Tablosu

Özellik	Izgara Arama	Rastgele Arama
Arama Stratejisi	Tüm kombinasyonları sistematik dener	Rastgele kombinasyonlar seçer
Hesaplama Maliyeti	Yüksek (özellikle çok boyutlu uzayda)	Daha düşük ve deneme sayısına bağlı
Optimum Bulma	Teorik olarak garantili	Garantili değil, fakat pratikte çoğu zaman yeterli
Esneklik	Sınırlı	Geniş aralıklarda daha esnek
Kullanım Durumu	Küçük ve dar aralıklı hiperparametrelerde	Geniş ve çok boyutlu hiperparametrelerde

Bayesyen optimizasyon

Bayesyen optimizasyon, DL modellerinde hiperparametre ayarlaması için kullanılan ve özellikle yüksek hesaplama maliyeti gerektiren, “kara kutu” fonksiyonların optimizasyonunda avantaj sağlayan bir yöntemdir. Bu yaklaşım, model doğruluğunu ve verimliliğini artırmak amacıyla hiperparametre arama sürecini sistematik ve veri odaklı bir biçimde yönetmektedir.

Temel prensipler ve çalışma mekanizması bağlamında, Bayesyen optimizasyon hedef fonksiyonun (örneğin, doğrulama kaybı veya doğruluk) olasılıksal bir tahminini oluşturmakta olup, genellikle gauss süreci (gaussian process, GP) gibi bir vekil (surrogate) model kullanılmaktadır; bu model, hiperparametre performansını önceki denemelerden öğrenmektedir. Edinim fonksiyonu (acquisition function, AF) ise sonraki test edilecek hiperparametre kombinasyonunu belirlemek için beklenen iyileşme (expected improvement, EI) veya üst güven sınırı (upper confidence bound, UCB) gibi kriterleri kullanmaktadır; bu fonksiyonlar yeni alanları keşfetmeyi (exploration) ve umut vaat eden bölgelere odaklanmayı (exploitation) dengeler niteliktedir. Bayesyen optimizasyon süreci Şekil 10’da gösterilmiştir.

**Şekil 10.** Bayesyen optimizasyon süreci.

Bayesyen optimizasyonun avantajları arasında verimlilik ve hız ön plandadır; bu yöntem, klasik ızgara arama veya rastgele arama yaklaşımlarına kıyasla çok daha az deneme

ile optimum hiperparametreleri bulabilmekte, özellikle yüksek boyutlu ve geniş hiperparametre uzaylarında deneme sayısını %50'ye kadar azaltarak modelin daha hızlı eğitilmesini sağlamaktadır. Model doğruluğu açısından, akıllı arama stratejisi sayesinde hiperparametre ayarı daha hassas yapılmakta ve modelin doğruluk ile F1 skoru gibi performans metriklerinde anlamlı iyileşmeler elde edilmektedir. Kaynak tasarrufu ve maliyet etkinliği bakımından, daha az deneme ile optimum sonuca ulaşılması hem hesaplama süresini hem de donanım maliyetlerini önemli ölçüde azaltmakta, böylece büyük ölçekli projeler ve bulut tabanlı eğitimlerde ciddi maliyet avantajları sağlamaktadır. Bayesyen optimizasyon, ızgara arama ve rastgele arama algoritmaları karşılaştırması Tablo 13'te gösterilmiştir.

Tablo 13. Bayesyen Optimizasyon, Izgara Arama ve Rastgele Arama Karşılaştırma Tablosu

Özellik	Izgara Arama	Rastgele Arama	Bayesyen Optimizasyon
Arama Stratejisi	Tüm kombinasyonları	Rastgele kombinasyon	Olasılıksal model tabanlı
Hesaplama Maliyeti	Çok yüksek	Orta	Düşük
Optimuma Ulaşma Hızı	Yavaş	Orta	Hızlı
Sonuçların Kalitesi	Orta	Orta/İyi	Yüksek
Akıllı Öğrenme	Yok	Yok	Var (geçmiş denemelerden öğrenir)
Uygulama Alanı	Küçük modeller	Genel	Orta/büyük modeller ve pahalı denemeler yapılmaktadır.

Bayesyen optimizasyon, DL modellerinde öğrenme oranı, katman sayısı ve dropout (derin öğrenme modellerinde kullanılan düzenleme yöntemi) oranı gibi hiperparametrelerin optimizasyonunda etkin bir şekilde kullanılmaktadır. Pratik uygulamalarda, Bayesyen optimizasyon sayesinde optimum hiperparametre kombinasyonuna ulaşmak için gereken deneme sayısı 5-10 kat azalmakta ve buna bağlı olarak eğitim süresi ile maliyette %30-40 oranında iyileşme sağlanmaktadır. Otonom hava kargo sistemlerinde ise, model optimizasyonunun hızlandırılması gerçek zamanlı adaptasyon imkânı tanımakta ve operasyonel verimlilik artışına katkı sağlamaktadır.

Erken durdurma ve düzenleme

OHKA'larda DL tabanlı lojistik planlama araştırmasında, modelin aşırı öğrenmesini önlemek ve genellenebilirliğini artırmak amacıyla erken durdurma (early stopping) ve

düzenleştirme (regularization) teknikleri bütünleşik şekilde uygulanmıştır. Bu yöntemler, modelin eğitim sürecinde optimum performansa ulaşmasını ve gerçek dünya koşullarında güvenilir şekilde çalışmasını sağlamıştır.

Erken durdurma, modelin eğitim sürecinde doğrulama (validation) kaybı belirli bir süre boyunca iyileşmediğinde eğitimi otomatik olarak sonlandıran bir tekniktir. Böylece model, eğitim verisine aşırı uyum sağlamadan, en iyi genelleme kabiliyetine ulaştığı noktada durdurulmaktadır. Araştırmada, doğrulama kaybı 10 ardışık epoch (makine öğrenmesinde bir modelin tüm eğitim veri setini baştan sona bir kez gördüğü tam bir döngü) boyunca iyileşme göstermediğinde erken durdurma mekanizması tetiklenmiştir. Bu sayede aşırı öğrenme riski minimize edilmiştir.

Erken durdurma uygulaması ile modelin gereksiz yere uzun süre eğitilmesi ve aşırı öğrenmesi engellenmiş, eğitim süresi ve hesaplama maliyeti azaltılmıştır. En iyi doğrulama performansını gösteren model ağırlıkları kaydedilerek test ve saha uygulamalarında kullanılmıştır.

Düzenleştirme; modelin karmaşıklığını kontrol altında tutmak ve genellenebilirliğini artırmak için kullanılan çeşitli teknikleri içermektedir. L1 ve L2 düzenleştirme yöntemlerinden özellikle L2 (Ridge) düzenleştirme yaygın olarak kullanılmış, bu yöntem model ağırlıklarının karelerinin toplamına ceza uygulayarak modelin aşırı karmaşılaşmasını önlemiştir. Çalışmada kullanılan erken durdurma ve düzenleştirme teknikleri ve katkıları Tablo 14'te gösterilmiştir.

Tablo 14. Kullanılan Erken Durdurma ve Düzenleştirme Teknikleri

Teknik	Uygulama Alanı	Katkısı
Erken Durdurma	Tüm DL modelleri	Aşırı öğrenmeyi ve gereksiz eğitim süresini azaltma
L2 Düzenleştirme	CNN, LSTM, GNN	Model karmaşıklığını kontrol etme ve genelleme artırma
Dropout	CNN, LSTM	Aşırı bağımlılığı azaltma ve genelleme artırma
L1 Düzenleştirme	Özellik seçimi gerektiren modeller	Model sadeleşmesi ve gereksiz ağırlıkların sıfırlanması

Eğitim sırasında dropout tekniği de uygulanmış, %0,2–%0,5 oranında rastgele seçilen nöronların devre dışı bırakılması ile modelin belirli nöronlara aşırı bağımlılığı engellenmiştir. Bu teknik, özellikle CNN ve LSTM tabanlı modellerde başarıyla kullanılmıştır. Düzenleştirme teknikleri erken durdurmayla birlikte uygulanarak hem model karmaşıklığı hem de eğitim süresi optimize edilmiştir.

Uygulama sonuçları, erken durdurma ve düzenlileştirme tekniklerinin birlikte kullanılmasıyla modelin yeni ve görülmemiş veri setlerinde yüksek doğruluk ve genellenebilirlik sağladığını göstermiştir. Eğitim ve doğrulama kayıpları arasındaki fark minimize edilerek modelin yalnızca eğitim verisine değil genel veri dağılımına uyum sağlaması hedeflenmiştir.

Saha testlerinde, erken durdurma ve düzenlileştirme sayesinde modelin ani çevresel değişikliklere karşı dayanıklılığı ve kararlılığı artırılmıştır. Ayrıca gereksiz uzun eğitim süreçleri engellenerek kaynak kullanımı ve eğitim maliyeti optimize edilmiştir.

Eğitim, doğrulama ve test veri setlerinin ayrılması

DL ve ML projelerinde, modelin başarısını ve genelleme yeteneğini objektif biçimde değerlendirebilmek amacıyla veri setinin eğitim, doğrulama ve test olmak üzere üçe ayrılması yaygın ve önerilen bir yöntemdir.

Eğitim seti (training set), modelin örüntüleri öğrenmesi için kullanılan veri kümesini ifade eder ve model, bu veri üzerinden parametrelerini optimize eder. Doğrulama seti (validation set), modelin hiperparametre ayarları ve mimari seçimlerinin değerlendirilmesi için kullanılır; eğitim sırasında modelin aşırı öğrenme eğilimi doğrulama seti üzerinden izlenir ve gerekli ayarlamalar yapılır. Test seti ise modelin eğitimi ve hiperparametre ayarları tamamlandıktan sonra gerçek performansının ölçülmesi için ayrılmış, daha önce kullanılmamış veri kümesidir; modelin genelleme yeteneği bu set aracılığıyla değerlendirilir.

Veri seti ayrımı için kullanılan yöntemler arasında holdout yöntemi (makine öğrenmesinde veri setini eğitim ve test setlerine ayırarak model performansını değerlendirmeye yarayan basit ve yaygın bir teknik), çapraz doğrulama ve katmanlı örnekleme (bir anakütledeki alt grupların her birinin örnekleme orantılı ve adil şekilde temsil edilmesini sağlamak) yer almaktadır. Bu çalışma kapsamında holdout yöntemine göre, veriler %70 eğitim, %15 doğrulama, %15 test olmak üzere üç kümeye bölünmüştür; bu oranlar veri miktarına ve probleme göre değişkenlik göstermiştir. Çapraz doğrulama yöntemi, özellikle veri setinin küçük olduğu durumlarda tercih edilir ve veri birden fazla kez farklı şekillerde eğitim ve doğrulama olarak bölünerek modelin farklı veri alt kümelerinde tutarlı performans gösterip göstermediği analiz edilir. Katmanlı örnekleme ise sınıf dengesizliği bulunan veri kümelerinde sınıfların dağılımını her kümede koruyacak şekilde yapılan ayrımı ifade eder; bu sayede modelin tüm sınıfları dengeli biçimde öğrenmesi sağlanır.

Modüler sistem entegrasyonu ve operasyonel akış

Bu tez çalışmasında geliştirilen otonom hava kargo sistemi, uçtan uca lojistik planlama süreçlerinin yönetilmesini mümkün kılan modüler ve entegre bir mimari üzerine inşa edilmiştir. Söz konusu sistem mimarisi, kullanıcı ve filo yönetimi, teslimat optimizasyonu, meteorolojik tahmin ve otonom uçuş kontrolü gibi işlevsel bileşenlerin bağımsız olarak geliştirilebilmesiyle birlikte, merkezi bir karar destek platformu üzerinde uyumlu bir şekilde çalışmasını sağlamaktadır. Bu modüler yaklaşım; sistemin ölçeklenebilirliğini, esnekliğini ve sürdürülebilirliğini garanti altına alırken, yeni teknolojilerin veya operasyonel gereksinimlerin mevcut işleyişi aksatmadan hızlıca entegre edilebilmesine olanak tanımaktadır.

Operasyonel süreç, bir teslimat görevinin oluşturulmasından başarıyla tamamlanmasına kadar ardışık ve bütünleşik adımlardan oluşmaktadır. İlk aşamada, farklı kaynaklardan elde edilen telemetri, CBS ve meteoroloji verileri, çoklu veri füzyonu teknikleriyle ortak bir referans çerçevesinde birleştirilmekte; müşteri siparişiyle eşzamanlı olarak teslimat görevi tasarlanmakta ve ilgili kargonun, otonom hava aracının taşıma kapasitesine uygun şekilde hazırlanması sağlanmaktadır. Takiben, görev filo yönetim modülüne aktarılmakta, bu modül ise hava durumu, yük ağırlığı, mesafe, filo kapasitesi ve batarya durumu gibi operasyonel değişkenleri dikkate alarak en uygun aracı belirlemekte ve DL algoritmaları yardımıyla en verimli uçuş rotasına atamaktadır. OHKA, atanmış rota üzerinde gelişmiş uçuş kontrol sistemleri ve yapay zekâ destekli navigasyon algoritmaları ile görevini icra ederken, gerçek zamanlı engel algılama ve çarpışma önleme sistemleri de uçuş güvenliğini temin etmektedir.

Tüm operasyon; analitik ve yönetim paneli aracılığıyla gerçek zamanlı olarak izlenmekte, aracın konumu, hızı, irtifası ve sistem sağlığına ilişkin telemetri verileri sürekli olarak operatöre raporlanmakta, böylece olağan dışı durumlara erken müdahale imkânı sunulmaktadır. OHKA varış noktasına ulaştığında, güvenli teslimat süreci biyometrik kimlik doğrulama ile sağlanır ve teslimat başarıyla sistem kayıtlarına geçirilir. Görev sonrası, uçuş süresi, enerji tüketimi ve görev başarı oranı gibi parametreler üzerinde gerçekleştirilen kapsamlı analizler, sistemin sürekli iyileştirilmesine yönelik görsel raporlar olarak yöneticilere sunulmaktadır.

Sistemin başarısı, temel yönetim modüllerinin yetkinliği ile doğrudan ilişkili olup; filo ve görev yönetimi, analitik karar destek paneli ve donanım-yazılım entegrasyonu katmanlarında görülmektedir. Filo ve görev yönetimi modülü, batarya döngüsü, motor saatleri ve sensör kalibrasyonu gibi kritik izleme noktalarının yanında, proaktif bakım ve arıza tespiti süreçlerini otomatikleştirmektedir. Dinamik görev atama ve sürülü operasyon kabiliyeti sağlanarak operasyonel verimlilik yükseltilmekte, yasal gereklilikler ve hava sahası kısıtlamaları gibi

regülasyon süreçleri ise sistem tarafından otomatik izlenmektedir. Aynı bir katmanda, analitik ve karar destek paneli; gerçek zamanlı görselleştirme, anahtar performans göstergelerinin (key performance indicators, KPI) izlenmesi ve elde edilen operasyonel verilerin yöneticilere karar desteği sunacak şekilde analizini mümkün kılmaktadır.

Donanım ve yazılım entegrasyonunda, çoklu sensör (IMU, LiDAR vb.) ile donatılmış ve 2-15 kg kalkış ağırlığı ile 15-80 km menzile sahip drone filosu kullanılmakta; yer istasyonu ile kesintisiz iletişim LoRa, Wi-Fi ve LTE/5G gibi yedekli protokoller üzerinden sağlanmaktadır. Ayrıca İHA trafik yönetimi (unmanned aircraft system traffic management, UTM), hava durumu servisleri ve gerekirse diğer insansız araç sistemleriyle tam entegrasyon sağlanabilmektedir. Yüksek hızlı ve büyük ölçekli DL uygulamaları ile operasyonel analizler için NVIDIA RTX A6000/3090/A100 gibi GPU destekli sunucular ile bulut tabanlı hibrit altyapılar kullanılmaktadır. Bu bütünsel yapı, sistemin operasyonel etkinliğini, güvenliğini ve sürdürülebilirliğini artırmak üzere tasarlanmıştır.

Deneysel Tasarım ve Performans Analiz Yöntemleri

Bu tez çalışmasında otonom hava kargo sisteminin performansını etkileyen çok sayıda faktör ve bu faktörler arasındaki etkileşimleri sistematik olarak incelemek amacıyla Taguchi L54 deney planı seçilmiştir. Taguchi yaklaşımı, minimum sayıda deneme ile maksimum bilgi elde etme ve süreç değişkenliğini optimize etme yeteneği sayesinde tercih edilmiş, böylece hem etkin bir analiz hem de kaynakların verimli kullanımı sağlanmıştır. Deneysel tasarım kapsamında, sistem performansını etkileyebileceği öngörülen yedi ana kontrol faktörü tanımlanmıştır: Filo yönetimi, rota karmaşıklığı, rüzgâr hızı, kargo ağırlığı, uçuş mesafesi, pil durumu ve hava durumudur. Söz konusu faktörlerin farklı seviyelerdeki bileşimleri ($2 \times 3 \times 3 \times 3 \times 3 \times 3 \times 3$) sonucunda toplamda 1458 senaryo yerine L54 deney planına göre 54 senaryo hazırlanmıştır. Deney planı toplamda 4 kez tekrar edilmiştir. Toplamda beş farklı temel performans karakteristiği için 216 ölçüm yapılmıştır. Deney planına göre elde edilen senaryolar, gerçek coğrafi verilerle bütünleşik olarak geliştirilen ve Giresun ili ile 15 ilçesini kapsayan “INCI - Drone Analiz Kontrol Paneli” simülasyon platformunda kapsamlı şekilde test edilmiştir.

Elde edilen geniş veri kümesinin değerlendirilmesi amacıyla endüstriyel kalite standartlarına dayalı, çok boyutlu ve nicel analizlere olanak tanıyan bir performans analiz çerçevesi uygulanmıştır. Öncelikle, sistemin operasyonel verimliliği ve süreç kalitesini nesnel biçimde ölçmek adına çeşitli endüstriyel metodolojilerden yararlanılmıştır. Toplam ekipman etkinliği (overall equipment effectiveness, OEE), sistemin bütüncül verimliliğini kullanılabilirlik, performans oranı ve kalite oranını bir araya getirerek tek bir skor şeklinde ifade

etmiş; bu sayede her senaryoda sistemin genel fonksiyonel etkinliği nicel olarak tespit edilmiştir. Altı sigma metodolojisinden türetilen sigma seviyesi ve hata oranı (defect rate, DR) ise, milyon fırsat başına düşen hata sayısı (defects per million opportunities, DPMO) üzerinden süreç kalitesi ve tutarlılığına dair istatistiksel bir ölçüm sunarak sistemin endüstri standartlarına yakınlığını değerlendirmeye olanak tanımıştır. Ayrıca, süreç yeterlilik indeksi (process capability index, PCI) hesaplanarak sistemin, belirlenmiş spesifikasyon sınırları dahilinde süreç sonuçlarında ne derecede tutarlı olduğu gözlemlenmiştir. Deneysel çalışmada OHKA'lar için optimize edilen beş temel performans karakteristiği şunlardır:

1. Teslimat süresi (dakika),
2. Operasyonel maliyet (TL),
3. Görev başarı oranı (%),
4. Enerji tüketimi (Wh),
5. Karbon ayak izi (kg CO₂)

Bu performans karakteristikleri, her bir deneysel senaryo için simülasyon platformu üzerinden doğrudan ölçülmüştür.

Yukarıdaki performans karakteristiklerinden; teslimat süresi, operasyonel maliyet, enerji tüketimi ve karbon ayak izi değerlerinin minimum olması hedeflendiğinden Eşitlik (22)'de verilen “daha küçük daha iyi” S/N_{LB} oranı seçilmiştir. Görev başarı oranı performans karakteristiği maksimum olması hedeflendiğinden Eşitlik (23)'de verilen “daha büyük daha iyi” S/N_{HB} oranı seçilmiştir.

$$S/N_{LB} = -10 \log_{10} \left(\frac{1}{n} \sum_{i=1}^n y_i^2 \right) \quad (22)$$

$$S/N_{HB} = -10 \log_{10} \left(\frac{1}{n} \sum_{i=1}^n \frac{1}{y_i^2} \right) \quad (23)$$

Altı sigma seviyesi hesaplaması için öncelikle her performans karakteristiği için spesifikasyon limitleri belirlenmiş (örneğin, teslimat süresi için üst limit 120 dakika, başarı oranı için alt limit %95), ardından DPMO değeri Eşitlik (24)'de gösterildiği gibi hesaplanmış, elde edilen DPMO değeri standart sigma dönüşüm tablosu kullanılarak sigma seviyesine çevrilmiştir.

$$DPMO = \frac{\text{Spesifikasyon dışı sonuç sayısı}}{\text{Toplam fırsat sayısı}} \times 1.000.000 \quad (24)$$

Süreç yeterlilik indeksleri Eşitlik (25)'te gösterildiği gibi Cp ve Eşitlik (26)'de gösterildiği gibi Cpk değerlerinin hesaplanmasıyla elde edilmiştir.

$$Cp = \frac{\text{Üst spesifikasyon limiti} - \text{Alt spesifikasyon limiti}}{6 \times \sigma} \quad (25)$$

$$Cpk = \text{Enk} \left[\frac{\text{Üst limit} - \mu}{3 \times \sigma}, \frac{\mu - \text{Alt limit}}{3 \times \sigma} \right] \quad (26)$$

Taguchi L54 deney planı

Bu araştırmada deneysel altyapı olarak, sistem performansını etkileyen çok sayıda kontrol faktörü ile bu faktörler arasındaki etkileşimlerin istatistiksel olarak etkin ve verimli biçimde analiz edilmesini mümkün kılan Taguchi L54 deney planı tercih edilmiştir. Taguchi yaklaşımı, minimum sayıda deney yaparak maksimum düzeyde bilgi edinme ve süreç değişkenliğini minimize etme avantajı sayesinde, en karmaşık operasyonel koşullar altında dahi sistemin davranışının güvenilir ve tekrarlanabilir şekilde modellenmesine olanak tanımıştır.

Deneysel tasarım kapsamında, sistemin operasyonel başarısını etkilediği öngörülen yedi ana kontrol faktörü ve bunların farklı seviyeleri dikkate alınmıştır. Deneyde incelenecek parametreler, seviyeleri ve aralıkları Tablo 15'te gösterilmiştir.

Tablo 15. Deneylerde İncelenecek Parametreler, Seviyeleri ve Aralıkları

Parametreler		Seviyeler		
Kodu	Adı	1	2	3
A	Filo Yönetimi (müdahale)	Manuel Var	Otomatik Yok	
B	Hava Durumu (derece)	Kötü 0 altı	Orta 0-10	İyi 10 üzeri
C	Rüzgar Hızı (km/s)	Düşük 0-15	Orta 16-30	Yüksek 31-45
D	Rota Karmaşıklığı (karşılaşılan eleman sayısı)	Basit 0-18	Orta 19-36	Zor 37 ve üzeri
E	Kargo Ağırlığı (kg)	Hafif 0-9,99	Orta 10-19,99	Ağır 20-29,99
F	Uçuş Mesafesi (km)	Kısa 0-14,99	Orta 15-29,99	Uzun 30 ve üzeri
G	Pil Durumu (%)	Düşük 0-19,99	Orta 20-79,99	Yüksek 80-100

Taguchi L54 deney planı Tablo 16'da gösterilmiştir.

Tablo 16. Taguchi L54 Deney Planı

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26
Deney No	A	B	C	E	F	G	e	e	D	AxD	BxD	BxD	AxBxD	AxBxD	CxD	CxD	DxE	DxE	DxF	DxF	DxG	DxG	e	e	e	e
1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
2	1	1	1	1	1	1	1	1	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
3	1	1	1	1	1	1	1	1	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
4	1	1	2	2	2	2	2	2	1	1	1	1	1	1	2	3	2	3	2	3	2	3	2	3	2	3
5	1	1	2	2	2	2	2	2	2	2	2	2	2	2	3	1	3	1	3	1	3	1	3	1	3	1
6	1	1	2	2	2	2	2	2	3	3	3	3	3	3	1	2	1	2	1	2	1	2	1	2	1	2
7	1	1	3	3	3	3	3	3	1	1	1	1	1	1	3	2	3	2	3	2	3	2	3	2	3	2
8	1	1	3	3	3	3	3	3	2	2	2	2	2	2	1	3	1	3	1	3	1	3	1	3	1	3
9	1	1	3	3	3	3	3	3	3	3	3	3	3	3	2	1	2	1	2	1	2	1	2	1	2	1
10	1	2	1	1	2	2	3	3	1	1	2	2	3	3	1	1	1	1	2	3	2	3	3	2	3	2
11	1	2	1	1	2	2	3	3	2	2	3	3	1	1	2	2	2	2	3	1	3	1	1	3	1	3
12	1	2	1	1	2	2	3	3	3	3	1	1	2	2	3	3	3	3	1	2	1	2	2	1	2	1
13	1	2	2	2	3	3	1	1	1	1	2	2	3	3	2	3	2	3	3	2	3	2	1	1	1	1
14	1	2	2	2	3	3	1	1	2	2	3	3	1	1	3	1	3	1	1	3	1	3	2	2	2	2
15	1	2	2	2	3	3	1	1	3	3	1	1	2	2	1	2	1	2	2	1	2	1	3	3	3	3
16	1	2	3	3	1	1	2	2	1	1	2	2	3	3	3	2	3	2	1	1	1	1	2	3	2	3
17	1	2	3	3	1	1	2	2	2	2	3	3	1	1	1	3	1	3	2	2	2	2	3	1	3	1
18	1	2	3	3	1	1	2	2	3	3	1	1	2	2	2	1	2	1	3	3	3	3	1	2	1	2
19	1	3	1	2	1	3	2	3	1	2	1	3	2	3	1	1	2	3	1	1	3	2	2	3	3	2
20	1	3	1	2	1	3	2	3	2	3	2	1	3	1	2	2	3	1	2	2	1	3	3	1	1	3
21	1	3	1	2	1	3	2	3	3	1	3	2	1	2	3	3	1	2	3	3	2	1	1	2	2	1
22	1	3	2	3	2	1	3	1	1	2	1	3	2	3	2	3	3	2	2	3	1	1	3	2	1	1
23	1	3	2	3	2	1	3	1	2	3	2	1	3	1	3	1	1	3	3	1	2	2	1	3	2	2
24	1	3	2	3	2	1	3	1	3	1	3	2	1	2	1	2	2	1	1	2	3	3	2	1	3	3
25	1	3	3	1	3	2	1	2	1	2	1	3	2	3	3	2	1	1	3	2	2	3	1	1	2	3
26	1	3	3	1	3	2	1	2	2	3	2	1	3	1	1	3	2	2	1	3	3	1	2	2	3	1
27	1	3	3	1	3	2	1	2	3	1	3	2	1	2	2	1	3	3	2	1	1	2	3	3	1	2
28	2	1	1	3	3	2	2	1	1	3	3	2	2	1	1	1	3	2	3	2	2	3	2	3	1	1

Tablo 16. (Devamı)

29	2	1	1	3	3	2	2	1	2	1	1	3	3	2	2	2	1	3	1	3	3	1	3	1	2	2
30	2	1	1	3	3	2	2	1	3	2	2	1	1	3	3	3	2	1	2	1	1	2	1	2	3	3
31	2	1	2	1	1	3	3	2	1	3	3	2	2	1	2	3	1	1	1	1	3	2	3	2	2	3
32	2	1	2	1	1	3	3	2	2	1	1	3	3	2	3	1	2	2	2	2	1	3	1	3	3	1
33	2	1	2	1	1	3	3	2	3	2	2	1	1	3	1	2	3	3	3	3	2	1	2	1	1	2
34	2	1	3	2	2	1	1	3	1	3	3	2	2	1	3	2	2	3	2	3	1	1	1	1	3	2
35	2	1	3	2	2	1	1	3	2	1	1	3	3	2	1	3	3	1	3	1	2	2	2	2	1	3
36	2	1	3	2	2	1	1	3	3	2	2	1	1	3	2	1	1	2	1	2	3	3	3	3	2	1
37	2	2	1	2	3	1	3	2	1	2	3	1	3	2	1	1	2	3	3	2	1	1	3	2	2	3
38	2	2	1	2	3	1	3	2	2	3	1	2	1	3	2	2	3	1	1	3	2	2	1	3	3	1
39	2	2	1	2	3	1	3	2	3	1	2	3	2	1	3	3	1	2	2	1	3	3	2	1	1	2
40	2	2	2	3	1	2	1	3	1	2	3	1	3	2	2	3	3	2	1	1	2	3	1	1	3	2
41	2	2	2	3	1	2	1	3	2	3	1	2	1	3	3	1	1	3	2	2	3	1	2	2	1	3
42	2	2	2	3	1	2	1	3	3	1	2	3	2	1	1	2	2	1	3	3	1	2	3	3	2	1
43	2	2	3	1	2	3	2	1	1	2	3	1	3	2	3	2	1	1	2	3	3	2	2	3	1	1
44	2	2	3	1	2	3	2	1	2	3	1	2	1	3	1	3	2	2	3	1	1	3	3	1	2	2
45	2	2	3	1	2	3	2	1	3	1	2	3	2	1	2	1	3	3	1	2	2	1	1	2	3	3
46	2	3	1	3	2	3	1	2	1	3	2	3	1	2	1	1	3	2	2	3	3	2	1	1	2	3
47	2	3	1	3	2	3	1	2	2	1	3	1	2	3	2	2	1	3	3	1	1	3	2	2	3	1
48	2	3	1	3	2	3	1	2	3	2	1	2	3	1	3	3	2	1	1	2	2	1	3	3	1	2
49	2	3	2	1	3	1	2	3	1	3	2	3	1	2	2	3	1	1	3	2	1	1	2	3	3	2
50	2	3	2	1	3	1	2	3	2	1	3	1	2	3	3	1	2	2	1	3	2	2	3	1	1	3
51	2	3	2	1	3	1	2	3	3	2	1	2	3	1	1	2	3	3	2	1	3	3	1	2	2	1
52	2	3	3	2	1	2	3	1	1	3	2	3	1	2	3	2	2	3	1	1	2	3	3	2	1	1
53	2	3	3	2	1	2	3	1	2	1	3	1	2	3	1	3	3	1	2	2	3	1	1	3	2	2
54	2	3	3	2	1	2	3	1	3	2	1	2	3	1	2	1	1	2	3	3	1	2	2	1	3	3

Taguchi L54 deney tasarımı kullanılarak, bu faktörlerin hem ana etkileri hem de kritik iki faktörlü etkileşimleri sistematik olarak incelenmiştir. Bu kapsamda incelenen etkileşimler;

- Filo yönetimi $\times$ rota karmaşıklığı etkileşimi ($A \times D$) (yönetim stratejilerinin karmaşık rotalardaki operasyonel verimliliğe etkisi)
- Hava durumu $\times$ rota karmaşıklığı etkileşimi ($B \times D$) (meteorolojik koşulların karmaşık rotalarda performans ve risk düzeyine etkisi)
- Rüzgâr hızı $\times$ rota karmaşıklığı etkileşimi ($C \times D$) (rüzgâr şiddetinin karmaşık rotalarda stabilite ve enerji tüketimine etkisi)
- Rota karmaşıklığı $\times$ kargo ağırlığı etkileşimi ($D \times E$) (rota karmaşıklığının yük artışıyla taşıma performansına etkisi)
- Rota karmaşıklığı $\times$ uçuş mesafesi etkileşimi ($D \times F$) (karmaşık rotada menzil artışının teslimat süresine etkisi)
- Rota karmaşıklığı $\times$ pil durumu etkileşimi ($D \times G$) (rota karmaşıklığının batarya verimi ve görev başarısına etkisi)
- Filo yönetimi $\times$ hava durumu $\times$ rota karmaşıklığı etkileşimi ($A \times B \times D$) (eşzamanlı koşullar altında yönetim kararlarının toplam sistem performansına etkisi)

Bu etkileşimlerin seçiminde, rota karmaşıklığının OHKA operasyonlarının merkezinde yer alan kritik bir belirleyici olduğu öngörülmektedir. Rota karmaşıklığı; manevra gereksinimi, rota sapması olasılığı ve görev planlama zorluğu üzerinden, hem sistemin fiziksel kısıtlarını (enerji tüketimi, menzil, pil verimliliği ve yük taşıma kapasitesi) hem de çevresel koşulların (özellikle rüzgâr etkisi ve meteorolojik değişkenlik) operasyonel çıktılar üzerindeki etkisini doğrudan şekillendirmektedir. Bu kapsamda, üçlü bileşik etki ($A \times B \times D$) filo yönetimi kararlarının, hava koşulları ve rota karmaşıklığı ile eşzamanlı etkileşimi altında sistem performansının bütüncül olarak nasıl değiştiğini temsil etmektedir. Bununla birlikte, söz konusu üçlü etkileşimin çok kriterli karar verme çerçevesinde ayrıca değerlendirilmesi gerekliliği nedeniyle, bu bileşik etkinin analizinin mevcut çalışma kapsamı dışında tutulması uygun görülmüştür.

Her bir senaryo, Giresun ili ve 15 ilçesine ait gerçek coğrafi veriler kullanılarak geliştirilmiş “INCI - Drone Analiz Kontrol Paneli” simülasyon platformu üzerinde yürütülmüştür. Böylelikle, elde edilen performans çıktılarının gerçek dünya koşulları ile yüksek oranda tutarlı ve güvenilir olması sağlanmıştır. Ayrıca çalışmanın kapsamından dolayı ekstrem durumların varlığı, orta seviyedeki kombinasyonların doğruluğu ve kritik kararlar verilmesi açısından deneyler, farklı zamanlarda olmak üzere 4 kez tekrarlanmış ve elde edilen sonuçların tutarlılığı artırılmıştır. Bu kapsamlı deneysel tasarım yaklaşımı, sonraki aşamalarda

gerçekleştirilecek olan performans, güvenilirlik ve ekonomik analizler için bilimsel açıdan güçlü, çok boyutlu ve yapılandırılmış bir veri setinin oluşturulmasına imkân vermiştir.

OEE, DR, sigma seviyesi ve PCI analizleri

Deneysel tasarımdan elde edilen senaryo verilerinin operasyonel başarımını kapsamlı ve bütüncül bir biçimde değerlendirmek amacıyla, endüstriyel kalite ve verimlilik alanında uluslararası kabul görmüş analiz yöntemleri uygulanmıştır. Bu yöntemler, sistemin performans, kalite ve süreç tutarlılığını nicel ve nesnel ölçütlerle analiz etmek üzere özel olarak seçilmiştir.

OEE, sistemin genel verimliliğini tek bir metrik altında değerlendirmek için kullanılmıştır. OEE hesaplamasında, senaryolar boyunca sistemin kullanılabilirlik (availability), performans oranı (performance rate) ve kalite oranı (quality rate) bütünleştirilerek her bir senaryo için tekil bir verimlilik skoru elde edilmiştir. Bu sayede, sistemin farklı operasyonel koşullar altındaki genel etkinliği nesnel biçimde karşılaştırılabilir hale getirilmiştir.

DR ve sigma seviyesi analizlerinde ise süreç kalitesi ve üretim tutarlılığı altı sigma yaklaşımı doğrultusunda ele alınmıştır. Bu kapsamda, DPMO hesaplanmış ve elde edilen sonuçlar neticesinde sistemin sigma seviyesi belirlenmiştir. Böylece süreç kalitesinin endüstriyel standartlarla kıyaslanabilirliği ve iyileştirme potansiyelleri ortaya konmuştur.

PCI incelemesinde ise, sürecin belirlenmiş spesifikasyon limitleri dâhilinde ne kadar tutarlı ve stabil çıktılar üretebildiği değerlendirilmiştir. Bu analiz, sistem çıkışlarının öngörülen kalite standartlarını sağlama düzeyini kantitatif olarak ortaya koymuş ve süreç güvenilirliğinin istatistiksel açıdan değerlendirilmesine imkân tanımıştır.

İstatistiksel analizler

Deneysel tasarım kapsamında elde edilen veri setinin istatistiksel olarak incelenmesi, sistem performansını etkileyen faktörlerin ve aralarındaki ilişkilerin nicel olarak belirlenmesini sağlamıştır. Bu amaçla, varyans analizi yöntemi kullanılmıştır. Söz konusu analiz, gözlemlenen performans değişkenliklerinin rastlantısal olup olmadığını test etmek, kontrol faktörlerinin etkilerini ortaya koymak ve sistem davranışını matematiksel olarak modellemek açısından temel bir metodolojik çerçeve sunmuştur.

Varyans analizi, incelenen yedi ana kontrol faktörünün ve bileşik etkilerinin görev başarı oranı gibi KPI'ler üzerindeki etkilerinin istatistiksel olarak anlamlı olup olmadığını test etmek amacıyla gerçekleştirilmiştir. Deneysel veriler üzerine yapılan varyans analizi sonucunda, hangi

faktörlerin ve bileşik etkilerin sistem performansı üzerinde belirleyici rol oynadığı ve faktörler arası etkileşimlerin büyüklüğü nesnel biçimde ortaya konmuştur.



ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu bölümde, elde edilen 66 farklı veri seti (hava sahası, coğrafi alt yapı, meteoroloji, uzaktan algılama, uçuş kayıtları verisi gibi) için 7 farklı performans değerlendirme, sistem takip ve simülasyon başlığı altında yapılan analizler ve sonuçları verilmiştir. Bu başlıklar;

1. Deneysel tasarım ve optimizasyon analizleri,
2. Rota optimizasyon analizleri,
3. Performans analizleri ve kalite yönetimi,
4. Güvenilirlik ve risk analizleri,
5. Derin öğrenme, makine öğrenmesi ve yapay zekâ analizleri,
6. Ekonomik analizler,
7. OHKA sistem takip ve simülasyon ekranı

şeklindedir.

Deneysel Tasarım ve Optimizasyon Analizleri

OHKA'nın performansını etkileyen faktörlerin bireysel etkilerinin belirlenmesi ve optimum çalışma koşullarının tespit edilmesi amacıyla %95 güven aralığında etki analizleri gerçekleştirilmiştir. Ham veriler üzerine yapılan analizler sonucunda, yedi farklı faktör (A-G) ile altı farklı bileşik etkinin (üçlü bileşik etki hariç tutulmuştur) beş temel performans karakteristiği üzerindeki etkileri ayrı ayrı değerlendirilmiş olup, faktörlerin ve bileşik etkilerin sistem performans karakteristiklerine katkısı incelenmiştir.

Ayrıca bu tez kapsamında Sinyal/Gürültü (S/N) analizinin gerçekleştirilmesi, Taguchi deney tasarımı çerçevesinde optimum faktör seviyelerinin belirlenmesi ve sistem performans karakteristiklerinin varyasyon kaynaklarına karşı dayanıklılığının değerlendirilmesi amacıyla gerekli görülmüştür. OHKA'nın performansını etkileyen faktörlerin bireysel etkilerinin belirlenmesi ve optimum çalışma koşullarının tespit edilmesi amacıyla etki analizleri gerçekleştirilmiştir. S/N verileri üzerine yapılan analizler sonucunda, yedi farklı faktör (A-G) ile altı farklı bileşik etkinin beş temel performans karakteristiği üzerindeki etkileri ayrı ayrı değerlendirilmiş olup, faktörlerin asıl ve bileşik etkilerinin sistem performans karakteristiklerine katkısı incelenmiştir.

Teslimat süresi performans karakteristiği ham verileri üzerine yapılan varyans analizi Tablo 17'de, incelenen faktörlere ait asıl ve bileşik etki grafikleri sırasıyla Şekil 11a ve Şekil 11b'de sunulmuştur. Teslimat süresi performans karakteristiği S/N verileri üzerine yapılan


varyans analizi sonuçları Tablo 18’de, incelenen faktörlere ait asıl ve bileşik etki grafikleri ise sırasıyla Şekil 11c ve Şekil 11d’de verilmiştir.

Tablo 17. Teslimat Süresi Ham Verileri Üzerine Yapılan Varyans Analizi Tablosu


Faktör	DF	Seq SS	Adj SS	Adj MS	F	P	Katkı
A	1	1,9	1,9	1,91	0,05	0,818	0,00%
B	2	106,3	106,3	53,13	1,48	0,230	0,13%
C	2	208,9	208,9	104,46	2,91	0,057	0,25%
D	2	121,4	121,4	60,72	1,69	0,187	0,14%
E	2	326,1	326,1	163,07	4,55	0,012	0,39%
F	2	9985,5	9985,5	4992,73	139,28	0,000	11,90%
G	2	42,6	42,6	21,31	0,59	0,553	0,05%
A*D	2	6167,9	6167,9	3083,93	86,03	0,000	7,35%
B*D	4	9896,0	9896,0	2474,01	69,02	0,000	11,79%
C*D	4	7057,2	7057,2	1764,31	49,22	0,000	8,41%
D*E	4	7070,3	7070,3	1767,58	49,31	0,000	8,43%
D*F	4	32989,3	32989,3	8247,32	230,07	0,000	39,32%
D*G	4	3481,6	3481,6	870,39	24,28	0,000	4,15%
Hata	180	6452,5	6452,5	35,85			7,69%
Uyumsuzluk	18	6400,2	6400,2	355,57	1100,51	0,000	7,63%
Saf Hata	162	52,3	52,3	0,32			0,06%
Toplam	215	83907,6					100%

Tablo 18. Teslimat Süresi S/N Verileri Üzerine Yapılan Varyans Analizi Tablosu


Faktör	DF	Seq SS	Adj SS	Adj MS	F	P	Katkı
A	1	1,111	1,111	1,1110	0,41	0,532	0,22%
B	2	0,000	0,000	0,0000	0,00	1,000	0,00%
C	2	0,246	0,246	0,1232	0,05	0,956	0,05%
D	2	6,199	6,199	3,0996	1,13	0,344	1,21%
E	2	0,411	0,411	0,2057	0,08	0,928	0,08%
F	2	64,528	64,528	32,2639	11,79	0,001	12,61%
G	2	1,221	1,221	0,6107	0,22	0,802	0,24%
A*D	2	45,118	45,118	22,5591	8,24	0,003	8,82%
B*D	4	58,156	58,156	14,5391	5,31	0,005	11,36%
C*D	4	41,876	41,876	10,4689	3,83	0,020	8,18%
D*E	4	42,665	42,665	10,6662	3,90	0,019	8,34%
D*F	4	181,000	181,000	45,2499	16,53	0,000	35,37%
D*G	4	19,944	19,944	4,9861	1,82	0,169	3,90%
Hata	18	49,261	49,261	2,7367			9,63%
Toplam	53	511,737					100%




(a)



(b)



(c)



(d)

Şekil 11. Teslimat süresi ham veri grafikleri; (a) asıl etki grafikleri, (b) bileşik etki grafikleri. Teslimat süresi S/N grafikleri; (c) asıl etki grafikleri, (d) bileşik etki grafikleri.

Taguchi metodolojisi doğrultusunda S/N oranının maksimize edilmesi prensibine dayanarak; ortalama performans karakteristiğinin hedeflenen değere getirilmesi ve bu performans karakteristiğinin hedef değeri civarındaki varyasyonu da minimuma indirgeyen ve böylece süreç kararlılığını artıran optimum çalışma şartlarının tespit edilmesi sağlanmaktadır.

Tablo 17 ve Tablo 18’de verilen varyans analiz tabloları ile Şekil 11’de verilen asıl ve bileşik etki grafikleri birlikte değerlendirildiğinde sırasıyla; D×F bileşik etkisi, F asıl etkisi, B×D, A×D, D×E, C×D, D×G bileşik etkileri ile D asıl etkisinin önemli olduğu, diğerlerinin önemli bir etkisinin olmadığı görülmektedir. Deneysel sonuçlar bu etkilerin yüksek katkı ve anlamlılık düzeyleriyle teslimat süresindeki değişimi güçlü biçimde açıkladığını ortaya koymaktadır. Teslimat süresinin minimum yapılması hedeflendiğinden optimum çalışma şartları A₁B₁C₁D₁E₁F₁G₂ olarak belirlenmiştir.

Operasyonel maliyet performans karakteristiği ham verileri üzerine yapılan varyans analizi Tablo 19’da, incelenen faktörlere ait asıl ve bileşik etki grafikleri sırasıyla Şekil 12a ve Şekil 12b’de sunulmuştur. Operasyonel maliyet performans karakteristiği S/N verileri üzerine


yapılan varyans analizi sonuçları Tablo 20’de, incelenen faktörlere ait asıl ve bileşik etki grafikleri ise sırasıyla Şekil 12c ve Şekil 12d’de verilmiştir.

Tablo 19. Operasyonel Maliyet Ham Verileri Üzerine Yapılan Varyans Analizi Tablosu


Faktör	DF	Seq SS	Adj SS	Adj MS	F	P	Katkı
A	1	5	5	5	0,68	0,410	0,00%
B	2	541	541	270	39,35	0,000	0,11%
C	2	196	196	98	14,23	0,000	0,04%
D	2	571	571	285	41,53	0,000	0,11%
E	2	116603	116603	58301	8487,53	0,000	23,01%
F	2	212498	212498	106249	15467,77	0,000	41,94%
G	2	127	127	64	9,24	0,000	0,03%
A*D	2	8	8	4	0,57	0,564	0,00%
B*D	4	952	952	238	34,63	0,000	0,19%
C*D	4	321	321	80	11,70	0,000	0,06%
D*E	4	834	834	209	30,36	0,000	0,16%
D*F	4	172444	172444	43111	6276,13	0,000	34,04%
D*G	4	320	320	80	11,63	0,000	0,06%
Hata	180	1236	1236	7			0,24%
Uyumsuzluk	18	926	926	51	26,83	0,000	0,18%
Saf Hata	162	311	311	2			0,06%
Toplam	215	506654					100%

Tablo 20. Operasyonel Maliyet S/N Verileri Üzerine Yapılan Varyans Analizi Tablosu


Faktör	DF	Seq SS	Adj SS	Adj MS	F	P	Katkı
A	1	0,002	0,002	0,0020	0,05	0,830	0,00%
B	2	0,030	0,030	0,0151	0,36	0,705	0,01%
C	2	0,103	0,103	0,0517	1,22	0,318	0,04%
D	2	0,897	0,897	0,4483	10,59	0,001	0,35%
E	2	56,226	56,226	28,1130	664,00	0,000	22,16%
F	2	107,123	107,123	53,5617	1265,07	0,000	42,22%
G	2	0,116	0,116	0,0581	1,37	0,279	0,05%
A*D	2	0,003	0,003	0,0016	0,04	0,962	0,00%
B*D	4	0,397	0,397	0,0992	2,34	0,094	0,16%
C*D	4	0,289	0,289	0,0722	1,71	0,193	0,11%
D*E	4	0,792	0,792	0,1980	4,68	0,009	0,31%
D*F	4	86,744	86,744	21,6860	512,20	0,000	34,19%
D*G	4	0,218	0,218	0,0545	1,29	0,312	0,09%
Hata	18	0,762	0,762	0,0423			0,30%
Toplam	53	253,703					100%




(a)



(b)



(c)



(d)

Şekil 12. Operasyonel maliyet ham veri grafikleri; (a) asıl etki grafikleri, (b) bileşik etki grafikleri. Operasyonel maliyet S/N grafikleri; (c) asıl etki grafikleri, (d) bileşik etki grafikleri.

Tablo 19 ve Tablo 20'de verilen varyans analiz tabloları ile Şekil 12'de verilen asıl ve bileşik etki grafikleri birlikte değerlendirildiğinde sırasıyla; F asıl etkisi, D×F bileşik etkisi ve E asıl etkisinin önemli olduğu, diğerlerinin önemli bir etkisinin olmadığı görülmektedir. Deneysel sonuçlar bu etkilerin yüksek katkı ve anlamlılık düzeyleriyle operasyonel maliyet değişkenliğini güçlü biçimde açıkladığını ortaya koymaktadır. Operasyonel maliyetin minimum yapılması hedeflendiğinden optimum çalışma şartları $A_1B_1C_1D_1E_1F_1G_2$ olarak belirlenmiştir.


Görev başarı performans karakteristiği ham verileri üzerine yapılan varyans analizi Tablo 21'de, incelenen faktörlere ait asıl ve bileşik etki grafikleri sırasıyla Şekil 13a ve Şekil 13b'de sunulmuştur. Görev başarı performans karakteristiği S/N verileri üzerine yapılan varyans analizi sonuçları Tablo 22'de, incelenen faktörlere ait asıl ve bileşik etki grafikleri ise sırasıyla Şekil 13c ve Şekil 13d'de verilmiştir.

Tablo 21. Görev Başarı Oranı Ham Verileri Üzerine Yapılan Varyans Analizi Tablosu


Faktör	DF	Seq SS	Adj SS	Adj MS	F	P	Katkı
A	1	592,5	592,46	592,46	243,11	0,000	3,69%
B	2	0,1	0,11	0,06	0,02	0,978	0,00%
C	2	0,2	0,15	0,08	0,03	0,969	0,00%
D	2	4545,5	4545,51	2272,76	932,59	0,000	28,28%
E	2	25,1	25,05	12,53	5,14	0,007	0,16%
F	2	27,0	26,99	13,50	5,54	0,005	0,17%
G	2	78,4	78,42	39,21	16,09	0,000	0,49%
A*D	2	2297,6	2297,58	1148,79	471,39	0,000	14,30%
B*D	4	0,1	0,06	0,02	0,01	1,000	0,00%
C*D	4	0,2	0,19	0,05	0,02	0,999	0,00%
D*E	4	383,7	383,71	95,93	39,36	0,000	2,39%
D*F	4	397,5	397,53	99,38	40,78	0,000	2,47%
D*G	4	7284,2	7284,17	1821,04	747,24	0,000	45,33%
Hata	180	438,7	438,67	2,44			2,73%
Uyumsuzluk	18	430,1	430,11	23,89	452,32	0,000	2,68%
Saf Hata	162	8,6	8,56	0,05			0,05%
Toplam	215	16070,6					100%

Tablo 22. Görev Başarı Oranı S/N Verileri Üzerine Yapılan Varyans Analizi Tablosu


Faktör	DF	Seq SS	Adj SS	Adj MS	F	P	Katkı
A	1	1,6403	1,6403	1,64032	24,45	0,000	3,68%
B	2	0,0003	0,0003	0,00013	0,000	0,998	0,00%
C	2	0,0004	0,0004	0,0002	0,000	0,997	0,00%
D	2	12,976	12,976	6,48799	96,69	0,000	29,10%
E	2	0,0997	0,0997	0,04986	0,74	0,49	0,22%
F	2	0,1053	0,1053	0,05263	0,78	0,471	0,24%
G	2	0,3109	0,3109	0,15544	2,32	0,127	0,70%
A*D	2	6,2688	6,2688	3,13439	46,71	0,000	14,06%
B*D	4	0,0002	0,0002	0,00004	0,000	1,000	0,00%
C*D	4	0,0005	0,0005	0,00013	0,000	1,000	0,00%
D*E	4	1,048	1,048	0,26201	3,9	0,019	2,35%
D*F	4	1,0861	1,0861	0,27152	4,05	0,016	2,44%
D*G	4	19,845	19,845	4,96125	73,94	0,000	44,51%
Hata	18	1,2078	1,2078	0,0671			2,71%
Toplam	53	44,5892					100%




(a)



(b)



(c)



(d)

Şekil 13. Görev başarı oranı ham veri grafikleri; (a) asıl etki grafikleri, (b) bileşik etki grafikleri. Görev başarı oranı S/N grafikleri; (c) asıl etki grafikleri, (d) bileşik etki grafikleri.

Tablo 21 ve 22’de verilen varyans analiz tabloları ile Şekil 13’te verilen asıl ve bileşik etki grafikleri birlikte değerlendirildiğinde sırasıyla; D×G bileşik etkisi, D asıl etkisi, A×D bileşik etkisi, A asıl etkisi, D×F ve D×E bileşik etkilerinin önemli olduğu, diğerlerinin önemli bir etkisinin olmadığı görülmektedir. Hata teriminin düşük katkısı ise modelin görev başarı oranındaki değişimi büyük ölçüde açıkladığını ve bulguların tutarlı bir yapı sergilediğini desteklemektedir. Görev başarı oranının maksimum yapılması hedeflendiğinden optimum çalışma şartları $A_1B_1C_1D_3E_2F_3G_1$ olarak belirlenmiştir.


Enerji tüketimi performans karakteristiği ham verileri üzerine yapılan varyans analizi Tablo 23’te, incelenen faktörlere ait asıl ve bileşik etki grafikleri sırasıyla Şekil 14a ve Şekil 14b’de sunulmuştur. Enerji tüketimi performans karakteristiği S/N verileri üzerine yapılan varyans analizi sonuçları Tablo 24’te, incelenen faktörlere ait asıl ve bileşik etki grafikleri ise sırasıyla Şekil 14c ve Şekil 14d’de verilmiştir.

Tablo 23. Enerji Tüketimi Ham Verileri Üzerine Yapılan Varyans Analizi Tablosu


Faktör	DF	Seq SS	Adj SS	Adj MS	F	P	Katkı
A	1	1028	1028	1028	0,71	0,401	0,00%
B	2	8656507	8656507	4328253	2983,01	0,000	10,39%
C	2	2143605	2143605	1071803	738,68	0,000	2,57%
D	2	1090	1090	545	0,38	0,687	0,00%
E	2	38396871	38396871	19198436	13231,45	0,000	46,08%
F	2	121974	121974	60987	42,03	0,000	0,15%
G	2	22938	22938	11469	7,90	0,001	0,03%
A*D	2	356	356	178	0,12	0,885	0,00%
B*D	4	884772	884772	221193	152,44	0,000	1,06%
C*D	4	246683	246683	61671	42,50	0,000	0,30%
D*E	4	32302351	32302351	8075588	5565,65	0,000	38,77%
D*F	4	251544	251544	62886	43,34	0,000	0,30%
D*G	4	30684	30684	7671	5,29	0,000	0,04%
Hata	180	261175	261175	1451			0,31%
Uyumsuzluk	18	232565	232565	12920	73,16	0,000	0,28%
Saf Hata	162	28610	28610	177			0,03%
Toplam	215	83321577					100%

Tablo 24. Enerji Tüketimi S/N Verileri Üzerine Yapılan Varyans Analizi Tablosu


Faktör	DF	Seq SS	Adj SS	Adj MS	F	P	Katkı
A	1	0,001	0,001	0,0008	0,02	0,889	0,00%
B	2	31,445	31,445	15,7223	415,71	0	9,98%
C	2	8,354	8,354	4,1769	110,44	0	2,65%
D	2	2,848	2,848	1,4241	37,65	0	0,90%
E	2	145,221	145,221	72,6103	1919,88	0	46,07%
F	2	0,348	0,348	0,1741	4,6	0,024	0,11%
G	2	0,197	0,197	0,0985	2,6	0,101	0,06%
A*D	2	0,051	0,051	0,0253	0,67	0,525	0,02%
B*D	4	3,15	3,15	0,7876	20,82	0	1,00%
C*D	4	1,082	1,082	0,2704	7,15	0,001	0,34%
D*E	4	120,279	120,279	30,0697	795,07	0	38,16%
D*F	4	1,37	1,37	0,3425	9,06	0	0,43%
D*G	4	0,181	0,181	0,0453	1,2	0,346	0,06%
Hata	18	0,681	0,681	0,0378			0,22%
Toplam	53	315,206					100%




(a)



(b)



(c)



(d)

Şekil 14. Enerji tüketimi ham veri grafikleri; (a) asıl etki grafikleri, (b) bileşik etki grafikleri. Enerji tüketimi S/N grafikleri; (c) asıl etki grafikleri, (d) bileşik etki grafikleri.

Tablo 23 ve Tablo 24'te verilen varyans analiz tabloları ile Şekil 14'te verilen asıl ve bileşik etki grafikleri birlikte değerlendirildiğinde sırasıyla; E asıl etkisi, D×E bileşik etkisi, B ve C asıl etkileri ile B×D bileşik etkisinin önemli olduğu, diğerlerinin önemli bir etkisinin olmadığı görülmektedir. Hata teriminin düşük katkısı ise modelin enerji tüketimi oranındaki değişimi büyük ölçüde açıkladığını ve bulguların tutarlı bir yapı sergilediğini desteklemektedir. Enerji tüketim miktarının minimum yapılması hedeflendiğinden optimum çalışma şartları $A_2B_1C_1D_1E_1F_2G_1$ olarak belirlenmiştir.


Karbon ayak izi performans karakteristiği ham verileri üzerine yapılan varyans analizi Tablo 25'te, incelenen faktörlere ait asıl ve bileşik etki grafikleri sırasıyla Şekil 15a ve Şekil 15b'de sunulmuştur. Karbon ayak izi performans karakteristiği S/N verileri üzerine yapılan varyans analizi sonuçları Tablo 26'da, incelenen faktörlere ait asıl ve bileşik etki grafikleri ise sırasıyla Şekil 15c ve Şekil 15d'de verilmiştir.

Tablo 25. Karbon Ayak İzi Ham Verileri Üzerine Yapılan Varyans Analizi Tablosu


Faktör	DF	Seq SS	Adj SS	Adj MS	F	P	Katkı
A	1	0,011	0,0110	0,0110	0,22	0,638	0,00%
B	2	24,921	24,9210	12,4605	252,18	0,000	9,59%
C	2	47,533	47,5325	23,7663	480,99	0,000	18,28%
D	2	0,297	0,2970	0,1485	3,01	0,052	0,11%
E	2	77,731	77,7307	38,8653	786,56	0,000	29,90%
F	2	5,055	5,0548	2,5274	51,15	0,000	1,94%
G	2	0,730	0,7304	0,3652	7,39	0,001	0,28%
A*D	2	0,069	0,0694	0,0347	0,70	0,497	0,03%
B*D	4	1,147	1,1469	0,2867	5,80	0,000	0,44%
C*D	4	35,410	35,4103	8,8526	179,16	0,000	13,62%
D*E	4	53,802	53,8023	13,4506	272,22	0,000	20,69%
D*F	4	2,903	2,9026	0,7256	14,69	0,000	1,12%
D*G	4	1,497	1,4973	0,3743	7,58	0,000	0,58%
Hata	180	8,894	8,8941	0,0494			3,42%
Uyumsuzluk	18	8,863	8,8634	0,4924	2600,68	0,000	3,41%
Saf Hata	162	0,031	0,0307	0,0002			0,01%
Toplam	215	260,000					100%

Tablo 26. Karbon Ayak İzi S/N Verileri Üzerine Yapılan Varyans Analizi Tablosu


Faktör	DF	Seq SS	Adj SS	Adj MS	F	P	Katkı
A	1	0,274	0,274	0,2743	0,38	0,543	0,07%
B	2	36,893	36,893	18,4465	25,82	0	10,03%
C	2	66,541	66,541	33,2705	46,57	0	18,09%
D	2	1,408	1,408	0,704	0,99	0,393	0,38%
E	2	109,344	109,344	54,6718	76,53	0	29,73%
F	2	13,677	13,677	6,8387	9,57	0,001	3,72%
G	2	1,066	1,066	0,533	0,75	0,488	0,29%
A*D	2	0,153	0,153	0,0764	0,11	0,899	0,04%
B*D	4	1,324	1,324	0,3311	0,46	0,762	0,36%
C*D	4	48,725	48,725	12,1811	17,05	0	13,25%
D*E	4	71,342	71,342	17,8354	24,97	0	19,40%
D*F	4	2,155	2,155	0,5387	0,75	0,568	0,59%
D*G	4	2,033	2,033	0,5083	0,71	0,595	0,55%
Hata	18	12,859	12,859	0,7144			3,50%
Toplam	53	367,794					100%




(a)



(b)



(c)



(d)

Şekil 15. Karbon ayak izi ham veri grafikleri; (a) asıl etki grafikleri, (b) bileşik etki grafikleri. Karbon ayak izi S/N grafikleri; (c) asıl etki grafikleri, (d) bileşik etki grafikleri.


Tablo 25 ve Tablo 26’da verilen varyans analiz tabloları ile Şekil 15’te verilen asıl ve bileşik etki grafikleri birlikte değerlendirildiğinde sırasıyla; E asıl etkisi, D×E bileşik etkisi, C asıl etkisi, C×D bileşik etkisi ile B ve F asıl etkilerinin önemli olduğu, diğerlerinin önemli bir etkisinin olmadığı görülmektedir. Karbon ayak izi miktarının minimum yapılması hedeflendiğinden optimum çalışma şartları $A_1B_1C_1D_1E_1F_1G_3$ olarak belirlenmiştir.

Yukarıdaki açıklamalar doğrultusunda her performans karakteristiği için etkin (önemli) olan parametrelerin ve bileşik etkilerin katkı yüzdeleri ile optimum çalışma şartları Tablo 27’de verilmiştir. Ayrıca performans karakteristikleri arasındaki ödünleşmeleri de dikkate alarak belirlenen optimum çalışma şartları da (Genel Optimum₁ ve Genel Optimum₂) Tablo 27’de verilmiştir.

Tablo 27. Etkin Olan Parametrelerin ve Bileşik Etkilerin Katkı Yüzdeleri ile Optimum Çalışma Şartları

	A	B	C	D	E	F	G	AxD	BxD	CxD	DxE	DxF	DxG
Teslimat Süresi	A ₁	B ₁	C ₁	D ₁ %1,21	E ₁	F ₁ %12,61	G ₂	%8,82	%11,36	%8,18	%8,34	%35,37	%3,90
Operasyonel Maliyet	A ₁	B ₁	C ₁	D ₁	E ₁ %22,16	F ₁ %42,22	G ₂					%34,19	
Görev Başarı Oranı	A ₁ %3,68	B ₁	C ₁	D ₃ %29,10	E ₂	F ₃	G ₁	%14,06			%2,35	%2,44	%44,51
Enerji Tüketimi	A ₂	B ₁ %9,98	C ₁ %2,65	D ₁	E ₁ %46,07	F ₂	G ₁		%1,00		%38,16		
Karbon Ayak İzi	A ₁	B ₁ %10,03	C ₁ %18,09	D ₁	E ₁ %29,73	F ₁ %3,72	G ₃			%13,25	%19,40		
Genel Optimum₁	A ₁	B ₁	C ₁	D ₁	E ₁	F ₁	G ₂						
Genel Optimum₂	A ₁	B ₁	C ₁	D ₃	E ₁	F ₃	G ₁						


Pareto frontu, bir sistemde birden fazla hedefin aynı anda optimize edilmesi gerektiğinde, bu hedefler arasında denge veya ödünleşme (trade-off) kuran en iyi çözümleri gösteren çözüm uzayıdır. Şekil 16’da sunulan Pareto frontu analizi ve ikili hedef optimizasyonu, OHKA teslimat sisteminde farklı performans karakteristiği ödünleşmelerini ortaya koymaktadır.



Şekil 16. Pareto frontu analizi ve ikili hedef optimizasyonu sonuçları; (a) teslimat süresi - görev başarı oranı grafiği, (b) operasyonel maliyet - görev başarı oranı grafiği, (c) enerji tüketimi – görev başarı oranı grafiği ve (d) karbon ayak izi – görev başarı oranı grafiği.

Teslimat süresi-başarı oranı değerlendirmesinde, optimal ödünleşme noktası 29,73 dakika teslimat süresi ve %95,10 başarı oranında gerçekleşmiştir. Pareto frontunun dik eğimi, teslimat süresindeki küçük iyileştirmelerin başarı oranında belirgin düşüslere yol açabileceğini göstermektedir. Maliyet-başarı oranı değerlendirmesinde 122,90 TL maliyet ve %95,08 başarı oranında optimal denge sağlanmıştır. Maliyet artışının başarı oranını lineer olmayan şekilde etkilediği, belirli bir eşik sonrası maliyet artışının başarı oranında sınırlı iyileştirme sağladığı gözlenmiştir. Enerji-başarı oranı değerlendirmesinde 1527,25 birim enerji tüketiminde %95,08 başarı oranı elde edilmiştir. Düşük enerji seviyelerinde başarı oranının keskin düşüş göstermesi, minimum enerji gereksiniminin kritik önemini vurgulamaktadır. Karbon ayak izi-başarı oranı değerlendirmesinde 2,31 birim karbon ayak izi %95,08 başarı oranına ulaşılmıştır. Tüm analizlerde Pareto optimal çözümlerin belirgin kümelenmeler oluşturması, sistem tasarımında belirli çalışma bölgelerinin tercih edilmesi gerektiğini göstermektedir. Bu bulgular, çok kriterli karar verme süreçlerinde optimal dengenin kurulmasının önemini ve tek bir performans karakteristiğinin maksimizasyonunun diğer performans karakteristiklerinin kabul edilemez seviyelerde kayıplarına yol açabileceğini ortaya koymaktadır.


Şekil 17'de sunulan OHKA performans optimizasyon uzayı, teslimat süresi-maliyet-başarı oranı parametrelerinin üç boyutlu etkileşimini kapsamlı şekilde ortaya koymaktadır. Pareto optimal noktaların kırmızı işaretlerle belirtildiği analizde, en iyi ödünleşme noktası maliyette 114,59 TL, teslimat süresinde 29,54 dakika ve başarı oranında %100 noktasında elde edilmiştir. Veri noktalarının renk dağılımına bakıldığında, yüksek başarı oranlarının yeşil tonlarda yoğunlaştığı görülmektedir. Pareto optimal çözümlerin dikey ekseninde (başarı oranı) üst seviyelerde konumlanması, sistem tasarımında güvenilirliğin öncelikli kriter olarak ele alındığını ortaya koymaktadır. Bu bulgular, operasyonel kararların çok boyutlu optimizasyon bakış açısıyla değerlendirilmesi gerektiğini vurgulamaktadır.



Şekil 17. OHKA performans optimizasyon uzayı.

Şekil 18'de sunulan çok boyutlu performans değerlendirmesi, sistemin bütüncül analizine yönelik entegre bir yaklaşım sunmaktadır. Şekil 18a'da görüldüğü üzere, MCDM kriter ağırlıklandırmasında süre kriteri %25 ile en yüksek öncelik düzeyinde konumlandırılmış, maliyet, başarı ve karbon kriterleri eşit olarak %20'şer ağırlık değeri almış ve enerji kriteri %15 ile en düşük ağırlığa sahip olduğu paylaşılmıştır. TOPSIS performans skorlarının istatistiksel dağılımının incelenmesi için Şekil 18b değerlendirildiğinde, ortalama skor 0,424 ve medyan değer 0,347 olarak hesaplanmış, çeyrekler arası genişlik [0,231; 0,563] aralığında belirlenmiştir. Günlük operasyonel işlemlerin enerji-karbon performansı üzerindeki etkilerinin değerlendirilmesi amacıyla Şekil 18c oluşturulmuştur. Enerji ve karbon avantajının sabah saatlerinde (08:00-09:00) ve öğleden sonra (13:30-14:30) en iyi seviyelerine ulaştığı gözlemlenmiştir. En iyi ve en kötü performanslı senaryoların karşılaştırmalı analizi için Şekil 18d'de normalize karar matrisi sonuçları sunulmuştur. En yüksek TOPSIS skorlu senaryo (Senaryo 56) 0,966 değeri ile teslimat süresinde %97, maliyette %100, başarı oranında %88,

enerjide %95 ve karbon ayak izinde %100 normalize performans değerleri sergilemiştir. En kötü performanslı senaryo (Senaryo 80) 0,111 TOPSIS skoru ile elde edilmiştir.




Şekil 18. OHKA performans analizi; (a) MCDM kriter ağırlıkları, (b) TOPSIS skor dağılımı, (c) günlük enerji-karbon performans döngüsü ve (d) en iyi ve en kötü senaryolar için normalize karar matrisi.

OHKA teslimat sistemlerinin performans modellemesinde kullanılan makine öğrenmesi algoritmalarının karşılaştırmalı analizi Şekil 19’da gösterilmiştir. Bu analize ihtiyaç duyulmasının temel nedeni, en yüksek tahmin doğruluğunu sağlayan modelin belirlenmesi ve sistemin güvenilirliğinin artırılmasıdır. Bu kapsamda dört farklı analiz yöntemi uygulanmıştır.

Şekil 19a’da görüldüğü üzere, beş farklı performans karakteristiği için R^2 karşılaştırması sunulmuştur. Lineer ve kuadratik regresyon modelleri arasındaki farklar incelendiğinde, kuadratik modelin tüm performans karakteristiklerinde (Teslimat Süresi, Operasyonel Maliyet, Görev Başarı Oranı, Enerji Tüketimi, Karbon Ayak İzi) lineer modele göre daha yüksek R^2 değerleri ürettiği gözlenmiştir. En belirgin fark başarı oranında gözlenmiş olup, lineer model 0.65 değerinde kalırken kuadratik model 0.815 değerine yükselmiştir.

Şekil 19b'de sunulan artık grafiği, model tahminlerinin güvenilirliğini değerlendirmek amacıyla oluşturulmuştur. Özellikle Zoom bölgesinde detaylandırılan kısımda, artık değerlerin sıfır çizgisi etrafında simetrik dağılım gösterdiği tespit edilmiştir. Bu durum, modelin sistematik hata içermediğini ve tahminlerin güvenilir olduğunu ortaya koymuştur.

Şekil 19c'de gösterilen normal Q-Q grafiği, model artıklarının normal dağılıma uygunluğunu test etmek için kullanılmıştır. Teorik kuantiller ile gerçek kuantiller arasındaki ilişki incelendiğinde, veri noktalarının büyük oranda referans çizgisi üzerinde konumlandığı gözlenmiştir. Bu bulgu, model varsayımlarının geçerliliğini ve parametrik testlerin uygulanabilirliğini doğrulamıştır.



Şekil 19. RSM model analizi ve değerlendirmesi; (a) model R² karşılaştırması, (b) artık grafiği ve (c) normal Q-Q grafiği.


OHKA teslimat sistemlerinde çok değişkenli optimizasyon analizlerinin gerekliliği, farklı operasyonel parametrelerin sistem performansı üzerindeki kompleks etkileşimlerini anlamak ve optimal çalışma koşullarını belirlemek açısından dört farklı analiz yapılmış ve Şekil 20'de sonuçları gösterilmiştir.

Şekil 20a'da sunulan kümülatif standardize model etkileri incelendiğinde, sistem genel performansı üzerinde en baskın belirleyicinin F faktörü olduğu, bunu E faktörü ve Dx F

etkileşiminin izlediği görülmektedir. Özellikle F faktörünün operasyonel maliyet ve teslimat süresi, E faktörünün ise enerji tüketimi ve karbon ayak izi üzerindeki açıklayıcılık payının, diğer parametrelere kıyasla istatistiksel olarak çok daha yüksek olduğu tespit edilmiştir. Toplam standardize model etkilerinden çıkan sonuçlar Taguchi yöntemiyle elde edilen sonuçları da desteklemektedir.

Şekil 20b, Şekil 20c ve Şekil 20d’de yer alan 3D yanıt yüzeyi analizleri, faktör etkileşimlerinin kritik optimizasyon noktalarını ortaya koymaktadır. Operasyonel maliyet performans karakteristiğinde F faktörünün 1.seviyesinin seçilmesi (Şekil 20b) ve enerji tüketiminde E faktörünün 1. seviyesinin seçilmesi (Şekil 20c) sistem verimliliğini artırırken; görev başarı oranı performans karakteristiği açısından D faktörünün 3.seviyesi ve G faktörünün 1. seviyesinin seçilmesi performansı maksimize eden en uygun çalışma bölgesini oluşturduğu belirlenmiştir (Şekil 20d).


Bu analizler, OHKA teslimat sistemlerinde çoklu faktör optimizasyonunun gerekliliğini ve farklı parametrelerin etkileşimlerinin sistem performansı üzerindeki kompleks etkilerini açık bir şekilde ortaya koymuştur.



Şekil 20. RSM model görselleştirme ve yanıt yüzeyi analizi; (a) toplam standardize model etkileri, (b) operasyonel maliyette $D \times F$ bileşik etkisine ait yanıt yüzeyi, (c) enerji tüketimindeki $D \times E$ bileşik etkisine ait yanıt yüzeyi ve (d) görev başarı oranındaki $D \times G$ bileşik etkisine ait yanıt yüzeyi.

Rota Optimizasyon Analizleri


Şekil 21'de sunulan ve OHKA sistemine bir alternatif olarak değerlendirilen geleneksel kara filosu için gerçekleştirilen araç rotalama problemi (vehicle routing problem -VRP) analizi, mevcut operasyonel yapıda önemli dengesizlikler ve verimsizlikler olduğunu ortaya koymaktadır. Filo kapasite kullanımında gözlemlenen heterojen yapı, ilk üç aracın tam kapasiteye yakın (1,22-1,29 ton) çalışırken dördüncü aracın %50'ye yakın bir atıl kapasiteyle (0,67 ton) operasyonu tamamlaması, filonun talep yapısına göre optimal şekilde yapılandırılmadığını veya görev dağılımının alt-optimal olduğunu göstermektedir. Bu dengesizlik, kat edilen mesafelerde de kendini göstermekte; araç 1 (277,1 km) ile araç 3 (129,6 km) arasındaki iki katı aşan rota uzunluğu farkı, iş yükü dağılımındaki eşitsizliği kanıtlamaktadır.



Şekil 21. Araç rotalama problemi; (a) araç kapasite kullanımı, (b) araç mesafe karşılaştırması, (c) talep dağıtımını ısı haritası, (d) araç verimlilik metrikleri ve (e) CVRP araç rotaları.

Analiz edilen talep dağılımı ısı haritası, bu operasyonel dengesizliklerin temel nedeninin, talebin coğrafi olarak belirli ilçe grupları arasında yoğunlaşması ve homojen bir dağılım göstermemesi olduğunu teyit etmektedir. Verimlilik metrikleri açısından en kritik bulgu, ton başına kat edilen mesafede araçlar arasında gözlemlenen önemli farklılıklardır; özellikle uzun rotalara sahip araç 1 ve araç 4'ün ton başına daha fazla mesafe kat etmesi, bu rotaların lojistik verimliliğinin daha düşük olduğunu ve operasyonel maliyetleri artırdığını ortaya koymaktadır. Sonuç olarak, kapasiteli araç rotalama problemi (capacitated vehicle routing problem - CVRP) rota haritasında görselleştirilen bu verimsizlikler ve dengesiz talep yapısı, geleneksel filonun özellikle dağınık veya düşük yoğunluklu talepleri karşılama konusundaki zorluklarını vurgulamakta ve bu tür senaryolar için drone tabanlı bir teslimat sisteminin potansiyel bir tamamlayıcı veya alternatif olarak sunabileceğini bilimsel olarak göstermektedir.

Şekil 22'de sunulan gezgin satıcı problemi (TSP) analizi, bölgedeki tüm ilçeleri kapsayan en kısa karayolu rotasını 394,1 km olarak belirleyerek, geleneksel bir lojistik operasyonun katlanmak zorunda olduğu minimum toplam mesafeyi ve dolayısıyla temel maliyet zeminini kantitatif olarak ortaya koymaktadır.




Şekil 22. Gezgin satıcı problemi; (a) TSP çözümü en kısa rota ve (b) ilçeler arası uzaklık matrisi.

Rota optimizasyonunun coğrafi temelleri incelendiğinde, ilçeler arası mesafe ısı haritası ve kümelenme analizi, kıyı şeridindeki ilçelerin birbirine yakın bir topoloji oluşturduğunu, ancak özellikle Çamoluk gibi iç kesimdeki ilçelerin coğrafi olarak izole olup diğer merkezlere uzak konumda bulunduğunu doğrulamaktadır. Bu coğrafi yapı, karayolu mesafelerinin

uzamasına ve lojistik verimliliğin azalmasına zemin hazırlayan temel bir faktör olarak belirlenmiştir. Bu nedenle, TSP çözümüyle elde edilen 394,1 km'lik optimal rota, yalnızca bir güzergah planı olmanın ötesinde, karayolu tabanlı sistemin doğal kısıtları ve verimlilik sınırlarını temsil eden bir referans değeri olarak kabul edilmektedir. Bu analizin en önemli bilimsel bulgusu, karayolu mesafesi ile drone sistemlerinin kullanabileceği "kuş uçuşu" mesafesi arasındaki farkın belirginleşmesidir. Özellikle coğrafi engeller nedeniyle karayolu güzergahlarının dolambaçlı olduğu iç bölgelerde, hava taşımacılığının toplam mesafeyi ve dolayısıyla operasyonel maliyetleri önemli ölçüde azaltma potansiyeli bulunmaktadır. Bu durum, TSP analizini, drone sistemlerinin stratejik fizibilitesini ve potansiyel yatırım getirisi değerlendirmesini gerçekleştirmek üzere temel bir araç haline getirmektedir.

Şekil 23'de detaylandırılan çoklu drone rota problemi analizi, operasyonel verimliliği artırmak amacıyla coğrafi segmentasyon tabanlı bir lojistik stratejisini ortaya koymaktadır. Sistem, toplam görev alanını farklı ilçe gruplarını içeren bölgesel kümelerle ayırarak her drone için özel bir operasyon sahası tahsis etmektedir.




Şekil 23. OHKA rota problemi; (a) OHKA rotaları, (b) OHKA performans metrikleri, (c) OHKA kapasite kullanımı ve (d) OHKA teslimat dağılımı.

Yukarıda temel stratejisi açıklanan "böl ve yönet" yaklaşımı, performans karakteristiklerindeki heterojen dağılımla kendini göstermektedir; Drone 1'in 197,4 km ile en uzun menzile sahip olduğu, Drone 2'nin ise 46,9 kg ile en yüksek yük kapasitesini kullandığı tespit edilmiştir. Söz konusu farklılaşma, bir dengesizlikten ziyade, her rotanın kendi bölgesinin özgün talep ve coğrafi koşullarına göre menzil veya yük gibi farklı birincil hedefler doğrultusunda optimize edildiğini gösteren gelişmiş bir planlama başarısını temsil etmektedir. Teslimat noktası dağılımının Drone 1 ve Drone 3 için %30, Drone 2 ve Drone 4 için %20 olarak farklılaşması, modelin heterojen talep yoğunluklarını etkin şekilde karşıladığını teyit etmektedir. Sonuç olarak, bu analiz çoklu drone sisteminin, tek ve monolitik rotalara dayanan geleneksel sistemlere kıyasla, paralel ve özelleştirilmiş operasyonlar yürüterek daha esnek, ölçeklenebilir ve verimli bir lojistik mimari sunduğunu bilimsel düzeyde kanıtlamaktadır. Bu yapı, her varlığın en yüksek performans gösterdiği yetenek setine göre kullanımını sağlayarak toplam sistem verimliliğini maksimize etmektedir.

Şekil 24'de sunulan operasyonel analizler, OHKA teslimat sisteminin performans dinamiklerini coğrafi ve zamansal boyutlarda ortaya koyarak sistem davranışının heterojen bir yapıya sahip olduğunu göstermektedir. Coğrafi bazda, teslimat sürelerinin Merkez ilçe için 25,2 dakika gibi düşük bir değerden Eynesil ilçesi için 215,7 dakikaya kadar geniş bir yelpazede dağılması, ortalama 117,1 dakikalık performansın ilçeler arasındaki topolojik ve mesafe farklılıklarından önemli ölçüde etkilendiğini ortaya koymaktadır. Zamansal analizler ise sistemin operasyonel istikrarını ve talep yapısının öngörülebilirliğini doğrulamaktadır. Yedi günlük hareketli ortalamalardan anlaşıldığı üzere, günlük teslimat sayılarındaki dalgalanmalara rağmen sistem haftalık periyotta kararlı bir operasyonel ritim sergilemektedir.

Bu talep dalgalanmalarının rastgele olmadığı; 24 saatlik ve haftalık talep yoğunluk haritalarında açıkça görülen belirli örüntüleri takip ettiği anlaşılmaktadır. Özellikle hafta içi günlerde ve 10:00-12:00 ile 14:00-16:00 saatleri arasında gözlemlenen talep zirveleri, sistemin reaktif bir modelden ziyade proaktif ve öngörüye dayalı bir kaynak planlaması gerektirdiğini göstermektedir. Sonuç olarak, bu bulgular, operasyonel verimliliğin maksimize edilmesi amacıyla coğrafi kısıtlamalara bağlı olarak hizmet seviyesi anlaşmalarının farklılaştırılmasının ve belirlenen zamansal talep piklerine etkin şekilde yanıt verebilecek dinamik kapasite ve personel yönetimi stratejilerinin benimsenmesinin gerekliliğini bilimsel düzeyde ortaya koymaktadır.



Şekil 24. Operasyonel analizler; (a) ilçe bazlı performans dağılımı, (b) haftalık teslimat trendi, (c) 24 saatlik talep dağılımı ve (d) haftalık talep yoğunluğu haritası.

OHKA teslimat sistemlerinin operasyonel risklerini değerlendirmek amacıyla gerçekleştirilen teknik analizlerden Şekil 25’de gösterilen kritik bulgular elde edilmiştir. Şekil 25a’da görüldüğü üzere, en yüksek risk öncelik numarası (risk priority number, RPN) 336 ile ani fırtına koşullarında tespit edilmiştir. Kar fırtınası (RPN: 288), yoğun sis (RPN: 280) ve dolu yağışı (RPN: 243) diğer yüksek riskli faktörler olarak belirlenmiştir. Risk matrisinde toplam 15 yüksek risk faktörü tanımlanmış olup, bunların toplam maliyeti 133.480 TL olarak hesaplanmıştır. Bu toplam maliyet, örneğin RPN bakımından ani fırtına, kar fırtınası, yoğun sis ve dolu yağışı gibi meteorolojik risklerin “kritik” seviyede öne çıktığı; maliyet açısından ise orman yangını (15.824 TL), dolu yağışı (13.904 TL), batarya arızası (12.029 TL), yoğun sis (10.984 TL) ve kuş çarpması (10.593 TL) gibi toplam 15 farklı risk kaleminin toplam yükünü ortaya koymaktadır. Bu bulgular, çevresel faktörlerin OHKA operasyonları üzerindeki kritik etkisini ortaya koymaktadır. Sistemin sürdürülebilir operasyonu açısından kritik öneme sahip

batarya sağlık durumu monitörizasyonu gerçekleştirilmiştir. Şekil 25b'de sunulan batarya sağlık göstergesinde mevcut durum %59,2 olarak ölçülmüştür. Bu değer, sistemin ortalama batarya performansına işaret etmekte olup, kritik seviyenin üzerinde, ancak optimal çalışma aralığının altında konumlanmaktadır.



Şekil 25. Teknik analizler; (a) risk matrisi analizi, (b) batarya sağlık göstergesi, (c) drone bakım takvimi ve periyotları ve (d) motor ve sistem performans metrikleri.


OHKA filosunun operasyonel sürekliliğini sağlamak için sistematik bakım periyotları belirlenmiştir. Şekil 25c'de görüldüğü üzere, günlük kontrollerden başlayarak 180 günlük kapsamlı revizyona kadar uzanan kademeli bir bakım protokolü uygulanmaktadır. Haftalık bakımlar 7 günde bir, aylık bakımlar 30 günde bir gerçekleştirilmektedir. Bu hiyerarşik bakım yaklaşımı, sistemin güvenilirliğini maksimize etmeyi hedeflemektedir. Motor ve sistem performans metriklerinin bütünsel değerlendirilmesi radar analizi ile gerçekleştirilmiştir. Şekil 25d'de sunulan altı eksenli performans değerlendirmesinde genel performans skoru 4,7/10 olarak belirlenmiştir. Bu skor, batarya verimi, sıcaklık kontrolü, dakikadaki devir sayısı

(revolutions per minute, RPM) oranlaması, GPS bağlantısı, yük kapasitesi ve sinyal kalitesi parametrelerinin ağırlıklı ortalamasını yansıtmaktadır. Radar analizi kapsamında verilen altı temel performans metriği 0–10 ölçeğine normalize edilmiştir. Karşılaştırma amacıyla, kodlanma içerisinde her bir metrik için 10 üzerinden 8 değeri “hedef/kabul edilebilir performans seviyesi” olarak sabit bir referans çizgisi şeklinde tanımlanmıştır. Bu performans profilinin kritik eşik değerinin altında kalması, sistem optimizasyonu gereksinimini ortaya koymaktadır.

Performans Analizleri ve Kalite Yönetimi

OHKA teslimat sistemlerinin operasyonel kalitesini güvence altına almak amacıyla, kritik performans parametrelerinin süreç yeterliliği göstergeleri (Cp/Cpk) ve buna karşılık gelen sigma seviyeleri birlikte Şekil 26’da değerlendirilmiştir. Şekil 26a’da görüldüğü üzere, batarya sıcaklığı için $Cpk=1,545$ olarak belirlenmiş; buna bağlı olarak süreç seviyesi $\sigma_{ST}=4,635\sigma$ ve uzun dönem yaklaşımla $\sigma_{LT}=6,135\sigma$ olarak hesaplanmıştır. Bu bulgu, batarya termal yönetiminin spesifikasyon sınırları içinde yüksek yeterlilikle çalıştığını ve sürecin hedef değere yakın şekilde merkezlenmiş olduğunu göstermektedir. Şekil 26b’de görüldüğü üzere, teslimat süresi parametresi için $Cpk=0,951$ olup süreç seviyesi $\sigma_{ST}=2,853\sigma$ ve $\sigma_{LT}=4,353\sigma$ olarak bulunmuştur. Bu sonuçlar, teslimat süresinde süreç yayılımının diğer metriklere göre daha yüksek olduğunu; özellikle kısa vadede değişkenliğin azaltılması ve süreç merkezlemesinin iyileştirilmesinin öncelikli bir geliştirme alanı olduğunu ortaya koymaktadır. Şekil 26c’de görüldüğü üzere, GPS doğruluğu için $Cpk=1,067$ olarak tespit edilmiş ve sigma seviyesi $\sigma_{ST}=3,201\sigma$ ile $\sigma_{LT}=4,701\sigma$ düzeyinde gerçekleşmiştir. Bu durum, navigasyon performansının genel olarak kabul edilebilir yeterlilikte olduğunu; ancak daha düşük sapma hedefleri için ölçüm hassasiyeti, sinyal kararlılığı ve çevresel etkilerin yönetimine dönük iyileştirmelerin süreç performansını daha da artırabileceğini düşündürmektedir. Şekil 26d’de görüldüğü üzere, iniş hassasiyeti için $Cpk=1,086$ hesaplanmış; süreç seviyesi $\sigma_{ST}=3,258\sigma$ ve $\sigma_{LT}=4,758\sigma$ olarak belirlenmiştir. Bu bulgu, iniş performansının spesifikasyonlar dahilinde güvenilir bir düzeyde sürdürüldüğünü, ancak özellikle değişken rüzgâr ve zemin koşullarında daha yüksek tekrarlanabilirlik için kontrol algoritmalarının iyileştirilebileceğini göstermektedir. Şekil 26e’de görüldüğü üzere, paket titreşimi parametresinde $Cpk=1,422$ değeri elde edilmiş; buna karşılık süreç seviyesi $\sigma_{ST}=4,266\sigma$ ve $\sigma_{LT}=5,766\sigma$ olarak hesaplanmıştır. Bu sonuç, taşıma sürecinde kargo koruma ve titreşim sönmüleme mekanizmalarının etkinliğini desteklemekte ve kargo güvenliği açısından yüksek süreç yeterliliğine işaret etmektedir. Son olarak, şeklin genel değerlendirmesini sunan toplu görünümde (Şekil 26f), Cp/Cpk ve sigma seviyelerinin dağılımı, sistemin birçok kritik metrikte yeterli bir performans bandında


çalıştığını; buna karşın iyileştirme önceliğinin teslimat süresi gibi süreç yeterliliği düşük kalan performans karakteristiklerinde varyans azaltma ve hedefe merkezleme çalışmalarına verilmesi gerektiğini ortaya koymaktadır.




Şekil 26. Süreç seviyesi; (a) batarya sıcaklığı, (b) teslimat süresi, (c) GPS doğruluğu, (d) iniş hassasiyeti, (e) paket titreşimi ve (f) dağılım analizi.

OHKA teslimat sistemlerinin sürekli iyileştirme felsefesi çerçevesinde performansının izlenmesi ve kontrol altında tutulması için kontrol grafikleri uygulanması kritik bir gerekliliktir. Şekil 27'de sunulan dört farklı kontrol grafiği, sistemin kalite performansının kapsamlı bir değerlendirmesini sağlamaktadır. Şekil 27a'da görüldüğü üzere, p-chart hata oranı analizi 60 günlük periyodu kapsamaktadır. Merkez çizgisi (CL) 0,0630, üst kontrol limiti (UKL) 0,1266 ve alt kontrol limiti (AKL) 0 olarak belirlenmiştir. Süreç boyunca hata oranlarının kontrol limitleri içinde kaldığı, ancak önemli varyasyonlar gösterdiği tespit edilmiştir. Özellikle bazı günlerde hata oranının üst kontrol limitine yaklaştığı gözlenmiştir.


Verim yüzdesi trendi Şekil 27b'de görülmektedir. Ortalama verim %93,9 olarak gerçekleştiği ve 6 sigma hedefi olan 99,997 değerinin altında kaldığı belirlenmiştir. Trend çizgisindeki dalgalanmalar, süreç performansının henüz istenen düzeyde stabilizeye ulaşmadığını ve iyileştirme çalışmalarının devam etmesi gerektiğini göstermektedir.




(a)



(b)



(c)



(d)

Şekil 27. Kontrol grafiği analizleri; (a) hata oranı, (b) verim yüzdesi trendi, (c) X bar grafiği ve (d) R grafiği.

Şekil 27c ve Şekil 27d'de sunulan X bar ve R (MR) kontrol grafikleri birlikte değerlendirildiğinde, sürecin ortalama hata düzeyinin (DPU) genel olarak istatistiksel anlamda kontrol altında olduğu görülmektedir. X bar grafiğinde noktaların kontrol limitleri içinde kalması, süreç merkezinin günler boyunca belirgin bir kayma sergilemediğine ve ortalama performansın kararlı seyrettiğine işaret etmektedir. Buna karşılık R(MR) grafiğinde tek bir noktada (43. gün) üst kontrol limitinin aşılması, ardışık iki gün arasında olağandışı büyüklükte bir değişim meydana geldiğini ve bu durumun özel neden kaynaklı bir varyasyon artışı olabileceğini düşündürmektedir. Bu tür tekil sıçramalar; hava koşullarındaki ani değişim, operasyonel prosedür farklılığı, sistem/rota güncellemesi, ekipman performans sapması veya veri toplama sürecindeki düzensizlik gibi faktörlerle ilişkilendirilebilir.

OHKA teslimat sistemlerinin operasyonel verimliliğinin maksimize edilmesi için OEE metriklerinin detaylı analizi ve darboğazların tespiti kritik öneme sahiptir. Şekil 28'de sunulan OEE analizleri, sistemin performansını çok boyutlu olarak değerlendirmektedir. Şekil 28a'da görüldüğü üzere, süreç kapasitesi ve darboğaz analizi sekiz farklı operasyonel aşamayı kapsamaktadır. Sipariş alma, drone hazırlığı, paket hazırlama, yükleme, kalkış, uçuş ve iniş aşamalarının kapasite ve gerçekleşen değerleri karşılaştırılmış, teslimat aşamasının sistem darboğazı olduğu tespit edilmiştir. Bu aşamanın kırmızı renk ile vurgulanması, operasyonel iyileştirme çalışmalarının öncelikle bu alana odaklanması gerektiğini ortaya koymaktadır. Duruş türleri dağılımı Şekil 28b'de sunulmuştur. Toplam 4153 dakikalık duruş süresinin %40'ının planlı bakım faaliyetlerinden, %32,4'ünün değişim süresinden ve %27,6'sının plansız duruşlardan kaynaklandığı belirlenmiştir. Plansız duruşların toplam duruş süresinin yaklaşık üçte birini oluşturması, önleyici bakım stratejilerinin güçlendirilmesi gerektiğini göstermektedir. Şekil 28c'de yer alan OEE trendi ve bileşenleri analizi, 2025 Nisan ayından itibaren 30 günlük periyodu kapsamaktadır. OEE değerinin dünya standardı olan %85 seviyesinin altında seyrettiği ve dönem içinde önemli dalgalanmalar gösterdiği tespit edilmiştir. Kullanılabilirlik, performans ve kalite bileşenlerinin zaman içindeki değişimi, süreç stabilitesinin henüz optimum seviyeye ulaşmadığını ortaya koymaktadır. OEE waterfall (şelale) analizi Şekil 28d'de detaylandırılmıştır. Teorik kapasitenin %100'den başlayarak kullanılabilirlik kayıpları nedeniyle %9,9, performans kayıpları nedeniyle %8,5 ve kalite kayıpları nedeniyle %1,4 oranında azaldığı görülmüştür. Nihai OEE değerinin %80,2 olarak gerçekleşmesi, sistemde toplam %19,8'lik bir kayıp olduğunu göstermektedir. Performans kayıplarının kullanılabilirlik kayıplarına yakın olması, süreç hızının ve verimliliğinin artırılması gerektiğini işaret etmektedir. Bu analizler, OHKA teslimat sisteminin operasyonel mükemmelliğe ulaşmak için özellikle teslimat aşamasındaki darboğazın giderilmesi, plansız


duruşların azaltılması ve performans kayıplarının minimize edilmesi alanlarında iyileştirme çalışmalarına odaklanması gerektiğini ortaya koymaktadır.



Şekil 28. OEE analizleri; (a) süreç kapasitesi ve darboğaz analizi, (b) duruş türleri dağılımı, (c) OEE trendi ve bileşenleri ve (d) OEE waterfall (şelale) analizi-kayıp kaynakları.

OHKA teslimat sistemlerinin performans entegre analizlerinin gerçekleştirilmesi, operasyonel mükemmelliğe ulaşmada çok boyutlu değerlendirme yaklaşımlarının benimsenmesini gerektirmektedir. Şekil 29'da sunulan dört farklı analiz, sistemin performansını farklı perspektiflerden kapsamlı olarak değerlendirmektedir. Şekil 29'a da görüldüğü üzere, DPMO trendi 60 günlük periyot boyunca incelenmiştir. Trend analizi, DPMO değerinin günlük 104,5 birim azalma gösterdiğini ortaya koymaktadır. Bu olumlu trend, süreç iyileştirme çalışmalarının etkili olduğunu ve hata oranlarının sistematik olarak azaldığını göstermektedir. Başlangıçtaki yüksek değerlerden düşük seviyelere doğru olan bu hareket, kalite performansında önemli bir ilerleme kaydedildiğini işaret etmektedir. İlçe bazında hata dağılımı ısı haritası Şekil 29b'de sunulmuştur. 30 günlük verilere göre, Merkezde teslimat gecikmelerinin 15 adet ile en yüksek değere ulaştığı görülmektedir. Bunun en temel sebebi ise teslimat sayısının Merkezde daha fazla olmasıdır. Hata tiplerinin coğrafi dağılımı incelendiğinde, teslimat


gecikmelerinin tüm ilçelerde yaygın olduğu, paket hasarı ve iletişim hatalarının belirli bölgelerde yoğunlaştığı tespit edilmiştir. Bu dağılım, bölgesel operasyonel stratejilerin geliştirilmesi gerektiğini ortaya koymaktadır. Şekil 29c'de yer alan hata tipleri pareto analizi, teslimat hatalarının yaklaşık 180 adet ile en yüksek kategoriye oluşturduğunu göstermektedir. Müşteri şikayetleri 160, iletişim hataları 115, navigasyon hataları 105 ve paket hataları 88 adet olarak kaydedilmiştir. Kümülatif yüzde eğrisi, ilk üç hata tipinin toplam hataların %70'ini aştığını göstermekte ve bu alanlara öncelikli odaklanılması gerektiğini ortaya koymaktadır. 30 günlük performans trendi Şekil 29d'de değerlendirilmiştir. Sigma trendinin 0,04 pozitif trend gösterdiği ve OEE değerinin %1,6 oranında artış eğiliminde olduğu tespit edilmiştir. Bu pozitif trendler, sürekli iyileştirme çalışmalarının performans üzerinde olumlu etki yarattığını ancak hedeflenen seviyelere ulaşmak için daha fazla çabaya ihtiyaç duyulduğunu göstermektedir.



Şekil 29. Performans entegre analizleri; (a) DPMO trendi, (b) ilçe bazında hata dağılımı, (c) hata tipleri pareto analizi ve (d) 30 günlük performans trendi ve projeksiyonları.

Güvenilirlik ve Risk Analizleri

OHKA teslimat sistemlerinin güvenilirlik performansının sistematik olarak izlenmesi ve değerlendirilmesi, operasyonel sürekliliğin sağlanması açısından kritik öneme sahiptir. Bu kapsamda Şekil 30'da sunulan Toplam Arızalar Arası Süre (mean time between failures – MTBF) - Ortalama Onarım Süresi (mean time to repair – MTTR) analizleri, filo güvenilirlik yönetiminin kapsamlı bir değerlendirmesini sağlamaktadır. Şekil 30'a'da görüldüğü üzere, OHKA filosu MTBF analizi dört farklı OHKA için arızalar arası ortalama süreleri göstermektedir. DR-GRS-002 kodlu OHKA 47,5 gün ile en yüksek MTBF değerine sahipken, DR-GRS-001 kodlu OHKA 40,4 gün ile en düşük değeri kaydetmiştir. DR-GRS-004 ve DR-GRS-003 kodlu OHKA'ların sırasıyla 45,6 ve 42,7 günlük MTBF değerleri, filo genelinde güvenilirlik performansının kabul edilebilir seviyelerde olduğunu göstermektedir. OHKA filosu MTTR analizi Şekil 30b'de sunulmuştur. DR-GRS-004 kodlu OHKA 4,2 saat ile en uzun onarım süresine sahipken, DR-GRS-002 kodlu drone 3,7 saat ile en kısa onarım süresini göstermiştir. DR-GRS-001 ve DR-GRS-003 kodlu drone'ların her ikisi de 3,9 saatlik onarım sürelerine sahiptir. Bu değerler, bakım operasyonlarının etkin bir şekilde yürütüldüğünü ve sistem kesintilerinin minimize edildiğini ortaya koymaktadır.



Şekil 30. MTBF-MTTR analizleri; (a) OHKA filosu MTBF analizi, (b) OHKA filosu MTTR analizi, (c) OHKA filosu kullanılabilirlik analizi ve (d) aylık arıza trend analizi.


Şekil 30c'de yer alan kullanılabilirlik analizi, tüm OHKA'ların %95 hedef değerinin üzerinde performans gösterdiğini ortaya koymaktadır. DR-GRS-002 kodlu drone %99,7 ile en yüksek kullanılabilirlik oranına sahipken, diğer üç drone da %99,6 kullanılabilirlik değeri ile yüksek performans sergilemektedir. Bu yüksek kullanılabilirlik oranları, sistemin operasyonel hazırlık düzeyinin mükemmel seviyede olduğunu göstermektedir. Aylık arıza trend analizi Şekil 30d'de detaylandırılmıştır. 14 aylık periyot boyunca OHKA'ların arıza sayılarının değişkenlik gösterdiği, ancak genel olarak 0 ile 3 arıza arasında seyrettiği görülmektedir.

OHKA teslimat sistemlerinin uzun vadeli operasyonel sürdürülebilirliğinin sağlanması için güvenilirlik fonksiyonları ve hayatta kalma analizlerinin detaylı olarak incelenmesi kritik öneme sahiptir. Şekil 31'de sunulan analizler, filo güvenilirlik performansının istatistiksel modellemesini kapsamlı bir şekilde ortaya koymaktadır. Şekil 31a'da görüldüğü üzere, OHKA filosu güvenilirlik fonksiyonu hem weibull hem de üstel dağılımlar kullanılarak modellenmiştir. Güvenilirlik fonksiyonunun 6. günde yaklaşık 0,90 ve 35. günde yaklaşık 0,35 değerlerinde olduğu tespit edilmiştir. Weibull dağılımının üstel dağılıma göre daha iyi uyum sağladığı ve sistemin yaşlanma karakteristiklerini daha doğru yansıttığı görülmektedir. İlk dönemlerdeki hızlı düşüş, erken dönem arızalarının varlığına işaret etmektedir.

Arıza oranı analizi Şekil 31b'de detaylandırılmıştır. Weibull dağılımına göre arıza oranının zamanla artan bir trend gösterdiği, 200. güne doğru 0,075 seviyesine ulaştığı görülmektedir. Üstel dağılımın sabit 0,023 arıza oranı değeri, gerçek sistem davranışını yeterince yansıtmamaktadır. Bu durum, sistemde yaşlanma etkilerinin bulunduğunu ve önleyici bakım stratejilerinin önemini ortaya koymaktadır.

Şekil 31c'de sunulan Weibull olasılık grafiği, veri noktalarının doğrusal olduğunu göstermektedir. β parametresinin 0,91 olarak belirlenmesi, sistemin ölü doğum bölgesinde olduğunu işaret etmektedir. Veri noktalarının doğru etrafındaki dağılımı, Weibull modelinin uygunluğunu doğrulamaktadır.


Hayatta kalma eğrisi Şekil 31d'de görülmektedir. Ampirik hayatta kalma fonksiyonunun Weibull tahmini ile uyumlu olduğu ve %95 güven aralığı içinde kaldığı tespit edilmiştir. Hayatta kalma olasılığının 50. günde yaklaşık 0,43, 100. günde 0,18 ve 150. günde 0,03 seviyelerine düştüğü görülmektedir. Bu değerler, filo yenileme ve bakım planlaması için kritik bilgiler sağlamaktadır.



Şekil 31. Güvenilirlik fonksiyonu ve hayatta kalma analizi; (a) OHKA filosu güvenilirlik fonksiyonu, (b) arıza oranı analizi, (c) weibull olasılık grafiği ve (d) hayatta kalma eğrisi.

Şekil 32'de sunulan FMEA ve risk değerlendirme analizleri, sistemin risk profilini çok boyutlu olarak ortaya koymaktadır. Şekil 32a'da görüldüğü üzere, tespit yeteneği ve şiddet analizi, arıza modlarının kritiklik seviyelerini değerlendirmektedir. Yüksek şiddet ve zayıf tespit bölgesinde yer alan arıza modlarının 90-100 arası RPN değerlerine sahip olduğu görülmektedir. Bu bölgedeki arızaların öncelikli olarak ele alınması gerekliliği ortaya çıkmaktadır. Yüksek şiddet ancak iyi tespit edilebilen arızaların ise daha düşük risk profili gösterdiği tespit edilmiştir. RPN pareto analizi Şekil 32b'de detaylandırılmıştır. FM1 kodlu arıza modunun yaklaşık 105 RPN değeri ile en kritik arıza modu olduğu belirlenmiştir. İlk dokuz arıza modunun toplam riskin %60'ını oluşturduğu kümülatif yüzde eğrisinden anlaşılmaktadır. Bu bulgu, risk azaltma çalışmalarının öncelikle bu arıza modlarına odaklanması gerektiğini göstermektedir. Şekil 32c'de görüldüğü üzere, olasılık ve şiddet bileşenlerinin oluşturduğu risk matrisi, yüksek risk bölgesinin belirli kombinasyonlarda toplandığını ve risk dağılımının homojen olmadığını açıkça ortaya koymaktadır. Bu yapı, riskin sadece tekil bir RPN değeri üzerinden değerlendirilmesinin yetersiz olabileceğini, bileşenlerin etkileşimsel olarak incelenmesinin daha sağlıklı sonuçlar sunduğunu göstermektedir. Sistem bazlı risk analizi Şekil 32d'de görülmektedir. İtki sistemlerinin (OHKA'ları hareket ettirmek için gerekli kuvveti üreten mekanik ve enerji dönüşüm sistemleri) 68 ortalama ve 105 maksimum RPN değerleri ile

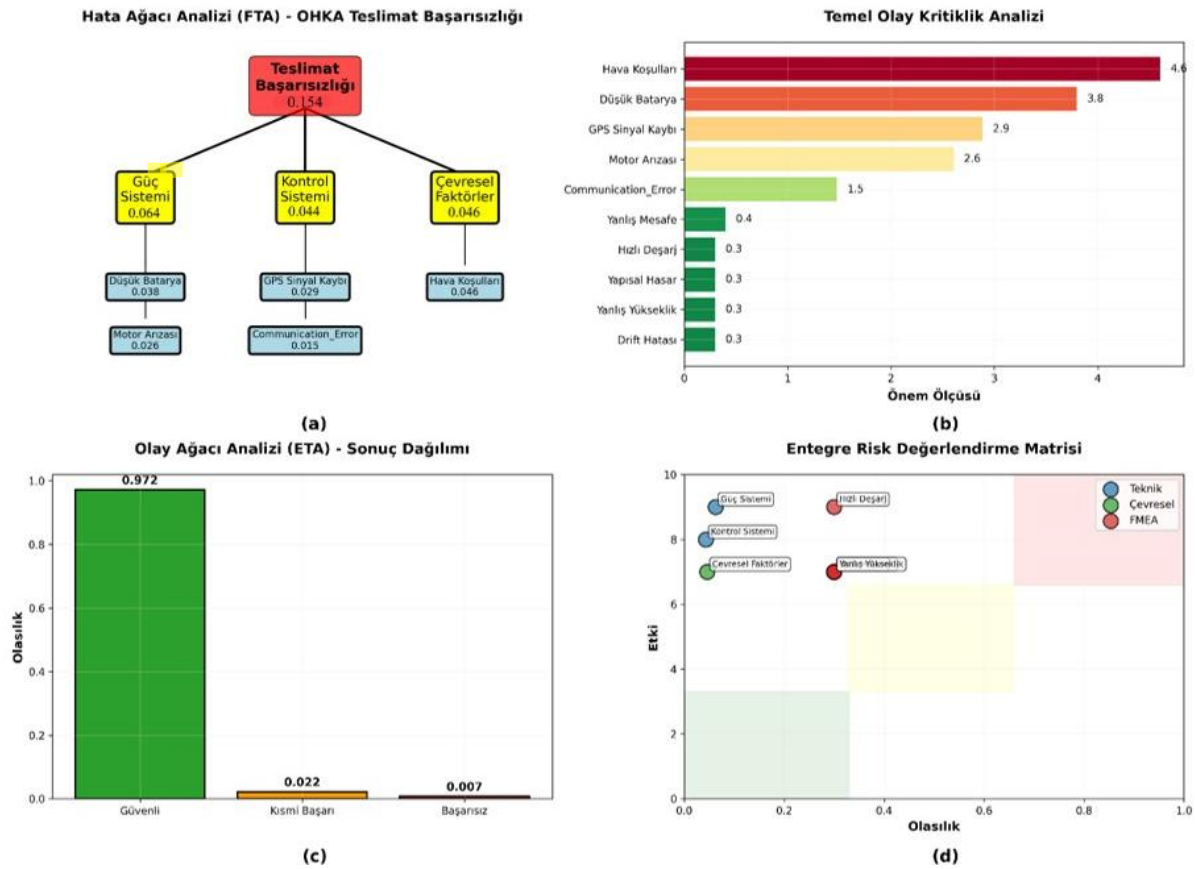
en yüksek risk profiline sahip olduğu tespit edilmiştir. Güç sistemleri 62 ortalama ve 81 maksimum RPN değerleri ile ikinci sırada yer almaktadır. İletişim sistemlerinin 36 ortalama ve 48 maksimum RPN değerleri ile en düşük risk seviyesinde olduğu belirlenmiştir. Bu analiz, yazılımlarda meydana gelen itki ve güç sistemlerinin güvenilirlik iyileştirme çalışmalarında önceliklendirilmesi gerektiğini göstermektedir.



Şekil 32. FMEA ve risk değerlendirme analizi; (a) tespit yeteneği ve şiddet analizi, (b) RPN pareto analizi, (c) risk matrisi – FMEA ve (d) sistem bazlı risk analizi.

Şekil 33'de sunulan Hata Ağacı Analizi (fault tree analysis – FTA) ve Olay Ağacı Analizi (event tree analysis – ETA), sistemin arıza modlarını ve sonuç senaryolarını kapsamlı bir şekilde ortaya koymaktadır. Şekil 33a'da görüldüğü üzere, FTA ile teslimat başarısızlığının temel nedenleri analiz edilmiştir. Toplam başarısızlık olasılığının 0,154 olarak hesaplandığı ve bunun üç ana kaynaktan oluştuğu tespit edilmiştir. Güç sistemi arızalarının 0,064, kontrol sistemi arızalarının 0,044 ve çevresel faktörlerin 0,046 olasılık değerleri ile katkıda bulunduğu görülmektedir. Temel olay kritiklik analizi Şekil 33b'de sunulmuştur. Hava koşullarının 4,6 önem ölçüsü ile en kritik faktör olduğu, bunu düşük batarya durumunun 3,8, GPS sinyal kaybının 2,9 ve motor arızasının 2,6 değerleri ile takip ettiği görülmektedir. Şekil 33c'de yer


alan ETA sonuç dağılımı, sistemin genel güvenilirlik performansını ortaya koymaktadır. Güvenli teslimat olasılığının 0,972 gibi yüksek bir değerde olması, sistemin %97,2 başarı oranına sahip olduğunu göstermektedir. Kısmi başarı olasılığının 0,022 ve başarısızlık olasılığının 0,007 olması, sistemin yüksek güvenilirlik seviyesinde çalıştığını doğrulamaktadır. Entegre risk değerlendirme matrisi Şekil 33d'de görülmektedir. Hızlı deşarj ve güç sistemi faktörlerinin yüksek etki ve olasılık değerleri ile kritik risk bölgesinde yer aldığı tespit edilmiştir. Kontrol sistemi ve çevresel faktörlerin orta risk seviyesinde, yanlış yükseklik faktörünün ise düşük risk bölgesinde konumlandığı görülmektedir. Bu matris, risk azaltma önceliklerinin belirlenmesinde önemli bir karar destek aracı olarak kullanılabilir.



Şekil 33. FTA ve ETA analizi; (a) FTA OHKA teslimat başarısızlığı, (b) temel olay kritik analizi, (c) ETA sonuç dağılımı ve (d) entegre risk değerlendirme matrisi.

OHKA teslimat sistemlerinin coğrafi risk faktörlerinin değerlendirilmesi ve bölgesel operasyonel stratejilerin geliştirilmesi için risk haritalarının kullanılması kritik bir planlama aracıdır. Şekil 34'de sunulan Giresun ilçeleri OHKA operasyon risk haritası, bölgesel risk dağılımını kapsamlı bir şekilde ortaya koymaktadır. Şekil 34'de görüldüğü üzere, Giresun ilinin Merkez ve 15 ilçesi için operasyonel risk skorları 0,30 ile 0,46 arasında değişmektedir. Eynesil ilçesinin 0,46 risk skoru ile en yüksek risk seviyesinde olduğu, kırmızı renk kodlaması ile vurgulanmıştır. Bu yüksek risk seviyesi, ilçenin Karadeniz kıyısındaki konumu ve muhtemel hava koşulları ile ilişkilendirilebilir. Yüksek risk kategorisinde yer alan diğer ilçeler arasında

Şebinkarahisar, Alucra ve Çamoluk bulunmaktadır. Bu ilçelerin risk skorlarının 0,44-0,45 aralığında olması, coğrafi konumları ve topografik özellikleri nedeniyle OHKA operasyonları için zorlayıcı koşullar barındırdığını göstermektedir. Özellikle iç kesimlerdeki bu ilçelerin dağlık yapısı, operasyonel riskleri artıran önemli bir faktör olarak değerlendirilmektedir. Orta risk seviyesinde yer alan ilçeler arasında Görele, Tirebolu, Espiye, Güce, Doğankent ve Çanakçı bulunmaktadır. Bu ilçelerin risk skorları 0,36-0,40 aralığında değişmekte olup, dengeli bir risk profili sergilemektedir.




Şekil 34. Giresun ilçeleri drone operasyon risk haritası.

Derin Öğrenme, Makine Öğrenmesi ve Yapay Zekâ Analizleri

Şekil 35'de sunulan analizler, güvenli iniş ve trafik yönetimi açısından sistemin performansını çok boyutlu olarak değerlendirmektedir. Şekil 35a'da görüldüğü üzere, mesafe-süre ilişkisi başarı oranı renk kodlaması ile sunulmuştur. Mesafe arttıkça uçuş süresinin doğrusal olarak arttığı, ancak başarı oranının 0,900'den 0,700'e doğru düştüğü tespit edilmiştir. 20 kilometrelik mesafede yaklaşık 30 dakikalık uçuş süresi gözlenirken, 100 kilometrelik mesafede bu sürenin 160 dakikaya kadar ulaştığı görülmektedir. Renk gradyanındaki değişim, uzun mesafelerde operasyonel risklerin arttığını açıkça ortaya koymaktadır. Mesafe-enerji tüketimi ilişkisi Şekil 35b'de detaylandırılmıştır. Trend analizi, kilometre başına enerji


tüketiminin 23,1 Wh/km olduğunu göstermektedir. Bu lineer ilişki, 100 kilometrelik mesafede yaklaşık 2300 Wh enerji tüketimi gerçekleştiğini ortaya koymaktadır. Veri noktalarının trend çizgisi etrafındaki dağılımı, farklı operasyonel koşulların enerji tüketiminde yarattığı varyasyonu yansıtmaktadır.



Şekil 35. Güvenli iniş ve trafik analizi; (a) mesafe-süre ilişkisi, (b) mesafe-enerji tüketimi, (c) güvenli iniş noktaları ve (d) günlük hava trafik yoğunluğu.

Şekil 35c'de yer alan güvenli iniş noktaları haritası, Giresun ilçelerindeki iniş alanlarının coğrafi dağılımını göstermektedir. Eynesil ilçesinin en büyük güvenli iniş alanına sahip olduğu, daire büyüklüğünden anlaşılmaktadır. Maksimum rüzgar hızı değerlerinin 12-24 m/s arasında değiştiği, kıyı bölgelerinde daha yüksek rüzgar hızlarının gözlemlendiği tespit edilmiştir. Şebinkarahisar, Alucra ve Çamoluk gibi iç kesimlerdeki ilçelerin daha düşük rüzgar hızlarına sahip olması, topografik korumanın etkisini göstermektedir. Günlük hava trafiği yoğunluğu Şekil 35d'de analiz edilmiştir. Sabah 06:00-10:00 saatleri arasında uçuş sayısının 300'ün üzerine çıktığı, öğleden sonra 17:00-20:00 saatleri arasında ise 320-340 aralığında pik yaptığı görülmektedir. Gece saatlerinde trafiğin 50-100 uçuş aralığına düştüğü, gündüz saatlerinde ise ortalama 100-150 uçuş seviyesinde seyrettiği tespit edilmiştir. Bu trafik akışının zaman içerisinde düzeni, dağılımı ve tekrarlanan davranış biçimlerinin (paterninin) oluşumunun en temel sebebi, çalışanların mesai başlangıcı veya bitiminde kargolarını teslim almak üzere uygun konumda bulunmalarına bağlanmaktadır.


Şekil 36'da sunulan Q-öğrenme analizleri, sistemin öğrenme performansını ve rota optimizasyonunu kapsamlı bir şekilde değerlendirmektedir. Şekil 36a'da görüldüğü üzere, Q-öğrenme eğitim süreci 1500 tam deneme turu boyunca izlenmiştir. Toplam ödül değerlerinin başlangıçta yaklaşık 300 seviyesinde olduğu ve eğitim sürecinde bazı dönemlerde artarak 350 seviyelerine ulaştığı tespit edilmiştir. Mavi alan ile gösterilen varyasyon bandının -100 ile 600 arasında geniş bir aralıkta dağılım göstermesi, öğrenme sürecindeki keşif-kullanım dengesini yansıtmaktadır. En sık kullanılan başarılı rotalar Şekil 36b'de analiz edilmiştir. Özellikle günlük bölgeler arasındaki rotaların daha az tercih edilmesi, topografik faktörlerin rota seçiminde önemli rol oynadığını göstermektedir. Q-öğrenme algoritmasının öğrenme sürecinde gösterdiği performans artışı, sistemin çevresel faktörleri ve operasyonel kısıtları dikkate alarak optimal rota seçimi yapabilme yeteneğini geliştirdiğini ortaya koymaktadır. Pekiştirmeli öğrenme algoritması olan Q-öğrenme, değişken koşullarda sistemin performansının sürekli iyileştirilmesini sağlamaktadır.



Şekil 36. Q-öğrenme analizi sonuçları; (a) Q-öğrenme eğitim süreci ve (b) en sık kullanılan başarılı rotalar.

OHKA sistemlerinin operasyonel performansının detaylı olarak izlenmesi ve telemetri verilerinin analiz edilmesi, sistem güvenilirliği ve verimliliğinin artırılması açısından önemlidir. Şekil 37'de sunulan OHKA telemetri verisi analizleri, çeşitli operasyonel parametrelerin birbirleri ile olan ilişkilerini kapsamlı bir şekilde ortaya koymaktadır. Şekil 37a'da görüldüğü üzere, hız-batarya ilişkisi irtifa parametresiyle birlikte değerlendirilmiştir. Yer hızının 2-14 m/s arasında değiştiği ve batarya yüzdesinin 20-100 aralığında dağılım gösterdiği tespit edilmiştir. Veri noktalarının yoğunlaşması, operasyonların büyük çoğunluğunun 5-11 m/s hız aralığında gerçekleştirildiğini göstermektedir. İrtifa değişimlerinin renk kodlaması ile gösterilmesi, yüksek irtifada daha fazla enerji tüketimi gerçekleştiğini ortaya koymaktadır. Motor RPM dağılımı Şekil 37b'de analiz edilmiştir. Ortalama motor devir sayısının 5000–6000 RPM aralığında yoğunlaştığı; dağılımın tek bir tepe yerine iki belirgin mod sergileyerek yaklaşık


5000–5500 ve 5500–6000 RPM bantlarında kümелendiği görülmektedir. Bu görünüm, verinin tek bir kararlı çalışma koşulundan ziyade farklı uçuş fazları/itki gereksinimleri (örneğin ilerleme/tırmanış), rüzgâr telafisi veya yük/enerji durumu gibi etkenlerle oluşan iki operasyonel rejimin bileşimi olabileceğine işaret edebilir. Dolayısıyla motor davranışı genel olarak kontrollü olmakla birlikte, yorumun kesinleştirilmesi için RPM'in uçuş modu ya da görev fazına göre ayrıştırılarak değerlendirilmesi uygun olacaktır.



Şekil 37. OHKA telemetri verisi analizi; (a) hız – batarya ilişkisi, (b) motor RPM dağılımı, (c) yük ağırlığına göre batarya performansı ve (d) örnek uçuş profili.

Şekil 37c'de yük ağırlığına göre batarya performansı değerlendirilmiştir. Grup 1, 2 ve 3'ün yaklaşık %62 batarya tüketimi gösterdiği, Grup 4'ün %54 ile en düşük tüketim değerine sahip olduğu ve Grup 5'in %57 tüketim ile orta seviyede performans sergilediği tespit edilmiştir. Bu sonuçlar, Grup 4'ün enerji verimliliği açısından optimal olduğunu ortaya koymaktadır. Örnek uçuş profili Şekil 37d'de detaylandırılmıştır. Batarya seviyesinin uçuş başlangıcında %100'den başlayarak kademeli olarak azaldığı, uçuş sonunda yaklaşık yüzde 20 seviyesine düştüğü görülmektedir. İrtifa profilinin 40-60 metre arasında dalgalanma gösterdiği, özellikle 58-78 zaman indeksi aralığında belirgin irtifa değişimlerinin yaşandığı tespit edilmiştir. Batarya tüketimindeki ani düşüşlerin irtifa değişimleri ile ilişkili olduğu gözlenmiştir.


OHKA teslimat sistemlerinde yapay zekâ tabanlı görüntü işleme ve tehlike algılama yeteneklerinin geliştirilmesi, operasyonların güvenli bir şekilde tamamlanması açısından önemlidir. Şekil 38'de sunulan CNN analizleri, derin öğrenme modelinin eğitim sürecini ve performans karakteristiklerini kapsamlı bir şekilde değerlendirmektedir. Şekil 38a'da görüldüğü üzere, model kayıp değişimi 15 eğitim verisi turu boyunca izlenmiştir. Eğitim kaybı değerinin 2,25'ten başlayarak 0,2 seviyelerine düştüğü, doğrulama kaybı değerinin ise benzer bir trend izleyerek 2,25 civarından 0,3 seviyelerine düştüğü tespit edilmiştir. İki eğri arasındaki yakın ilişki, modelin aşırı öğrenme problemi yaşamadığını ve iyi bir genelleme yeteneğine sahip olduğunu göstermektedir. Model doğruluk oranı analizi Şekil 38b'de sunulmuştur. Eğitim doğruluğu değerinin tur sayısı ilerledikçe artarak %95 seviyelerine ulaştığı, doğrulama doğruluğu değerinin ise %91,7 ile en yüksek performansı gösterdiği belirlenmiştir. Bu yüksek doğruluk oranları, modelin tehlike algılama görevinde etkin bir performans sergilediğini ortaya koymaktadır. Şekil 38c'de yer alan karmaşıklık matrisi, modelin sınıflandırma performansını detaylı olarak göstermektedir. Güvenli sınıfı için doğru tahmin oranının %77,5 ve tehlikeli sınıfı için ise %77,5 olduğu tespit edilmiştir. Yanlış pozitif oranının %22,5 ve yanlış negatif oranının %22,5 olması, modelin dengeli bir sınıflandırma performansı gösterdiğini ortaya koymaktadır. Şekil 38d'de sunulan ROC eğrisi, modelin ayırt edicilik performansını göstermektedir. AUC değerinin 0,952 olması, modelin mükemmele yakın bir sınıflandırma performansı sergilediğini ortaya koymaktadır. Optimum nokta olarak belirlenen 0 ve 0,78 koordinatları, yüksek hassasiyet ve düşük yanlış pozitif oranı dengesinin sağlandığını göstermektedir. Öğrenme hızı analizi Şekil 38e'de detaylandırılmıştır. Kayıp değişim hızının eğitim verisi tur sayısı ilerledikçe azaldığı ve öğrenme durgunlaşması noktasında sıfıra yaklaştığı görülmektedir. Negatif değerler modelin öğrenme sürecinde olduğunu, sıfıra yakın değerler ise optimum noktaya yaklaşıldığını göstermektedir. Tahmin güven dağılımı Şekil 38f'de analiz edilmiştir. Doğru tahminlerin güven skorlarının %0,82 civarında yoğunlaştığı, yanlış tahminlerin ise %0,56 civarında dağılım gösterdiği tespit edilmiştir. Bu belirgin ayırım, modelin tahminlerinde güvenilir olduğunu ve belirsizlik durumlarını etkin bir şekilde yansıttığını göstermektedir.




Şekil 38. CNN performans analizleri; (a) model kayıp değişimi, (b) model doğruluk oranı, (c) karmaşıklık matrisi, (d) ROC eğrisi, (e) öğrenme hızı analizi ve (f) tahmin güven dağılımı.

OHKA teslimat sistemlerinde hava trafiği yönetimi ve çarpışma önleme sistemlerinin geliştirilmesi, çoklu OHKA operasyonlarının güvenli bir şekilde yürütülmesi için hayati öneme sahiptir. Şekil 39'da sunulan çarpışma önleme sistemi analizleri, üç boyutlu uzayda OHKA hareketlerinin koordinasyonunu kapsamlı bir şekilde değerlendirmektedir.


Şekil 39a'da görüldüğü üzere, 3D OHKA yolları ve çarpışma önleme sisteminin görselleştirilmesinde, farklı renklerde gösterilen OHKA yörüngelerinin üç boyutlu uzayda karmaşık bir hareket deseni oluşturduğu tespit edilmiştir. Z ekseninde 50-350 metre aralığında, X ekseninde 200-900 metre aralığında ve Y ekseninde ise 100-900 metre aralığında hareket eden OHKA'ların yörüngelerinin kesişim noktalarında potansiyel çarpışma riskleri bulunduğu görülmektedir. Yan görünüm XZ düzlemi analizi Şekil 39b'de sunulmuştur. Farklı renklerde gösterilen yörüngelerin kesişim noktaları, sistemin çarpışma önleme algoritmasının devreye girmesi gereken kritik bölgeleri işaret etmektedir. Şekil 39c'de yer alan üstten görünüm XY düzlemi, yatay düzlemdeki tekrarlanan davranış biçimlerinin göstermektedir. XY düzlemi analizi sonucunda OHKA'ların, özellikle merkezi bölgelerde yoğun trafik oluşturduğu görülmektedir. Bu yoğunluk, hava koridorlarının optimize edilmesi gerektiğini ortaya koymaktadır. Yan görünüm YZ düzlemi Şekil 39d'de detaylandırılmıştır. YZ düzlemi boyunca değişen OHKA konumlarının, dikey düzlemde de karmaşık hareket desenleri oluşturduğu tespit edilmiştir. Farklı yükseklik katmanlarının kullanılması, çarpışma riskini azaltmak için önemli bir strateji olarak görülmektedir. Şekil 39e'de sunulan son durum mesafe matrisi, OHKA'lar arası mesafeleri metre cinsinden göstermektedir. Matristeki koyu kırmızı bölgeler, 0-200 metre aralığındaki kritik yakınlıkları işaret etmektedir. Yeşil bölgeler ise 600-800 metre aralığındaki güvenli mesafeleri temsil etmektedir. Bu matris, anlık çarpışma riski değerlendirmesinde kritik bir araç olarak kullanılmaktadır. Yükseklik kullanım dağılımı Şekil 39f'de analiz edilmiştir. 150-300 metre aralığındaki yüksekliklerin en sık kullanıldığı, özellikle 150, 225 ve 275 metre bandında yaklaşık 725 ile en yüksek frekans değerine eriştiği görülmektedir. Bu dağılım, hava trafiği yönetiminde belirli yükseklik katmanlarının yoğun kullanıldığını ve dikey ayırım stratejilerinin optimize edilmesi gerektiğini göstermektedir.




(a)




(b)




(c)



(d)




(e)



(f)


Şekil 39. Çarpışma önleme sistemi; (a) 3D OHKA yolları ve çarpışma önleme, (b) yan görünüm XZ düzlemi, (c) üstten görünüm XY düzlemi, (d) yan görünüm YZ düzlemi, (e) mesafe matrisi ve (f) yükseklik kullanım dağılımı.

OHKA teslimat sistemlerinde batarya yönetiminin kritik önemi nedeniyle, gelişmiş makine öğrenmesi modellerinin kullanılarak batarya seviyesi tahminlerinin yapılması operasyonel sürdürülebilirlik açısından büyük önem taşımaktadır. Şekil 40'ta sunulan LSTM ve GRU model performans karşılaştırması, bu iki derin öğrenme yaklaşımının etkinliğini kapsamlı bir şekilde değerlendirmektedir. Şekil 40a'da görüldüğü üzere, model eğitim kayıpları 100 eğitim verisi turu boyunca izlenmiştir. LSTM ve GRU modellerinin eğitim ve test kayıpları logaritmik ölçekte sunulmuş olup, her iki modelin de ilk turlarda hızlı bir öğrenme eğrisi gösterdiği tespit edilmiştir. Başlangıçtaki 10^{-1} seviyesindeki kayıp değerlerinin, 20. turdan sonra yaklaşık 2×10^{-2} seviyelerine düştüğü ve bu seviyede stabilize olduğu görülmektedir. LSTM ve GRU modellerinin eğitim ve test kayıpları arasındaki yakın ilişki, her iki modelin de aşırı öğrenme problemi yaşamadığını ve iyi genelleme yeteneğine sahip olduğunu ortaya koymaktadır. Batarya seviyesi tahminleri Şekil 40b'de detaylı olarak analiz edilmiştir. 800 zaman indeksi boyunca gerçek batarya seviyeleri ile LSTM ve GRU model tahminlerinin karşılaştırılması, her iki modelin de periyodik şarj-deşarj döngülerini başarıyla tahmin edebildiğini göstermektedir. Batarya seviyesinin %20 ile %100 arasında değiştiği ve yaklaşık 100 zaman indeksi aralıklarla tekrarlayan şarj döngülerinin bulunduğu tespit edilmiştir. LSTM ve GRU tahminlerinin gerçek değerlerle neredeyse örtüştüğü, özellikle ani düşüş ve yükseliş noktalarında her iki modelin de yüksek hassasiyet gösterdiği görülmektedir. Model performanslarının karşılaştırılması, LSTM ve GRU yaklaşımlarının batarya seviyesi tahmininde benzer başarı gösterdiğini ortaya koymaktadır. Her iki modelin de zaman serisi verilerindeki uzun vadeli bağımlılıkları yakalayabilmesi, OHKA operasyonlarında kritik olan batarya yönetimi için güvenilir tahminler sağlamaktadır. Bu tahmin yetenekleri, operasyonel planlama ve risk yönetimi açısından değerli karar destek araçları sunmaktadır.



Şekil 40. LSTM ve GRU model performans karşılaştırması; (a) model eğitim kayıpları ve (b) batarya seviyesi tahminleri.

Şekil 41'de sunulan titreşim analizleri, sistemin mekanik durumunu ve potansiyel arıza belirtilerini kapsamlı bir şekilde değerlendirmektedir. Şekil 41a'da görüldüğü üzere, üç eksen titreşim verileri 1000 zaman indeksi boyunca izlenmiştir. X ve Y eksenlerindeki titreşim değerlerinin 0,2-0,8 g (yerçekimi ivmesi, $1g = 9,81 \text{ m/s}^2$) aralığında salınım gösterdiği, Z ekseninde ise 0,1-0,9 g aralığında değiştiği gözlenmiştir. Bu farklılık, OHKA'ların dikey eksen boyunca daha fazla mekanik strese maruz kaldığını göstermektedir.




Şekil 41. Yüksek frekans sensör verisi ve titreşim analizleri; (a) 3 eksen titreşim verileri, (b) titreşim frekans spektrumu, (c) titreşim anomali tespiti, (d) motor sıcaklığı – titreşim ilişkisi, (e) hareketli ortalama ve (f) titreşim istatistikleri.

Şekil 41b'de titreşim frekans spektrumu analiz edilmiştir. Güç spektrum yoğunluğunun 0-25 Hz frekans değerinde belirginlik gösterdiği ve 10^{-3} seviyesine ulaştığı görülmektedir. Bu frekans değeri, motor dönüş hızı veya pervanelerin rezonans frekansı ile ilişkilendirilebilir. Spektrumun geri kalanında güç yoğunluğunun stabilize göstermesi, sistemin genel olarak kararlı çalıştığını göstermektedir. Şekil 41c'de yer alan titreşim anomali tespiti, 60000 zaman indeksi boyunca normal ve anomali durumlarını göstermektedir. Normal titreşim değerlerinin 0,6-1,2 aralığında yoğunlaştığı, anomali olarak işaretlenen kırmızı noktaların ise 1,5-2,0 aralığında ve 0-0,3 aralığında periyodik olarak ortaya çıktığı tespit edilmiştir. Bu periyodik anomaliler, bakım gerektiren bileşenlerin varlığına işaret etmektedir. Motor sıcaklığı-titreşim ilişkisi Şekil 41d'de sunulmuştur. Ortalama motor sıcaklığının 43-47°C aralığında olduğu ve titreşim genliği 0,5-1,2 g aralığında yoğunlaştığı görülmektedir. Sıcaklık arttıkça titreşim değerlerinin de artma eğiliminde olması, termal genleşme ve mekanik tolerans değişimlerinin etkisini ortaya koymaktadır. Renk skalasında gösterilen zaman indeksi, operasyon süresince bu ilişkinin evrimini yansıtmaktadır. Şekil 41e'de sunulan hareketli ortalama analizi, titreşim verilerinin uzun vadeli trendini göstermektedir. Ortalama değerin 0,8 g civarında seyrettiği ve $\pm 2\sigma$ bantları içinde kaldığı tespit edilmiştir. Periyodik olarak yaklaşık 2,0 g seviyelerine ulaşan değerler, sistemin belirli operasyonel koşullarda yüksek titreşim ürettiğini göstermektedir. Titreşim istatistikleri Şekil 41f'de tablo formatında özetlenmiştir. Z ekseninin diğer eksenlere göre daha yüksek ortalama ve standart sapma değerlerine sahip olması, dikey yöndeki dinamik yüklerin daha fazla olduğunu doğrulamaktadır.

OHKA sistemlerinde çoklu sensör verilerinin entegrasyonu ve durum kestirimi, güvenilir ve hassas operasyonların gerçekleştirilmesi için önemlidir. Şekil 42'de sunulan sensör füzyonu ve durum kestirimi analizleri, sistemin algılama ve karar verme yeteneklerini kapsamlı bir şekilde değerlendirmektedir. Şekil 42a'da görüldüğü üzere, sensör korelasyon matrisi altı farklı sensör arasındaki ilişkileri ortaya koymaktadır. Kalman filtresi ile irtifa tahmini Şekil 42b'de analiz edilmiştir. Gerçek irtifa değerlerinin 60-200 metre arasında değiştiği, gürültülü GPS verilerinin önemli sapmalar gösterdiği görülmektedir. Kalman filtresi tahminlerinin gerçek değerleri yakından takip etmesi ve gürültüyü etkin bir şekilde filtrelemesi, füzyon algoritmasının başarılı çalıştığını göstermektedir. Özellikle ani irtifa değişimlerinde filtrenin hızlı adaptasyon yeteneği dikkat çekmektedir. Şekil 42c'de yer alan IMU tabanlı yönelim tahmini, roll (kanat yatışı), pitch (burun yukarı/aşağı) ve yaw (burun sağa/sola) açılarının zaman içindeki değişimini göstermektedir. Roll açısının -0,01 ile 0,02 radyan arasında, pitch açısının 0 ile 0,01 radyan arasında ve yaw açısının -0,01 ile 0,03 radyan arasında değiştiği tespit edilmiştir. Bu küçük açı değerleri, OHKA'nın kararlı uçuş modunda olduğunu ve otonom stabilizasyon sisteminin etkin çalıştığını göstermektedir. Sensör güvenilirlik analizi Şekil


42d'de sunulmuştur. GPS ve LiDAR sensörlerinin sırasıyla 0,95 ve 0,93 güvenilirlik skoru ile en yüksek performansı gösterdiği belirlenmiştir. Bu skorlar, sensör füzyonu algoritmasında ağırlıklandırma için kullanılabilecek önemli parametrelerdir.




Şekil 42. Sensör füzyonu ve durum kestirimi analizi; (a) sensör korelasyon matrisi, (b) kalman filtresi ve irtifa tahmini, (c) IMU tabanlı yönelim tahmini ve (d) sensör güvenilirlik analizi.

Şekil 43'te sunulan analizler, sistemin bakım yönetimi ve arıza tahmin yeteneklerini kapsamlı bir şekilde değerlendirmektedir. Şekil 43a'da görüldüğü üzere, arıza belirtileri özeti üç ana sınıfta verilmiştir. Bu sınıflandırma, bakım önceliklerinin belirlenmesinde kritik bir girdi sağlamaktadır. Bathub eğrisi (bir cihazın veya ekipmanın ömrü boyunca arıza oranının nasıl değiştiğini gösterir) arıza olasılığı analizi Şekil 43b'de sunulmuştur. Bu eğri, bakım stratejilerinin yaşam döngüsüne göre optimize edilmesi gerektiğini ortaya koymaktadır. Şekil 43c'de yer alan önleyici bakım takvimi, farklı bileşenler için bakım periyotlarını detaylandırmaktadır. Bu kademeli bakım yaklaşımı, kritik bileşenlerin düzenli kontrolünü sağlarken, operasyonel kesintileri minimize etmektedir. Bakım stratejileri maliyet karşılaştırması Şekil 43d'de analiz edilmiştir.

Şekil 44'te sunulan sensör anomali analizleri, farklı makine öğrenmesi yaklaşımları kullanılarak anomali tespitin çok boyutlu değerlendirmesini sağlamaktadır. Şekil 44a'da görüldüğü üzere, yeniden yapılandırma hatası dağılımı normal bir dağılım profili sergilemektedir. Hataların büyük çoğunluğunun 0-1 aralığında yoğunlaştığı, 1,1091 eşik değerinin üzerindeki değerlerin anomali olarak sınıflandırıldığı tespit edilmiştir. Bu eşik değeri, normal operasyonel varyasyonların üst sınırını temsil etmekte ve sistemin istatistiksel olarak anlamlı sapmaları tespit etmesini sağlamaktadır.




Şekil 43. Arıza tahmini ve önleyici bakım analizi; (a) arıza belirtileri özeti, (b) bathtub eğrisi – arıza olasılığı, (c) önleyici bakım takvimi ve (d) bakım stratejileri maliyet karşılaştırması.



Şekil 44. Sensör anomali analizi; (a) yeniden yapılandırma hatası dağılımı, (b) zaman serisi anomali tespiti, (c) 3D PCA uzayında anomaliler ve (d) DBSCAN kümeleme ile anomali tespiti.


Zaman serisi anomali tespiti Şekil 44b'de analiz edilmiştir. MSE değerinin gösterilmesi, modelin performansının kantitatif olarak değerlendirilmesini sağlamaktadır. Anomalilerin zaman içindeki dağılımı, sistemde periyodik veya rastgele arıza davranışlarının varlığını ortaya koymaktadır. Şekil 44c'de yer alan 3D PCA uzayında anomali görselleştirmesi, boyut indirgeme tekniği kullanılarak yüksek boyutlu sensör verilerinin üç ana bileşene indirgenmesini göstermektedir. Normal veri noktalarının merkezi bir küme oluşturduğu, anomali noktalarının ise bu kümenin dışında dağıldığı tespit edilmiştir. PC1, PC2 ve PC3 eksenlerindeki -4 ile 4 arasındaki değer aralığı, veri varyansının büyük kısmının bu üç bileşende toplandığını göstermektedir. DBSCAN kümeleme ile anomali tespiti Şekil 44d'de detaylandırılmıştır. Yoğunluk tabanlı kümeleme algoritması kullanılarak, ana veri kümesinin (Küme 0) merkezi bölgede yoğunlaştığı, gürültü veya anomali olarak sınıflandırılan noktaların ise çevresel bölgelerde dağıldığı görülmektedir. Bu yaklaşım, önceden tanımlanmış eşik değerlerine ihtiyaç duymadan, veri yoğunluğuna dayalı olarak anomalileri tespit edebilmektedir. Bu çok yönlü anomali tespit yaklaşımları, farklı anomali tiplerinin yakalanmasını sağlamakta ve sistemin güvenilirliğini artırmaktadır. Yeniden yapılandırma hatası, PCA ve DBSCAN yöntemlerinin birlikte kullanılması hem istatistiksel hem de yapısal anomalilerin tespit edilmesini mümkün kılmaktadır.

Şekil 45'te sunulan analizler, hava koşullarının OHKA operasyonları üzerindeki etkilerini kapsamlı bir şekilde değerlendirmektedir. Mevsimsel değişkenlik, OHKA operasyonlarının planlanmasında kritik bir parametre olarak değerlendirilmelidir. Mevsimsel sıcaklık dağılımı Şekil 45a'da incelenmiştir. Basınç-sıcaklık ilişkisi Şekil 45b'de rüzgar hızı parametresiyle birlikte analiz edilmiştir. Rüzgar hızının 0-14 m/s aralığında değişmesi, farklı meteorolojik koşullarda OHKA operasyonlarının gerçekleştirilebileceğini göstermektedir. Şekil 45c'de yer alan görüş mesafesi dağılımı, uçuş güvenliği açısından kritik bir parametre olarak değerlendirilmiştir. Görüş mesafesinin 0-15000 metre aralığında dağılım gösterdiği, en yüksek frekansın 1000-2000 metre aralığında gerçekleştiği tespit edilmiştir. Düşük görüş koşullarının (1 km altı) ve orta görüş koşullarının (5 km altı) sırasıyla kırmızı ve turuncu çizgilerle işaretlenmesi, operasyonel risk seviyelerinin belirlenmesinde önemli bir referans sağlamaktadır. Nem-yağış ilişkisi Şekil 45d'de detaylandırılmıştır. OHKA operasyonları için genellikle uygun koşulların mevcut olduğunu, ancak nem faktörünün batarya performansı ve elektronik sistemler üzerindeki etkisinin göz önünde bulundurulması gerektiğini ortaya koymaktadır.



Şekil 45. Meteorolojik ve çevresel faktörlerin analizi; (a) mevsimsel sıcaklık dağılımı, (b) basınç-sıcaklık ilişkisi, (c) görüş mesafesi dağılımı ve (d) nem – yağış ilişkisi.


Şekil 46'da sunulan iniş bölgeleri analizleri, güvenli iniş noktalarının belirlenmesi ve operasyonel risklerin minimize edilmesi açısından kapsamlı bir değerlendirme sağlamaktadır. Şekil 46a'da görüldüğü üzere, iniş alanı risk dağılımı üç kategoride değerlendirilmiştir. Orta risk kategorisinde 108 iniş alanının bulunması, mevcut iniş noktalarının büyük çoğunluğunun orta düzeyde operasyonel risk taşıdığını göstermektedir. Yüksek risk kategorisinde 32 alanın yer alması, bu bölgelerde özel güvenlik önlemlerinin alınması gerektiğini ortaya koymaktadır. Düşük risk kategorisinde sadece 17 alanın bulunması, ideal iniş koşullarına sahip bölgelerin sınırlı olduğunu işaret etmektedir. Yüzey malzemesine göre güvenlik analizi Şekil 46b'de sunulmuştur. Asfalt yüzeylerin 0,49 güvenlik skoru ile en düşük değere sahip olduğu, kum ve toprak yüzeylerin ise 0,54 güvenlik skoru ile en yüksek değerleri aldığı tespit edilmiştir. Beton yüzeylerin 0,52, çim yüzeylerin ise 0,53 güvenlik skoru alması, farklı yüzey tiplerinin OHKA inişleri için benzer güvenlik seviyeleri sunduğunu ancak yumuşak yüzeylerin hafif bir avantaja sahip olduğunu göstermektedir. Şekil 46c'de alan büyüklüğü-güvenlik skoru ilişkisi, engel yüksekliği parametresiyle birlikte değerlendirilmiştir. Büyük alanlarda güvenlik skorlarının genellikle daha yüksek olduğu, ancak engel yüksekliğinin artmasıyla (kırmızı tonlarda gösterilen 180 metreye yakın değerler) güvenlik skorlarının düştüğü tespit edilmiştir.



Şekil 46. İniş bölgeleri; (a) iniş alanları risk dağılımı, (b) yüzey malzemesine göre güvenlik, (c) alan büyüklüğü – güvenlik skoru ve (d) Giresun ili ve ilçeleri iniş bölgeleri.

Giresun ili ve ilçeleri iniş bölgeleri haritası Şekil 46d'de görselleştirilmiştir. İniş noktalarının il genelinde dağılım gösterdiği, özellikle kıyı şeridinde ve merkezi yerleşim alanlarında yoğunlaştığı tespit edilmiştir. Güney bölgelerinde ve dağlık kesimlerde iniş noktalarının daha seyrek olması, topografik koşulların iniş bölgesi seçiminde belirleyici faktör olduğunu ortaya koymaktadır.


Şekil 47'de sunulan kargo analizleri, yük karakteristiklerinin sistem performansı üzerindeki etkilerini kapsamlı bir şekilde değerlendirmektedir. Şekil 47a'da görüldüğü üzere, kargo ağırlık dağılımı 0-5 kg aralığında analiz edilmiştir. Dağılımın 0,5 kg civarında maksimum yoğunluk gösterdiği tespit edilmiştir. Kernel yoğunluk tahmini (Kernel density estimation - KDE) eğrisinin, ağırlık dağılımının 3,4 kg aralığında ikinci kez yoğunluk gösterdiğini ortaya koyması, teslimat sisteminde iki farklı kargo kategorisinin yaygın olduğunu işaret etmektedir. Bu bimodal dağılım, operasyonel planlama ve OHKA seçiminde önemli bir girdi sağlamaktadır. Kargo boyut dağılımı Şekil 47b'de üç boyutlu olarak görselleştirilmiştir. Veri noktalarının yoğunlukla 20-40 cm en ve boy değerlerinde, 10-20 cm yükseklik değerlerinde kümелendiği tespit edilmiştir. Bu boyut dağılımı, OHKA'nın kompartımanının tasarımı ve aerodinamik optimizasyon açısından kritik bilgiler sağlamaktadır.



Şekil 47. Kargo analizleri – 1; (a) kargo ağırlık dağılımı, (b) kargo boyut dağılımı, (c) ağırlık merkezi – stabilite ilişkisi ve (d) farklı yükleme senaryolarında stabilite.

Şekil 47c'de yer alan ağırlık merkezi-stabilite ilişkisi analizi, yük dengesinin uçuş stabilitesi üzerindeki etkisini ortaya koymaktadır. Ağırlık merkezi noktasından olan kayma miktarının 0-5 cm arasında değiştiği, stabilite skorlarının ise 0,5-1 aralığında dağılım gösterdiği görülmektedir. Polinom eğrisinin yaklaşık 0,75 seviyesinde yatay seyretmesi, belirli bir ağırlık merkezinden kayma miktarına kadar stabilitenin korunabildiğini, ancak aşırı dengesizlik durumlarında stabilite kaybının yaşanabileceğini göstermektedir. Farklı yükleme senaryolarında stabilite analizi Şekil 46d'de sunulmuştur. 30 dakikalık uçuş süresi boyunca optimal yüklemenin 0,95-1 aralığında yüksek stabilite değerleri gösterdiği tespit edilmiştir. Dengesiz yükleme senaryosunda stabilite skorlarının 0,75-0,90 aralığında dalgalandığı, aşırı yükleme durumunda ise 0,50-0,75 aralığına düşerek kritik eşiğin altında seyrettiği görülmektedir. Bu analiz, yükleme kalitesinin uçuş güvenliği üzerindeki doğrudan etkisini kantitatif olarak ortaya koymaktadır.


Şekil 48'de sunulan ikinci kargo analizi seti, yük karakteristiklerinin çok boyutlu değerlendirmesini sağlamaktadır. Şekil 48a'da görüldüğü üzere, kargo hassasiyet matrisi iki ana kategori ve iki alt kategori üzerinden değerlendirilmiştir. Buradaki dağılımdan, toplam kargo yükünün önemli bir kısmının özel taşıma koşulları gerektirmediğini, ancak sıcaklık kontrolü gerektiren kargoların da azımsanmayacak oranda olduğu anlaşılmaktadır.




Şekil 48. Kargo analizleri – 2; (a) kargo hassasiyet matrisi, (b) OHKA yük alanı ağırlık dağılımı, (c) kargo tipi dağılımı ve (d) yükleme stratejisi performans karşılaştırması.

OHKA yük alanı ağırlık dağılımı Şekil 48b'de ısı haritası formatında sunulmuştur. Yük ağırlığının 0,5-2,5 kg aralığında değiştiği ve merkezi bölgelerde yoğunlaştığı tespit edilmiştir. Bu dağılım, yükleme dengesi açısından optimum koşulların sağlandığını ortaya koymaktadır. Şekil 48c'de yer alan kargo tipi dağılımı, teslimat sisteminde taşınan ürün çeşitliliğini göstermektedir. Buradaki dengeli dağılım, sistemin çeşitli kargo tiplerini etkin bir şekilde taşıyabildiğini göstermektedir. Yükleme stratejisi performans karşılaştırması Şekil 48d'de matris formatında analiz edilmiştir. Bu sonuçlar, farklı yükleme stratejilerinin belirli kargo tipleri için optimize edilebileceğini ortaya koymaktadır.


Şekil 49'da sunulan transfer öğrenme analizleri, farklı derin öğrenme mimarilerinin karşılaştırmalı değerlendirmesini kapsamlı bir şekilde ortaya koymaktadır. Şekil 49a'da görüldüğü üzere, transfer öğrenme model karşılaştırmasında beş farklı mimarinin parametre sayısı ve test doğrulukları analiz edilmiştir. Çok sınıflı ROC eğrileri Şekil 49b'de detaylandırılmıştır. Güvenli kategorisinin 0,87 AUC değeri ile en yüksek sınıflandırma performansını gösterdiği belirlenmiştir. Dikkatli, riskli ve yasaklı kategorilerinin ayırt edilmesinde modelin zorlandığı tespit edilmiştir. Bu durum sınıflar arası benzerliğin etkisi olarak değerlendirilmektedir.




(a)



(b)



(c)




(d)

Şekil 49. Transfer öğrenme; (a) transfer öğrenme model karşılaştırması, (b) çok sınıflı ROC eğrileri, (c) öğrenme hızı programlama stratejileri ve (d) öz-dikkat ağırlık haritası.

Şekil 49c'de yer alan öğrenme hızı programlama stratejileri, model eğitimi boyunca farklı yaklaşımların karşılaştırılmasını sağlamaktadır. Sabit öğrenme hızının 10^{-3} seviyesinde stabil bir görünüm sergilediği, adım beklemeli stratejide ise kademeli olarak azalma görülmektedir. Üstel azalma stratejisinin sürekli bir düşüş eğrisi izlediği, kosinüs tavlama yaklaşımının ise 100. tura doğru hızlı bir düşüş gösterdiği tespit edilmiştir. Bu farklı stratejiler, model yakınsama davranışını optimize etmek için kullanılabilecek seçenekleri ortaya koymaktadır. Öz-dikkat (bir dizideki her elemanın, aynı dizideki diğer tüm elemanlara "dikkat ederek" kendi temsilini oluşturduğu bir mekanizma) ağırlık haritası Şekil 49d'de görselleştirilmiştir. 13x13 boyutundaki matriste belirli bölgelerde yoğunlaşan yüksek dikkat ağırlık değerleri, modelin görüntünün hangi alanlarına odaklandığını göstermektedir. Özellikle köşegenli ve belirli çapraz bölgelerdeki yüksek dikkat değerleri, modelin uzamsal ilişkileri yakaladığını ve kritik özelliklere odaklandığını ortaya koymaktadır.


Ekonomik Analizler

OHKA teslimat sistemlerinin ekonomik sürdürülebilirliğinin değerlendirilmesi için kapsamlı finansal analizlerin gerçekleştirilmesi, yatırım kararlarının verilmesinde kritik öneme sahiptir. Şekil 50'de sunulan NŞD, iç verim (getiri) oranı ve geri ödeme periyodu analizleri, projenin finansal uygulanabilirliğini çok boyutlu olarak ortaya koymaktadır. Şekil 50a'da görüldüğü üzere, NŞD duyarlılık analizi iskonto oranının proje değeri üzerindeki etkisini göstermektedir. İskonto oranı %0'dan başlayarak arttıkça, NŞD'nin 89,2 milyon TL seviyelerinden başlayarak sürekli azaldığı tespit edilmiştir. İç karlılık oranının %133 olarak belirlenmesi, projenin yüksek getiri potansiyeline sahip olduğunu ortaya koymaktadır. Yıllık ve kümülatif nakit akışları Şekil 50b'de analiz edilmiştir. Başlangıç yatırımının 10 milyon TL olduğu, 2025 yılında 10,8 milyon TL pozitif nakit akışının başladığı görülmektedir. Nakit akışları incelendiğinde projenin artan getiri profiline sahip olduğu anlaşılmaktadır. Kümülatif nakit akışının 2029 sonunda yaklaşık 89,2 milyon TL'ye ulaşması, yatırımın güçlü bir finansal performans sergilediğini ortaya koymaktadır. Şekil 50c'de yer alan geri ödeme periyodu analizi, yatırımın geri dönüş süresini detaylandırmaktadır. Başlangıçtaki negatif nakit pozisyonunun 0,9 yıl gibi kısa bir sürede pozitive döndüğü tespit edilmiştir. Bu hızlı geri ödeme süresi, projenin likidite açısından cazip olduğunu ve yatırımcılar için düşük risk profili sunduğunu göstermektedir. 2025 yılından itibaren kümülatif nakit akışının sürekli artış göstermesi, projenin uzun vadeli değer yaratma potansiyelini ortaya koymaktadır. Finansal performans özeti Şekil 50d'de özetlenmiştir.



Şekil 50. NŞD, iç getiri oranı ve geri ödeme periyodu analizi; (a) NŞD duyarlılık analizi, (b) yıllık ve kümülatif nakit akışları, (c) geri ödeme periyodu analizi ve (d) finansal performans özeti.

Şekil 51'de sunulan sosyal yatırım getirisi (SROI) analizleri, projenin ekonomik değerinin ötesinde oluşturduğu sosyal ve çevresel faydaları kapsamlı bir şekilde ortaya koymaktadır. Şekil 51a'da görüldüğü üzere, SROI bileşenleri radar grafiği üzerinde beş farklı boyutta değerlendirilmiştir. Bu çok boyutlu değerlendirme, projenin sadece ekonomik değil, sosyal ve çevresel açıdan da önemli katkılar sağladığını göstermektedir. Yatırım ve sosyal fayda karşılaştırması Şekil 51b'de analiz edilmiştir. 4,0 milyon TL'lik yatırıma karşılık 6,5 milyon TL'lik sosyal fayda elde edilmesi, SROI değerinin 0,62:1 olarak gerçekleşmesini sağlamıştır. Bu oran, her 1 TL'lik yatırımın 1,62 TL'lik toplam değer oluşturduğunu göstermekte ve projenin sosyal açıdan verimli olduğunu ortaya koymaktadır. Şekil 51c'de yer alan SROI projeksiyon trendi, 2024-2028 döneminde SROI değerinin artış eğilimini göstermektedir. Başlangıçta 1,2 seviyelerinde olan SROI değerinin, 2028 yılında 2,5 seviyelerine ulaşması öngörülmektedir. Hedef SROI değerinin 2,0 olarak belirlendiği ve bu hedefin 2027 yılında aşılabacağı, projenin uzun vadede artan sosyal değer oluşturacağını göstermektedir.




Şekil 51. Sosyal yatırım getirisi (SROI); (a) SROI bileşenleri, (b) yatırım ve sosyal fayda karşılaştırması, (c) SROI projeksiyon trendi, (d) ekonomik etki akış diyagramı, (e) maliyet-etkinlik karşılaştırması ve (f) ilçe bazında ekonomik etki haritası.

Ekonomik etki akış diyagramı Şekil 51d'de detaylandırılmıştır. 100 milyon TL'lik drone (OHKA'ya çevrilmesi hariç tutulmuştur) yatırımının, 30 milyon TL'lik direkt istihdama, 20 milyon TL'lik endirekt istihdama ve 25 milyon TL'lik tedarik zincirine katkı sağladığı görülmektedir. 15 milyon TL'lik vergi gelirlerine katkı sağlanması, projenin kamu finansmanına da olumlu etki yaptığını göstermektedir. Şekil 51e'de sunulan maliyet-etkinlik karşılaştırması,

farklı teslimat yöntemlerinin normalize edilmiş değerlerini göstermektedir. OHKA'nın 15 TL maliyet indeksi ve 0,5 kg emisyon indeksi ile en verimli yöntem olduğu, kamyonun ise 50 TL-12,0 kg değerleri ile en yüksek maliyete ve emisyonu sahip olduğu tespit edilmiştir. Bu karşılaştırma, OHKA teknolojisinin çevresel sürdürülebilirlik açısından üstünlüğünü açıkça ortaya koymaktadır. İlçe bazında ekonomik etki haritası Şekil 51f'de görselleştirilmiştir. Merkezi ilçelerin daha yüksek ekonomik etki skorlarına sahip olması, nüfus yoğunluğu ve ekonomik aktivite ile ilişkilendirilebilir.

OHKA teslimat sistemlerinin uzun vadeli ekonomik sürdürülebilirliğinin değerlendirilmesi için toplam sahip olma maliyeti (TCO) analizinin gerçekleştirilmesi, yatırım kararlarında kritik öneme sahiptir. Şekil 52'de sunulan TCO analizleri, sistemin yaşam döngüsü boyunca oluşacak tüm maliyetleri kapsamlı bir şekilde ortaya koymaktadır. Şekil 52a'da görüldüğü üzere, 5 yıllık OHKA TCO dağılımı toplam 18,4 milyon TL olarak gerçekleşmiştir.




Şekil 52. Toplam sahip olma maliyeti; (a) 5 yıllık TCO dağılımı, (b) yıllık işletme maliyetleri trendi ve (c) OHKA ve geleneksel filo TCO karşılaştırması.


Yıllık işletme maliyetleri trendi Şekil 52b'de analiz edilmiştir. Personel maliyetlerinin en büyük operasyonel gider kalemi olduğu, bunu sırasıyla bakım, sigorta, enerji ve diğer maliyetlerin takip ettiği tespit edilmiştir. Maliyetlerdeki periyodik dalgalanmalar, operasyonel yoğunluk ve bakım döngüleri ile ilişkilendirilebilir. Şekil 52c'de yer alan OHKA ve geleneksel filo TCO karşılaştırması, iki farklı teslimat yönteminin maliyet profillerini ortaya koymaktadır.

OHKA Sistem Takip ve Simülasyon Ekranı

INCI – drone analiz kontrol paneli ekranının genel görünümü Şekil 53’de verilmiştir. Şekil 53a’da ana panelin görünümü bulunmaktadır. Bu panel içerisinde güncel filo durumu, aktif olan rotalar, teslimatlar ve ortalama batarya durumları görülmektedir. Canlı haritalar da yine bu ekran üzerinden erişim sağlanmaktadır. Şekil 53b’de ise ana panel görünümünün devamı bulunmaktadır. Bu ekran üzerinde modüllere hızlı erişim sağlanabilirken, aktivite akışları ve sistem uyarıları kontrol edilmektedir.




(a)




(b)

Şekil 53. INCI – drone analiz kontrol paneli ekranı; (a) göstergeler ve canlı haritalar görünümü, (b) hızlı erişim, aktiviteler ve sistem uyarı görünümü.

Filo yönetimi ekranının genel görünümü Şekil 54'te verilmiştir. Şekil 54a'da filonun güncel durumu hakkında bilgiler yer almaktadır. Sistemde güncellemeler dakika bazlı ve otomatik olarak gerçekleştirilmektedir. Şekil 54b'de ise filonun güncel durumunun devamı ve bakım takvimi yer almaktadır.




(a)




(b)

Şekil 54. Filo yönetimi ekranı; (a) filo güncel durumu görünümü, (b) filonun güncel durumu devamı ve bakım takvimi görünümü.

Rota planlama ve optimizasyon ekranının genel görünümü Şekil 55'te verilmiştir. Şekil 55a'da rotanın planlaması veya rotanın optimize edilmesi ile ilgili işlemlerin yapıldığı ekran bulunmaktadır. Ayrıca aktif rotalar canlı harita ve liste şeklinde gösterilmiştir. Şekil 55b'de rota planlamasının uzamsal hareketleri, rota noktaları ve optimizasyon ayarlarının bulunduğu ekran gösterilmiştir.




(a)




(b)

Şekil 55. Rota planlama ve optimizasyon ekranı; (a) rota planlama ve optimizasyon görünümü, (b) 3d uzamsal görüntüsü, rota noktaları ve optimizasyon ayarları görünümü.

Hava durumu ve çevre analizi ekranının genel görünümü Şekil 56'da verilmiştir. Şekil 56a'da bulunan konumdaki güncel hava durumu bilgileri, alanın hava durum haritası, 5 günlük tahmin ve rüzgar radarının yer aldığı ekran gösterilmiştir. Şekil 56b'de ise risk değerlendirmesi, güvenli iniş alanları ve çevresel etki analizleri bilgilerinin yer aldığı ekran gösterilmiştir.




(a)




(b)

Şekil 56. Hava durumu ve çevre analizi ekranı; (a) güncel hava durumu, alanın hava durumu haritası, 5 günlük tahminler ve rüzgar radarı görünümü, (b) risk değerlendirme, güvenli iniş alanları ve çevresel etki analizleri görünümü.


Kargo yönetimi ekranının genel görünümü Şekil 57’de verilmiştir. Şekil 57a’da canlı kargo takibi ve müşteri yönetimi ekranı bulunmaktadır. Şekil 57b’de teslimat zaman çizelgesi ve kalite kontrol bilgilerinin yer aldığı ekran verilmiştir. Şekil 57c’de ise teslimat takibi ve müşteri memnuniyeti analizi ile kargo listesi ekranı verilmiştir.



(a)




(b)



(c)

Şekil 57. Kargo yönetimi ekranı; (a) canlı kargo takibi ve müşteri yönetimi görünümü, (b) teslimat zaman çizelgesi ve kalite kontrol bilgileri görünümü, (c) teslimat takibi ve müşteri memnuniyeti analizi ile kargo listesi görünümü.

Analitik sistem ekranının genel görünümü Şekil 58’de verilmiştir. Bu ekran içerisinde genel bakış, operasyonel, finansal, kalite ve tahminleme gibi farklı analizlerin yapıldığı ekranlar bulunmaktadır.



Şekil 58. Analitik sistem ekranı.

Sonuç olarak, OHKA sistem takip ve simülasyon yazılımına ait arayüzler; ana kontrol panelinde güncel filo durumu, aktif rotalar, teslimatlar ve ortalama batarya bilgilerinin canlı haritalar ile bütünleşik biçimde izlenebilmesi, modüllere hızlı erişim sağlanması ve aktivite akışları ile sistem uyarılarının tek ekranda yönetilebilmesi sayesinde kullanıcı deneyimini güçlendirmekte ve operasyonel karar alma süreçlerini belirgin biçimde desteklemektedir. Filo yönetiminde güncellemeler ve bakım takvimi; rota planlama/optimizasyonda canlı harita, liste ve 3B görünümün ayarlarla birlikte sunulması; hava durumu analizlerinde risk ve güvenli iniş alanlarının gösterilmesi; kargo yönetiminde ise canlı takip, teslimat çizelgesi, kalite kontrol ve müşteri memnuniyetinin tek akışta toplanması, sistemin uçtan uca izlenebilirliğini güçlendirmektedir. Son aşamada analitik ekranın genel bakış, operasyonel, finansal, kalite ve tahminleme gibi farklı analiz katmanlarını bir araya getirmesi, yazılımın karar destek yönünü pekiştirmektedir. İlerleyen çalışmalarda, kullanıcı geri bildirimleri temelinde arayüz akışlarının sadeleştirilmesi, görselleştirme ve raporlama bileşenlerinin genişletilmesi ve rol tabanlı yetkilendirmeye uygun yeni modüllerin eklenmesi; yazılımın işlevselliğini, ölçeklenebilirliğini ve sürdürülebilirliğini daha da güçlendirecektir.

SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında, otonom hava kargo aracı (OHKA) teslimat sistemi; deneysel tasarım, rota optimizasyonu, performans ve kalite yönetimi, güvenilirlik ve risk analizi, derin öğrenme tabanlı modelleme, ekonomik değerlendirme ve sistem takip simülasyonu ile bütünleşik olarak incelenmiştir. Taguchi L54 deney tasarımıyla yedi kontrol faktörü (A: filo yönetimi, B: hava durumu, C: rüzgâr hızı, D: rota karmaşıklığı, E: kargo ağırlığı, F: uçuş mesafesi ve G: pil durumu) ve beş temel performans karakteristiği (teslimat süresi, operasyonel maliyet, görev başarı oranı, enerji tüketimi ve karbon ayak izi) birlikte değerlendirilmiş; ardından rota planlama, çoklu OHKA operasyonları, yapay zekâ destekli karar alma ve ekonomik–sosyal etki analizleri ile sistemin bütüncül performans profili ortaya konmuştur.

Araştırma sürecinde elde edilen 66 farklı veri seti ve 7 farklı performans değerlendirme başlığı üzerinden, OHKA sisteminin yalnızca teknik açıdan değil, aynı zamanda ekonomik sürdürülebilirlik, çevresel etki, güvenilirlik ve risk yönetimi boyutlarında da nasıl davrandığı kantitatif olarak değerlendirilmiştir. Aşağıda, bu kapsamlı analizlerden elde edilen temel sonuçlar ve bunlara dayalı öneriler özetlenmektedir.

Bu tez kapsamında ulaşılan başlıca sonuçlar şunlardır:

1. Asıl etki analizlerinde görüldüğü üzere, teslimat süresi tepkisinin en belirgin biçimde F faktörü boyunca değiştiğini; operasyonel maliyetin özellikle F ve E faktörleri boyunca anlamlı düzeyde ayrıştığını göstermektedir. Buna ek olarak görev başarı oranında D faktörünün baskın, A faktörünün ise ikincil düzeyde etkili olduğu görülmektedir. Enerji tüketimi ile karbon ayak izinde değişimin en belirgin biçimde E faktörü boyunca gerçekleştiği (enerjide bunu sırasıyla B ve C, karbon ayak izinde ise sırasıyla C ve B izlemektedir) ortaya konmuştur.
2. Sinyal/gürültü (S/N) analizleri ve robust parametre tasarımı, performans karakteristiklerine göre optimum koşulların farklılaştığını göstermiştir: Teslimat süresi ve operasyonel maliyet için $A_1B_1C_1D_1E_1F_1G_2$, görev başarı oranı için $A_1B_1C_1D_3E_2F_3G_1$, enerji tüketimi için $A_2B_1C_1D_1E_1F_2G_1$ ve karbon ayak izi için ise $A_1B_1C_1D_1E_1F_1G_3$ kombinasyonu önerilmektedir. Robustluk açısından; operasyonel maliyette F ve E faktörlerinin ana etkilerinin yanısıra D×F bileşik etkisinin yüksek katkı düzeyiyle belirleyici olduğu; görev başarı oranında D×G bileşik etkisinin baskınlaştığı; enerji tüketiminde E faktörünün ana etkisi ile D×E bileşik etkisinin

kritik rol oynadığı ve karbon ayak izinde E ve C faktörlerinin gözlenen güçlü değişimin D faktörüyle birleşmesinde daha da belirginleştiği anlaşılmaktadır.

3. Pareto frontu analizleri, teslimat süresi ile başarı oranı arasında 29,73 dakika ve %95,10 başarı; maliyet ile başarı oranı arasında 122,90 TL ve %95,08 başarı; enerji ile başarı oranı arasında 1527,25 Wh ve %95,08 başarı; karbon ayak izi ile başarı oranı arasında ise 2,31 kg karbon ayak izi ve %95,08 başarı değerlerinin, optimum ödünleşme noktaları olduğunu göstermiştir. Tek bir performans karakteristiğinin aşırı iyileştirilmesinin diğer göstergelerde kabul edilemez kayıplara yol açabileceğini ortaya koymuştur.
4. Üç boyutlu performans optimizasyon uzayında, maliyetin 114,59 TL, teslimat süresinin 29,54 dakika ve başarı oranının %100 olduğu Pareto-optimal çözüm, sistem tasarımının hem yüksek hizmet seviyesi hem de kabul edilebilir maliyet düzeyinde gerçekleştirilebileceğini ortaya koymuştur.
5. MCDM ve TOPSIS analizi, kriter ağırlıklandırmasında teslimat süresinin %25 ile en yüksek değere sahip kriter olduğunu, maliyet, başarı oranı ve karbon ayak izi kriterlerinin %20'şer, enerji kriterinin ise %15 ağırlığa sahip olduğunu ortaya koymuştur. En iyi senaryonun 0,966 TOPSIS skoru ile teslimat süresinde %97, maliyette %100, başarı oranında %88, enerjide %95 ve karbon ayak izinde %100 normalize performans değerlerine ulaştığı tespit edilmiştir.
6. Geleneksel karayolu filosu için gerçekleştirilen VRP analizi, 3 aracın tam kapasiteye yakın (1,22–1,29 ton) çalışırken bir aracın yaklaşık %50 atıl kapasiteyle (0,67 ton) operasyonu tamamladığı tespit edilmiştir. Ayrıca rotalar arasında 277,1 km ile 129,6 km gibi iki katı aşan mesafe farkları olduğu gözlenmiştir. Bu bulgu, karayolu filosunun talep ve coğrafi koşullara bağlı olarak kötü bir performans sergilediğini ve OHKA sisteminin bu dengesizlikleri azaltmada etkili bir çözüm alternatifi sunduğunu göstermektedir.
7. TSP analizi, tüm ilçeleri kapsayan en kısa karayolu rotasını 394,1 km olarak hesaplayarak, karayolu tabanlı operasyonların zorunlu minimum mesafe ve maliyet tabanını belirlemiştir. Bu değer, OHKA'ların kuş uçuşu mesafe avantajı sayesinde özellikle iç ve dağlık bölgelerde önemli maliyet ve teslimat süresi tasarrufu sağlayabileceğini kantitatif olarak desteklemektedir.
8. Çoklu drone rota problemi analizi, Drone 1'in 197,4 km ile en uzun menzile ve Drone 2'nin 46,9 kg ile en yüksek kapasite kullanımına sahip olduğunu; teslimat noktası dağılımının Drone 1 ve 3 için %30, Drone 2 ve 4 için ise %20 oranında olduğunu göstermiştir. Bu bulgu, coğrafi segmentasyon tabanlı çoklu OHKA

yapısının heterojen talep koşullarına uyum sağlayan esnek ve ölçeklenebilir bir mimari sunduğunu ortaya koymaktadır.

9. İlçe bazlı operasyonel analizler, ortalama teslimat süresinin 117,1 dakika olduğunu; Merkez ilçede 25,2 dakikaya kadar düşen bu sürenin Eynesil’de 215,7 dakikaya kadar yükseldiğini ortaya koymuştur. Talep yoğunluğunun gün içinde 10:00–12:00 ve 14:00–16:00 saatlerinde, hafta geneli itibarıyla ise belirli günlerde kümelenmesi, sistemin proaktif ve tahmine dayalı kapasite yönetimiyle desteklenmesi gerektiğini kanıtlamıştır.
10. Risk matrisi analizinde ani fırtına (RPN: 336), kar fırtınası (RPN: 288), yoğun sis (RPN: 280) ve dolu yağışı (RPN: 243) en yüksek risk öncelik numaralarına sahip faktörler olarak belirlenmiştir. Toplam 15 yüksek risk faktörünün 133.480 TL’lik maliyet oluşturduğu tespit edilmiştir. Bu bulgular, çevresel koşulların OHKA operasyonları üzerindeki belirleyici etkisini açıkça ortaya konmuştur.
11. Süreç yeterliliği analizlerinden görüldüğü üzere batarya sıcaklığında $Cpk=1,545$ ile süreç seviyesinin $\sigma_{ST}=4,635\sigma$ ve $\sigma_{LT}=6,135\sigma$ düzeyinde yüksek yeterlilikte olduğunu; paket titreşiminde $Cpk=1,422$ ile $\sigma_{ST}=4,266\sigma$ ve $\sigma_{LT}=5,766\sigma$ seviyelerine ulaşıldığını göstermektedir. Buna karşılık teslimat süresi için $Cpk=0,951$ olup süreç seviyesinin $\sigma_{ST}=2,853\sigma$ ve $\sigma_{LT}=4,353\sigma$ ile diğer metriklerle kıyasla daha düşük kaldığı; GPS doğruluğu ($Cpk=1,067$; $\sigma_{ST}=3,201\sigma$) ve iniş hassasiyeti ($Cpk=1,086$; $\sigma_{ST}=3,258\sigma$) gibi parametrelerin ise kabul edilebilir yeterlilik bandında seyrettiği görülmüştür. Bu nedenle, genel değerlendirmede iyileştirme önceliğinin özellikle teslimat süresinde varyansın azaltılması ve sürecin hedefe merkezlenmesi yönünde yapılandırılması gerektiği vurgulanmıştır.
12. OEE analizleri sonucunda, teorik kapasitenin kullanılabilirlik kayıpları nedeniyle %9,9, performans kayıpları nedeniyle %8,5 ve kalite kayıpları nedeniyle %1,4 oranında azalarak nihai OEE değerinin %80,2’ye düştüğü; teslimat aşamasının sistem darboğazı olduğu ve toplam kaybın %19,8 seviyesinde gerçekleştiği belirlenmiştir.
13. DPMO trendinin 60 günlük periyotta günlük 104,5 birim azalma gösterdiği, sigma trendinin 0,04 pozitif eğilim sergilediği ve OEE değerinin %1,6 oranında artış eğiliminde olduğu tespit edilmiştir. Teslimat hataları, müşteri şikâyetleri ve iletişim hatalarının Pareto analizinde toplam hataların %70’inden fazlasını oluşturmalarına rağmen, sürekli iyileştirme çalışmalarının süreç performansını anlamlı biçimde artırdığı ortaya çıkmıştır.

14. MTBF–MTTR ve kullanılabilirlik analizleri, dört OHKA için MTBF değerlerinin 40,4–47,5 gün, MTTR değerlerinin 3,7–4,2 saat aralığında olduğunu; tüm araçlarda kullanılabilirlik oranlarının %99,6–%99,7 seviyelerinde gerçekleştiğini göstermiştir. Weibull tabanlı hayatta kalma analizinde 50. günde %43 olan hayatta kalma olasılığı 150. günde %3 seviyelerine kadar gerilemiş, arıza oranının zamanla artan bir eğilim gösterdiği belirlenmiştir.
15. FTA–ETA analizleri, toplam teslimat başarısızlığı olasılığını %14,5; güvenli teslimat olasılığını ise %97,2 olarak tahmin etmiştir. Hava koşulları, düşük batarya ve GPS sinyal kaybı en kritik temel olaylar olarak öne çıkmıştır.
16. CNN tabanlı görüntü işleme modelinde eğitim doğruluğunun %95, doğrulama doğruluğunun %91,7'ye; ROC eğrisi altında kalan alanın (AUC) 0,952'ye ulaşması, güvenli/tehlikeli sınıflandırmasında %77,5 doğru sınıflandırma oranlarının yakalanması, modelin tehlike algılama ve görsel karar destek süreçlerinde etkin biçimde kullanılabileceğini göstermiştir.
17. Mesafe–enerji ilişkisi analizinde kilometre başına ortalama enerji tüketiminin 23,1 Wh/km olduğu; 100 km'de yaklaşık 2300 Wh enerji tüketildiği tespit edilmiştir. Telemetri verileri analizinde motor devrinin çoğunlukla 5000–6000 RPM aralığında ve batarya tüketiminin %20–%100 aralığında kararlı bir dağılım sergilemesi, sistemin normal çalışma bölgesinde öngörülebilir bir performans profiline sahip olduğunu ortaya koymuştur.
18. LSTM ve GRU tabanlı batarya seviyesi tahmin modellerinde, eğitim ve test kayıplarının yaklaşık 5 eğitim turu sonunda 2×10^{-2} seviyelerine gerilemesi ve gerçek zamanlı batarya seviyeleriyle tahmin eğrilerinin neredeyse örtüşmesi, uzun vadeli batarya yönetimi ve görev planlaması için güvenilir bir tahmin altyapısı sağlandığını göstermiştir.
19. Ekonomik analizler, 10 milyon TL'lik başlangıç yatırımıyla NŞD'nin 89,2 milyon TL'ye ulaştığını, iç verim oranının %133 seviyesinde olduğunu ve geri ödeme süresinin 0,9 yıl gibi çok kısa bir sürede gerçekleştiğini göstermiştir. Ayrıca, 5 yıllık TCO, OHKA filosu için 18,4 milyon TL olarak hesaplandığı ve geleneksel karayolu filosuna kıyasla 5 yıldan daha uzun sürede önemli maliyet avantajı sağlandığı belirlenmiştir. Bu sonuçlar, OHKA filolarının ekonomik açıdan sürdürülebilir ve rekabetçi bir yatırım olduğunu vurgulamaktadır.
20. SROI analizinde 4,0 milyon TL'lik yatırımla 6,5 milyon TL'lik sosyal fayda üretilmiş ve SROI değeri 1,62 olarak hesaplanmıştır. 100 milyon TL'lik geniş ölçekli bir yatırım senaryosunda 30 milyon TL doğrudan istihdam, 20 milyon TL

dolaylı istihdam, 25 milyon TL tedarik zinciri etkisi ve 15 milyon TL vergi gelirine katkı sağlanması, OHKA sisteminin ekonomik ve sosyal açıdan yüksek katma değer potansiyeline sahip olduğunu ortaya koymuştur.

21. Maliyet–etkinlik karşılaştırmasında OHKA’nın 15 TL maliyet indeksi ve 0,5 kg emisyon indeksi ile en verimli teslimat yöntemi olduğu; kamyonun ise 50 TL maliyet ve 12,0 kg emisyon indeksiyle en yüksek maliyet ve emisyonu sahip seçenek olarak konumlandığı görülmüştür. İlçe bazlı ekonomik etki haritasında ise özellikle merkezi ilçelerde yüksek ekonomik etki skorlarının elde edilmesi, OHKA sistemlerinin hem çevresel hem de ekonomik sürdürülebilirlik açısından güçlü bir alternatif sunduğunu göstermektedir.

Bu bulgular doğrultusunda geliştirilen temel öneriler aşağıdaki gibi özetlenebilir:

1. OEE değerinin %80,2’den dünya standardı olan %85’in üzerine çıkarılabilmesi için özellikle teslimat aşamasındaki darboğazların giderilmesine, süreç hızının artırılmasına ve plansız duruşların azaltılmasına odaklanan yalın ve Altı Sigma tabanlı iyileştirme projeleri önceliklendirilebilir.
2. Batarya sağlık göstergesinin (%59,2) iyileştirilmesi amacıyla, batarya ve itki sistemlerine yönelik donanım güncellemeleri ile LSTM/GRU tabanlı akıllı enerji yönetim algoritmalarının entegrasyonu sağlanabilir; kestirimci bakım modelleriyle MTBF ve MTTR değerleri yaşam döngüsü odaklı olarak optimize edilebilir.
3. Gelecek çalışmalarda, yazılımın kullanım kolaylığını ve operasyonel katkısını artırmak amacıyla arayüz akışları daha yalın bir yapıya kavuşturulabilir, gerçek zamanlı izleme ve veri görselleştirme yeteneklerinin güçlendirilebilir, ayrıca uyarı mekanizmaları ile raporlama modüllerinin karar destek sürecini destekleyecek şekilde bütünleşik ve ölçeklenebilir bir mimaride yeniden yapılandırılabilir.

KAYNAKLAR

- Ağralı, M., Soydemir, M. U., Gökçen, A., and Sahin, S., 2021. Deep reinforcement learning based controller design for model of the vertical take off and landing system. *Avrupa Bilim ve Teknoloji Dergisi*, (26), 358-363.
- Altché, F. and de La Fortelle, A., 2017. An LSTM network for highway trajectory prediction. 2017 IEEE 20th international conference on intelligent transportation systems (ITSC), 353-359. <https://ieeexplore.ieee.org/abstract/document/8317913/>
- Arshad, M., 2020. Artificial intelligence in business simulation analysis. *European Journal of Technology*, 4(1), 16-30.
- Bai, Y., Song, Z. and Cui, W., 2022. Studying the Coupling and Coordination of Regional Economic and University Development Levels Based on a Deep Learning Model. *Mathematical Problems in Engineering*, 2022, 1-7. <https://doi.org/10.1155/2022/1480173>
- Baryannis, G., Dani, S. and Antoniou, G., 2019a. Predicting supply chain risks using machine learning: The trade-off between performance and interpretability. *Future Generation Computer Systems*, 101, 993-1004.
- Baryannis, G., Validi, S., Dani, S. and Antoniou, G., 2019b. Supply chain risk management and artificial intelligence: State of the art and future research directions. *International Journal of Production Research*, 57(7), 2179-2202. <https://doi.org/10.1080/00207543.2018.1530476>
- Bayram, H., Doddapaneni, K., Stefas, N. and Isler, V., 2016. Active localization of VHF collared animals with aerial robots. 2016 IEEE International Conference on Automation Science and Engineering (CASE), 934-939. <https://ieeexplore.ieee.org/abstract/document/7743503/>
- Bayram, H., Stefas, N., Engin, K. S. and Isler, V., 2017. Tracking wildlife with multiple UAVs: System design, safety and field experiments. 2017 International symposium on multi-robot and multi-agent systems (MRS), 97-103. <https://ieeexplore.ieee.org/abstract/document/8250937/>
- Belhadi, A., Kamble, S., Fosso Wamba, S. and Queiroz, M. M., 2022. Building supply-chain resilience: An artificial intelligence-based technique and decision-making framework. *International Journal of Production Research*, 60(14), 4487-4507. <https://doi.org/10.1080/00207543.2021.1950935>
- Belhadi, A., Mani, V., Kamble, S. S., Khan, S. A. R. and Verma, S., 2024. Artificial intelligence-driven innovation for enhancing supply chain resilience and performance under the effect of supply chain dynamism: An empirical investigation. *Annals of Operations Research*, 333(2-3), 627-652. <https://doi.org/10.1007/s10479-021-03956-x>
- Ben-Daya, M., Hassini, E. and Bahroun, Z., 2019. Internet of things and supply chain management: A literature review. *International Journal of Production Research*, 57(15-16), 4719-4742. <https://doi.org/10.1080/00207543.2017.1402140>
- Bijjahalli, S., Sabatini, R. and Gardi, A., 2020. Advances in intelligent and autonomous navigation systems for small UAS. *Progress in Aerospace Sciences*, 115, 100617.
- Blöthner, S. and Larch, M., 2022. Economic determinants of regional trade agreements revisited using machine learning. *Empirical Economics*, 63(4), 1771-1807. <https://doi.org/10.1007/s00181-022-02203-x>
- Bojarski, M., 2016. End to end learning for self-driving cars. arXiv preprint arXiv:1604.07316.

- Cadden, T., Dennehy, D., Mantymaki, M. and Treacy, R., 2022. Understanding the influential and mediating role of cultural enablers of AI integration to supply chain. *International Journal of Production Research*, 60(14), 4592-4620. <https://doi.org/10.1080/00207543.2021.1946614>
- Cavalcante, I. M., Frazzon, E. M., Forcellini, F. A. and Ivanov, D., 2019. A supervised machine learning approach to data-driven simulation of resilient supplier selection in digital manufacturing. *International Journal of Information Management*, 49, 86-97.
- Chatterjee, P., Yazdani, M., Fernández-Navarro, F. and Pérez-Rodríguez, J., 2023. *Machine Learning Algorithms and Applications in Engineering*. CRC Press. https://books.google.com/books?hl=tr&lr=&id=pcynEAAAQBAJ&oi=fnd&pg=PP1&dq=Machine+Learning+Algorithms+and+Applications+in+Engineering&ots=YmFhl_0W3x&sig=2xvxfLarFJTai0xoQx5mWmix05w
- Chen, X., Ma, H., Wan, J., Li, B. and Xia, T., 2017. Multi-view 3d object detection network for autonomous driving. *Proceedings of the IEEE conference on Computer Vision and Pattern Recognition*, 1907-1915. http://openaccess.thecvf.com/content_cvpr_2017/html/Chen_Multi-View_3D_Object_CVPR_2017_paper.html
- Chen, X., Ulmer, M. W. and Thomas, B. W., 2022. Deep Q-learning for same-day delivery with vehicles and drones. *European Journal of Operational Research*, 298(3), 939-952.
- Chen, X., Zheng, C. and Liu, M., 2024. Research on Inventory Management Optimization Strategy in Supply Chain Based on Deep Reinforcement Learning. 2024 5th International Conference on Computer Vision, Image and Deep Learning (CVIDL), 786-791. 2024 5th International Conference on Computer Vision, Image and Deep Learning (CVIDL). <https://doi.org/10.1109/CVIDL62147.2024.10603641>
- Cliff, O. M., Fitch, R., Sukkarieh, S., Saunders, D. L. and Heinsohn, R., 2015. Online localization of radio-tagged wildlife with an autonomous aerial robot system. *Robotics: Science and Systems*. <https://opus.lib.uts.edu.au/handle/10453/121195>
- Cliff, O. M., Saunders, D. L. and Fitch, R., 2018. Robotic ecology: Tracking small dynamic animals with an autonomous aerial vehicle. *Science Robotics*, 3(23), eaat8409. <https://doi.org/10.1126/scirobotics.aat8409>
- Dash, R., McMurtrey, M., Rebman, C. and Kar, U. K., 2019. Application of artificial intelligence in automation of supply chain management. *Journal of Strategic Innovation and Sustainability*, 14(3). <https://articlearchives.co/index.php/JSIS/article/view/4867>
- Deng, C. and Liu, Y., 2021. A Deep Learning-Based Inventory Management and Demand Prediction Optimization Method for Anomaly Detection. *Wireless Communications and Mobile Computing*, 2021(1), 9969357. <https://doi.org/10.1155/2021/9969357>
- Dora, M., Kumar, A., Mangla, S. K., Pant, A. and Kamal, M. M., 2022. Critical success factors influencing artificial intelligence adoption in food supply chains. *International Journal of Production Research*, 60(14), 4621-4640. <https://doi.org/10.1080/00207543.2021.1959665>
- Dosovitskiy, A., Ros, G., Codevilla, F., Lopez, A. and Koltun, V., 2017. CARLA: An open urban driving simulator. *Conference on robot learning*, 1-16. <https://proceedings.mlr.press/v78/dosovitskiy17a.html>
- Dubey, R., Gunasekaran, A., Childe, S. J., Papadopoulos, T., Luo, Z. and Roubaud, D., 2020. Upstream supply chain visibility and complexity effect on focal company's sustainable performance: Indian manufacturers' perspective. *Annals of Operations Research*, 290(1-2), 343-367. <https://doi.org/10.1007/s10479-017-2544-x>

- ElSayed, M. and Mohamed, M., 2024. Robust digital-twin airspace discretization and trajectory optimization for autonomous unmanned aerial vehicles. *Scientific Reports*, 14, 12506. <https://doi.org/10.1038/s41598-024-62421-4>
- Farahani, A., Genga, L., Schrottenboer, A. H. and Dijkman, R., 2024. Capacity planning in logistics corridors: Deep reinforcement learning for the dynamic stochastic temporal bin packing problem. *Transportation Research Part E: Logistics and Transportation Review*, 191, 103742.
- Fei, W. A. N. G., Xiaoping, Z. H. U., Zhou, Z. and Yang, T. A. N. G., 2024. Deep-reinforcement-learning-based UAV autonomous navigation and collision avoidance in unknown environments. *Chinese Journal of Aeronautics*, 37(3), 237-257.
- Gajana, K. D., 2024. Medical Supplies Delivery Autonomous Drone with Security. *International Journal for Research in Applied Science and Engineering Technology*, 12(4), 6022-6030. <https://doi.org/10.22214/ijraset.2024.61335>
- Ganesh, A. D. and Kalpana, P., 2022. Future of artificial intelligence and its influence on supply chain risk management—A systematic review. *Computers & Industrial Engineering*, 169, 108206.
- Gunasekaran, A. and Ngai, E. W., 2014. 21st Century Logistics and Supply Chain Management. *Expert Systems with Applications*, 41(1). <https://pascal-francis.inist.fr/vibad/index.php?action=getRecordDetail&idt=28264924>
- Han, X., Li, Y., Li, J., Zhang, B. and Ma, Z., 2023. Deep Reinforcement Learning Applied in Distribution Network Control and Optimization. 2023 IEEE 7th Conference on Energy Internet and Energy System Integration (EI2), 4838-4843. 2023 IEEE 7th Conference on Energy Internet and Energy System Integration (EI2). <https://doi.org/10.1109/EI259745.2023.10512736>
- Harrington, A., 2015. Who controls the drones? *Engineering & Technology*, 10(2), 80-83. <https://doi.org/10.1049/et.2015.0211>
- Helo, P. and Hao, Y., 2022. Artificial intelligence in operations management and supply chain management: An exploratory case study. *Production Planning & Control*, 33(16), 1573-1590. <https://doi.org/10.1080/09537287.2021.1882690>
- Heruatmadja, C. H., Prabowo, H., Warnars, H. L. H. S. and Heryadi, Y., 2024. Suitable Deep Learning Based for High Accuracy Object Detection in Inventory Management: Systematic Literature Review. 2024 7th International Conference on Informatics and Computational Sciences (ICICoS), 406-412. 2024 7th International Conference on Informatics and Computational Sciences (ICICoS). <https://doi.org/10.1109/ICICoS62600.2024.10636831>
- Hu, C. and Paunic, V., 2020. Building Forecasting Solutions Using Open-Source and Azure Machine Learning. *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 3497-3498. KDD '20: The 26th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. <https://doi.org/10.1145/3394486.3406699>
- Hu, W.-C., Wu, H.-T., Cho, H.-H. and Tseng, F.-H., 2020. Optimal route planning system for logistics vehicles based on artificial intelligence. *Journal of Internet Technology*, 21(3), 757-764.
- Huang, L., Liu, X., Wang, X., Li, J. and Tan, B., 2023. Deep Learning Methods in Image Matting: A Survey. *Applied Sciences*, 13(11), Article 11. <https://doi.org/10.3390/app13116512>

- Jedermann, R. and Lang, W., 2008. The Benefits of Embedded Intelligence – Tasks and Applications for Ubiquitous Computing in Logistics. İçinde C. Floerkemeier, M. Langheinrich, E. Fleisch, F. Mattern, & S. E. Sarma (Ed.), *The Internet of Things* (C. 4952, ss. 105-122). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-78731-0_7
- Jiang, L., 2022. Optimization Algorithm of Logistics Distribution Path Based on Deep Learning. 2022 IEEE 4th International Conference on Civil Aviation Safety and Information Technology (ICCASIT), 154-158. 2022 IEEE 4th International Conference on Civil Aviation Safety and Information Technology (ICCASIT). <https://doi.org/10.1109/ICCASIT55263.2022.9987167>
- Joerss, M., 2016. Parcel delivery: The future of last mile. 32 p, USA. Available online: https://www.google.com.hk/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&cad=rja&uact=8&ved=2ahUKEwjJ8YPRsfH8AhXMAogKHVjkARYQFnoECA4QAQ&url=https%3A%2F%2Fbdkep.de%2Ffiles%2Fbdkep-dateien%2Fpdf%2F2016_the_future_of_last_mile.pdf&usg=AOvVaw0h3LUW_7iHh bhJYggjESN7
- Ju, C. and Son, H. I., 2022. Investigation of an autonomous tracking system for localization of radio-tagged flying insects. *IEEE Access*, 10, 4048-4062.
- Kannagi, V., Rajkumar, M., Chandra, I., Sangeethalakshmi, K. and Mohanavel, V., 2022. Logical Mining Assisted Heart Disease Prediction Scheme in Association with Deep Learning Principles. 2022 International Conference on Electronics and Renewable Systems (ICEARS), 1409-1415. <https://doi.org/10.1109/ICEARS53579.2022.9751820>
- Kaspi, M., Raviv, T. and Ulmer, M. W., 2022. Preface: Special issue on the future of city logistics and urban mobility. *Networks*, 79(3), 251-252. <https://doi.org/10.1002/net.22093>
- Kaur, K., 2021. Role of artificial intelligence in education: Peninsula College Central Malaysia. *International Journal of Academic Research in Progressive Education and Development*, 10(2). <https://ijarped.com/index.php/journal/article/view/2204>
- Kellermann, R., Biehle, T. and Fischer, L., 2020. Drones for parcel and passenger transportation: A literature review. *Transportation Research Interdisciplinary Perspectives*, 4, 100088.
- Kendall, A. and Cipolla, R., 2016. Modelling uncertainty in deep learning for camera relocalization. 2016 IEEE international conference on Robotics and Automation (ICRA), 4762-4769. <https://ieeexplore.ieee.org/abstract/document/7487679/>
- Körner, F., Speck, R., Göktogan, A. H. and Sukkarieh, S., 2010. Autonomous airborne wildlife tracking using radio signal strength. 2010 IEEE/RSJ International Conference on Intelligent Robots and Systems, Taiwan, 107-112. <https://ieeexplore.ieee.org/abstract/document/5654385/>
- Lang, S., Schenk, M. and Reggelen, T., 2019. Towards learning-and knowledge-based methods of artificial intelligence for short-term operative planning tasks in production and logistics: Research idea and framework. *IFAC-PapersOnLine*, 52(13), 2716-2721.
- Lau, H. Y. and Zhao, Y., 2004. Multi-objective genetic algorithms for scheduling material handling equipment at automated air cargo terminals. *IEEE Conference on Cybernetics and Intelligent Systems*, 2004., 2, 718-723. <https://ieeexplore.ieee.org/abstract/document/1460676/>

- Li, B., Yang, Y., Zhao, Z., Ni, X. and Zhang, D., 2024. A Novel Ensemble Learning Approach for Intelligent Logistics Demand Management. *Journal of Internet Technology*, 25(4), 507-515. <https://doi.org/10.70003/160792642024072504002>
- Li, N., Ma, L., Yu, G., Xue, B., Zhang, M. and Jin, Y., 2022. Survey on Evolutionary Deep Learning: Principles, Algorithms, Applications and Open Issues (No. arXiv:2208.10658). *arXiv*. <https://doi.org/10.48550/arXiv.2208.10658>
- Lillicrap, T. P., 2015. Continuous control with deep reinforcement learning. *arXiv preprint arXiv:1509.02971*.
- Limbouurg, S., Schyns, M. and Laporte, G., 2012. Automatic aircraft cargo load planning. *Journal of the Operational Research Society*, 63(9), 1271-1283. <https://doi.org/10.1057/jors.2011.134>
- Liu, S., Jiang, H., Chen, S., Ye, J., He, R. and Sun, Z., 2020. Integrating Dijkstra's algorithm into deep inverse reinforcement learning for food delivery route planning. *Transportation Research Part E: Logistics and Transportation Review*, 142, 102070.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y. and Berg, A. C., 2016. SSD: Single Shot MultiBox Detector (C. 9905, ss. 21-37). https://doi.org/10.1007/978-3-319-46448-0_2
- Liu, X., 2022. A New Machine Learning Algorithm for Regional Low-Carbon Economic Development Analysis Based on Data Mining. *Journal of Function Spaces*, 2022, 1-8. <https://doi.org/10.1155/2022/5692666>
- Long, J., Shelhamer, E. and Darrell, T., 2015. Fully convolutional networks for semantic segmentation. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 3431-3440. http://openaccess.thecvf.com/content_cvpr_2015/html/Long_Fully_Convolutional_Networks_2015_CVPR_paper.html
- Mamede, F. P., Da Silva, R. F., De Brito Junior, I., Yoshizaki, H. T. Y., Hino, C. M. and Cugnasca, C. E., 2023. Deep Learning and Statistical Models for Forecasting Transportation Demand: A Case Study of Multiple Distribution Centers. *Logistics*, 7(4), 86. <https://doi.org/10.3390/logistics7040086>
- Menichino, A., Di Vito, V., Ariante, G. and Del Core, G., 2023. AAM/goods delivery: Main enablers for BVLOS routine operations within environment at low and medium risk. *Aircraft Engineering and Aerospace Technology*, 95(10), 1578-1587. <https://doi.org/10.1108/AEAT-01-2023-0003>
- Mercy, T. and Pipeleers, G., 2017. Motion planning for autonomous vehicles in a vast environment. *Benelux Meeting on Systems and Control*, Date: 2017/03/28-2017/03/30, Location: Spa.
- Min, H., 2010. Artificial intelligence in supply chain management: Theory and applications. *International Journal of Logistics Research and Applications*, 13(1), 13-39. <https://doi.org/10.1080/13675560902736537>
- Min, H., Yu, W. and Vincent, B., 2008. Collaborative planning, forecasting and replenishment: Demand planning in supply chain management. *International Journal of Information Technology and Management*, 7(1), 4. <https://doi.org/10.1504/IJITM.2008.015886>
- Mohseni, F. and Morsali, M., 2017. Decoupled Sampling Based Planning Method for Multiple Autonomous Vehicles (No. arXiv:1702.03429). *arXiv*. <http://arxiv.org/abs/1702.03429>

- Murray, C. C. and Chu, A. G., 2015. The flying sidekick traveling salesman problem: Optimization of drone-assisted parcel delivery. *Transportation Research Part C: Emerging Technologies*, 54, 86-109.
- Najafabadi, M. M., Villanustre, F., Khoshgoftaar, T. M., Seliya, N., Wald, R. and Muharemagic, E., 2015. Deep learning applications and challenges in big data analytics. *Journal of Big Data*, 2(1), 1. <https://doi.org/10.1186/s40537-014-0007-7>
- Ogunsanya, M., Isichei, J. and Desai, S., 2023. Grid search hyperparameter tuning in additive manufacturing processes. *Manufacturing Letters*, 35, 1031-1042.
- Pillai, A. S. and Tedesco, R., 2023. Machine Learning and Deep Learning in Natural Language Processing. <https://doi.org/10.1201/9781003296126>
- Pournader, M., Ghaderi, H., Hassanzadegan, A. and Fahimnia, B., 2021. Artificial intelligence applications in supply chain management. *International Journal of Production Economics*, 241, 108250.
- Qi, C. R., Su, H., Mo, K. and Guibas, L. J., 2017a. Pointnet: Deep learning on point sets for 3d classification and segmentation. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 652-660. http://openaccess.thecvf.com/content_cvpr_2017/html/Qi_PointNet_Deep_Learning_CVPR_2017_paper.html
- Qi, Y., Yang, G., Liu, L., Fan, J., Orlandi, A., Kong, H., Yu, W. and Yang, Z., 2017b. 5G Over-the-Air Measurement Challenges: Overview. *IEEE Transactions on Electromagnetic Compatibility*, 59(6), 1661-1670. *IEEE Transactions on Electromagnetic Compatibility*. <https://doi.org/10.1109/TEM.2017.2707471>
- Raja Santhi, A. and Muthuswamy, P., 2022. Pandemic, war, natural calamities, and sustainability: Industry 4.0 technologies to overcome traditional and contemporary supply chain challenges. *Logistics*, 6(4), 81.
- Ranjan, S. and Senthilarasu, S., 2020. *Applied Deep Learning and Computer Vision for Self-Driving Cars: Build autonomous vehicles using deep neural networks and behavior-cloning techniques*. Packt Publishing Ltd. [https://books.google.com/books?hl=tr&lr=&id=nIX4DwAAQBAJ&oi=fnd&pg=PP1&dq=Ranjan,+S.,+%26+Senthilarasu,+S.+\(2020\).+Applied+Deep+Learning+and+Computer+Vision+for+Self-Driving+Cars.+Packt+Publishing.&ots=DGVqsWhceD&sig=iaDTI3-I4zzM8-f2819K8zn5Xyl](https://books.google.com/books?hl=tr&lr=&id=nIX4DwAAQBAJ&oi=fnd&pg=PP1&dq=Ranjan,+S.,+%26+Senthilarasu,+S.+(2020).+Applied+Deep+Learning+and+Computer+Vision+for+Self-Driving+Cars.+Packt+Publishing.&ots=DGVqsWhceD&sig=iaDTI3-I4zzM8-f2819K8zn5Xyl)
- Redmon, J., 2016. You only look once: Unified, real-time object detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*.
- Riahi, Y., Saikouk, T., Gunasekaran, A. and Badraoui, I., 2021. Artificial intelligence applications in supply chain: A descriptive bibliometric analysis and future research directions. *Expert Systems with Applications*, 173, 114702.
- Rodríguez-Espíndola, O., Chowdhury, S., Beltagui, A. and Albores, P., 2020. The potential of emergent disruptive technologies for humanitarian supply chains: The integration of blockchain, Artificial Intelligence and 3D printing. *International Journal of Production Research*, 58(15), 4610-4630. <https://doi.org/10.1080/00207543.2020.1761565>
- Ronneberger, O., Fischer, P. and Brox, T., 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: N. Navab, J. Hornegger, W. M. Wells, & A. F. Frangi (Ed.), *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015* (C. 9351, ss. 234-241). Springer International Publishing. https://doi.org/10.1007/978-3-319-24574-4_28

- Salip, D., Mavlonazarov, K. and Razumowsky, A., 2023. Optimization of Energy Consumption by Autonomous Electric Trucks during Cargo Transportation Based on the Artificial Bee Colony Algorithm. 2023 International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM), 520-525. <https://ieeexplore.ieee.org/abstract/document/10139183/>
- Samek, W., 2017. Explainable artificial intelligence: Understanding, visualizing and interpreting deep learning models. arXiv preprint arXiv:1708.08296.
- Sánchez-Soriano, J., Rojo-Gala, M. Á., Pérez-Pérez, G., Rosende, S. B. And Gordo-Herrera, N., 2024. Optimized Autonomous Drone Navigation Using Double Deep Q-Learning for Enhanced Real-Time 3D Image Capture. *Drones*, 8(12), 725.
- Sangeetha, D. M., Priya, D. R. M., Elias, J., Mamgain, D. P., Wassan, S. and GULATI, D. K., 2021. Techniques using artificial intelligence to solve stock market forecast, sales estimating and market division issues. *The journal of contemporary issues in business and government*, 27(3), 209-215
- Schouwenaars, T., 2006. Safe trajectory planning of autonomous vehicles [PhD Thesis, Massachusetts Institute of Technology]. <https://dspace.mit.edu/handle/1721.1/35298>
- Sharifmousavi, M., Kayvanfar, V. and Baldacci, R., 2024. Distributed Artificial Intelligence Application in Agri-food Supply Chains 4.0. *Procedia Computer Science*, 232, 211-220.
- Sharma, R., Shishodia, A., Gunasekaran, A., Min, H. and Munim, Z. H., 2022. The role of artificial intelligence in supply chain management: Mapping the territory. *International Journal of Production Research*, 60(24), 7527-7550. <https://doi.org/10.1080/00207543.2022.2029611>
- Sharma, V., Ali, O.S. and Kantak, G., 2024. Supply Chain Intelligence: Deep Learning for Demand Forecasting and Inventory Management. *International Journal of Advanced Research in Science, Communication and Technology*.
- Sieber, C., Vieira da Silva, L. M., Grünhagen, K. and Fay, A., 2024. Rule-Based Verification of Autonomous Unmanned Aerial Vehicles. *Drones*, 8(1), Article 1. <https://doi.org/10.3390/drones8010026>
- Sigari, C. and Biberthaler, P., 2021. Medical drones: Disruptive technology makes the future happen. *Der Unfallchirurg*, 124(12), 974-976. <https://doi.org/10.1007/s00113-021-01095-3>
- Singh, G., Chadha, R., Bawa, G., Chauhan, H. and Prakash, V., 2023. Comparative Analysis of Tracking Algorithms for Drone Monitoring Applications. 2023 4th International Conference on Computation, Automation and Knowledge Management (ICCAKM), 01-06. <https://doi.org/10.1109/ICCAKM58659.2023.10449628>
- Soltani, Z. K., 2021. The applications of artificial intelligence in logistics and supply chain. *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*, 12(13), 4488-4499.
- Sonaria, E. and Jenie, Y. I., 2024. Design of Alerting System for Beyond Visual Line of Sight Operational Cargo Delivery UAV. *WARTA ARDHIA*, 49(1), 48-59.
- Song, A., Yang, X., Ni, L., Liu, C., Yao, Y. and Pan, L., 2022. Optimization Analysis of the Emergency Logistics Identification Method Based on the Deep Learning Model under the Background of Big Data. *Wireless Communications and Mobile Computing*, 2022, 1-8. <https://doi.org/10.1155/2022/2463035>
- Soori, M., Arezoo, B. and Dastres, R., 2023. Artificial intelligence, machine learning and deep learning in advanced robotics, a review. *Cognitive Robotics*, 3, 54-70.

- Spandonidis, C., Sedikos, E., Giannopoulos, F., Petsa, A., Theodoropoulos, P., Chatzis, K. and Galiatsatos, N., 2022. A novel intelligent iot system for improving the safety and planning of air cargo operations. *Signals*, 3(1), 95-112.
- Suanpang, P. and Jamjuntr, P., 2024. Optimizing Last-Mile Delivery By Deep Q-Learning Approach For Autonomous Drone Routing In Smart Logistics. *Operational Research in Engineering Sciences: Theory and Applications*, 7(2).
- Tang, J., Li, X., Dai, J. and Bo, N., 2020. A case-based online trajectory planning method of autonomous unmanned combat aerial vehicles with weapon release constraints. *Def. Sci. J.*, 70(4), 374-382.
- Tao, W., Daichuan, Y., Weifeng, L., Chenglin, W. and Baigen, C., 2021. A Novel Integrated Path Planning Algorithm for Warehouse AGVs. *Chinese Journal of Electronics*, 30(2), 331-338. <https://doi.org/10.1049/cje.2021.02.002>
- Toorajipour, R., Sohrabpour, V., Nazarpour, A., Oghazi, P. and Fischl, M., 2021. Artificial intelligence in supply chain management: A systematic literature review. *Journal of Business Research*, 122, 502-517.
- Van Der Heijden, M., Ebben, M., Gademann, N. and Van Harten, A., 2002. Scheduling vehicles in automated transportation systems. *OR Spectrum*, 24(1), 31-58. <https://doi.org/10.1007/s291-002-8199-x>
- Van Nguyen, H., Chessser, M., Koh, L. P., Rezatofighi, S. H. and Ranasinghe, D. C., 2017. Trackerbots: Autonomous uav for real-time localization and tracking of multiple radio-tagged animals. *arXiv preprint arXiv:1712.01491*, 33. <https://static.aminer.cn/storage/pdf/arxiv/17/1712/1712.01491.pdf>
- Van Nguyen, H., Chessser, M., Chen, F., Rezatofighi, S. H. and Ranasinghe, D. C., 2018a. Autonomous UAV sensor system for searching and locating VHF radio-tagged wildlife. *Proceedings of the 16th ACM Conference on Embedded Networked Sensor Systems*, 333-334. <https://doi.org/10.1145/3274783.3275169>
- Van Nguyen, H., Rezatofighi, S. H., Taggart, D., Ostendorf, B. and Ranasinghe, D. C., 2018b. Trackerbots: Software in the loop study of quad-copter robots for locating radio-tags in a 3D space. *Australasian Conference on Robotics and Automation 2018*, 304-313. <https://research.monash.edu/en/publications/trackerbots-software-in-the-loop-study-of-quad-copter-robots-for->
- Van Nguyen, H., Chen, F., Chessser, J., Rezatofighi, H. and Ranasinghe, D., 2020. LAVAPilot: Lightweight UAV trajectory planner with situational awareness for embedded autonomy to track and locate radio-tags. *2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 2488-2495. <https://ieeexplore.ieee.org/abstract/document/9341615/>
- Vander Hook, J., Tokekar, P. and Isler, V., 2014. Cautious Greedy Strategy for Bearing-only Active Localization: Analysis and Field Experiments. *Journal of Field Robotics*, 31(2), 296-318. <https://doi.org/10.1002/rob.21499>
- Verbakel, J., 2024. A Proximal Policy Optimization Algorithm for Solving Logistical Optimization Problems Master Thesis Business Analytics and Operations Research.
- Wahedi, H. J., Heltoft, M., Christophersen, G. J., Severinsen, T., Saha, S. and Nielsen, I. E., 2023. Forecasting and Inventory Planning: An Empirical Investigation of Classical and Machine Learning Approaches for Svanehøj's Future Software Consolidation. *Applied Sciences*, 13(15), 8581. <https://doi.org/10.3390/app13158581>
- Waikar, V., Sawant, S. and Joshi, A., 2023. A Review Paper on Route Optimization Using Deep Learning. *2023 6th International Conference on Contemporary Computing and*

- Informatics (IC3I), 2387-2391. 2023 6th International Conference on Contemporary Computing and Informatics (IC3I). <https://doi.org/10.1109/IC3I59117.2023.10397919>
- Wang, Y., Skeete, J.-P. and Owusu, G., 2022. Understanding the implications of artificial intelligence on field service operations: A case study of BT. *Production Planning & Control*, 33(16), 1591-1607. <https://doi.org/10.1080/09537287.2021.1882694>
- Wang, W., Zhang, G., Da, Q., Lu, D., Zhao, Y., Li, S. and Lang, D., 2023. Multiple Unmanned Aerial Vehicle Autonomous Path Planning Algorithm Based on Whale-Inspired Deep Q-Network. *Drones*, 7(9), 572.
- Wang, L. and Liu, G., 2024. Research on multi-robot collaborative operation in logistics and warehousing using A3C optimized YOLOv5-PPO model. *Frontiers in Neurorobotics*, 17, 1329589.
- Wu, Y., Cheng, M., Huang, S., Pei, Z., Zuo, Y., Liu, J., Yang, K., Zhu, Q., Zhang, J., Hong, H., Zhang, D., Huang, K., Cheng, L. and Shao, W., 2022. Recent Advances of Deep Learning for Computational Histopathology: Principles and Applications. *Cancers*, 14(5), 1199. <https://doi.org/10.3390/cancers14051199>
- Yang, X. and Guan, W., 2023. Research on logistics distribution route optimization based on deep learning model and block chain technology. *3c Empresa: Investigación y Pensamiento Crítico*, 12(1), 68-85.
- You, Y., 2022. Data Mining of Regional Economic Analysis Based on Mobile Sensor Network Technology. *Journal of Sensors*, 1-13. <https://doi.org/10.1155/2022/3415055>
- Yu, F., Chen, M., Xia, X., Zhu, D., Peng, Q. and Deng, K., 2024. Logistics Distribution Route Optimization With Time Windows Based on Multi-Agent Deep Reinforcement Learning. *International Journal of Information Technologies and Systems Approach (IJITSA)*, 17(1), 1-23. <https://doi.org/10.4018/IJITSA.342084>
- Zhou, G., Min, H. and Gen, M., 2003. A genetic algorithm approach to the bi-criteria allocation of customers to warehouses. *International Journal of Production Economics*, 86(1), 35-45.
- Zhu, D., 2020. The application of artificial intelligence-based iot technology in regional economic statistics. *Journal of Physics: Conference Series*, 1648(2), 022042. <https://iopscience.iop.org/article/10.1088/1742-6596/1648/2/022042/meta>
- Zhu, Z., Das, G. and Hanheide, M., 2023. Autonomous Topological Optimisation for Multi-robot Systems in Logistics. *Proceedings of the 38th ACM/SIGAPP Symposium on Applied Computing*, 791-799. <https://doi.org/10.1145/3555776.3577666>

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı:	Muhammed Sefa GÖR
Doğum tarihi:	
Doğum Yeri:	
Uyruğu:	
Adres:	
Tel:	
E-mail:	
Eğitim	
Lise:	Erzurum Anadolu Lisesi
Lisans:	Atatürk Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü
Yüksek lisans:	Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı (2016)
Doktora:	Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı
Yabancı Dil Bilgisi	
İngilizce:	İyi
Almanca:	İyi
Fransızca:	Başlangıç
Üye Olunan Mesleki Kuruluşlar	
Tezden Üretilmiş Yayınlar	
1. Gör, M. S., & Çelik, C. (2025). Logistics Planning of Autonomous Air Cargo Vehicles with Deep Learning Methods: A Literature Review. <i>Applied Sciences</i> , 15(19), 10709.	