



**TERMİNAL HAVA SAHASINDA
METEOROLOJİK OLAYLARDAN
KAYNAKLANAN GECİKMELERİN YAPAY
ZEKÂ KULLANILARAK TAHMİNİ**

Yüksek Lisans Tezi

Mustafa Servet ÖZÇINAR

Eskişehir 2025

**TERMİNAL HAVA SAHASINDA METEOROLOJİK OLAYLARDAN
KAYNAKLANAN GECİKMELERİN YAPAY ZEKÂ KULLANILARAK
TAHMİNİ**

Mustafa Servet ÖZÇINAR

YÜKSEK LİSANS TEZİ

Hava Trafik Kontrol Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Fulya AYBEK ÇETEK

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

Ağustos 2025

JÜRİ VE ENSTİTÜ ONAYI

Mustafa Servet ÖZÇINAR'ın TERMİNAL HAVA SAHASINDA METEOROLOJİK OLAYLARDAN KAYNAKLANAN GECİKMELERİN YAPAY ZEKÂ KULLANILARAK TAHMİNİ başlıklı çalışması 08/08/2025 tarihinde aşağıdaki jüri tarafından değerlendirilerek “Eskişehir Teknik Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği”nin ilgili maddeleri uyarınca, Hava Trafik Kontrol Anabilim dalında YÜKSEK LİSANS Tezi olarak kabul edilmiştir.

Jüri Üyeleri

Unvan Adı Soyadı

İmza

Üye

: Dr. Öğr. Üyesi Fulya AYBEK ÇETEK

Üye

: Doç. Dr. Ramazan Kürşat ÇEÇEN

Üye

: Dr. Öğr. Üyesi Emre AYDOĞAN

Prof. Dr. Harun BÖCÜK

Lisansüstü Eğitim Enstitüsü Müdürü

08/08/2025

DANIřMAN ONAYI

Daniřmanlıęını yrttęm YKSEK LİSANS ęrencisi Mustafa Servet ZINAR, TERMİNAL HAVA SAHASINDA METEOROLOJİK OLAYLARDAN KAYNAKLANAN GECİKMELERİN YAPAY ZEKÂ KULLANILARAK TAHMİNİ bařlıklı tez alıřmasını tamamlamıřtır. Hazırlamıř olduęu tez tarafımca incelenmiř ve ęrencinin tez savunma sınavına alınması bilimsel ve etik aıdan uygun grlmřtr.

Tez Daniřmanı

Dr. ęr. yesi Fulya AYBEK ETEK

ÖZET

TERMİNAL HAVA SAHASINDA METEOROLOJİK OLAYLARDAN KAYNAKLANAN GECİKMELERİN YAPAY ZEKÂ KULLANILARAK TAHMİNİ

Mustafa Servet ÖZÇINAR

Hava Trafik Kontrol Anabilim Dalı

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Ağustos 2025

Danışman: Dr. Öğr. Üyesi Fulya AYBEK ÇETEK

Bu tez, terminal hava sahasında meteorolojik olayların neden olduğu uçuş gecikmelerinin yapay zekâ ile tahmin edilmesini incelemektedir. İstanbul Havalimanı'ndan elde edilen uçuş ve meteorolojik veriler kullanılarak, regresyon ve sınıflandırma temelli makine öğrenmesi modelleri geliştirilmiştir. Çalışma, veri dengesizliği ve nadir olayların temsili gibi zorlukları ele almış; ADASYN ve CTGAN gibi veri artırma teknikleriyle bu sorunlara çözümler önerilmiştir. LightGBM ve H2O AutoML gibi ileri yöntemler, gecikme sürelerini ve kategorilerini yüksek doğrulukla tahmin etmede başarılı bulunmuştur. SHAP analizleri, düşük görüş mesafesi ve alçak bulutlar gibi faktörlerin gecikmeler üzerindeki belirleyici etkisini ortaya koyarak, modelin başarısının operasyonel gerçekliklerle örtüşen örüntüleri öğrenme kabiliyetinden kaynaklandığını doğrulamıştır. Bu çalışma, karmaşık havacılık operasyonlarında meteorolojik gecikmeleri öngörmek için yorumlanabilir ve güçlü bir metodolojik çerçeve sunmaktadır.

Anahtar Sözcükler: Uçuş gecikme tahmini, Meteoroloji kaynaklı uçuş gecikmeleri, Yorumlanabilir yapay zekâ (XAI), Veri dengesizliği, Otomatik makine öğrenmesi

ABSTRACT

PREDICTION OF METEOROLOGICAL DELAYS IN TERMINAL AIRSPACE USING ARTIFICIAL INTELLIGENCE

Mustafa Servet ÖZÇINAR

Department of Air Traffic Control

Eskişehir Technical University, Institute of Graduate Programs, August 2025

Supervisor: Asst. Prof. Dr. Fulya AYBEK ÇETEK

This thesis addresses the challenge of predicting flight delays caused by meteorological conditions at major hub airports using artificial intelligence. Utilizing data from Istanbul Airport (LTFM) as a case study, models were developed by integrating standard meteorological reports (METAR) with operational flight records. The research designed both a regression model to forecast delay durations and a classification model to assign delays into operational risk categories. The challenges posed by rare high-delay events and data imbalance were successfully overcome using advanced synthetic data generation and balancing techniques, such as CTGAN and ADASYN. The developed LightGBM and H2O AutoML-based models produced high-performance predictions on test data. Notably, the classification model demonstrated exceptional success in identifying operationally critical "High Delay" events. SHAP analyses provided transparency into the models' decision mechanisms, confirming the decisive role of factors like low visibility and low cloud ceilings. This research presents an interpretable and robust methodological framework for forecasting meteorological delays in complex aviation operations.

Keywords: Flight delay prediction, Weather and flight delays, Explainable artificial intelligence (XAI), Data imbalance, Automated machine learning (AutoML).

TEŞEKKÜR

Çalışma sürecinin her aşamasında bilimsel vizyonu ve değerli yönlendirmeleriyle yolumu aydınlatan danışmanım Dr. Öğr. Üyesi Fulya AYBEK ÇETEK'e en içten teşekkürlerimi sunarım. Kendisinin akademik titizliği ve teşviki, bu araştırmanın sağlam temeller üzerine kurulmasını sağlamıştır.

Araştırmanın veri altyapısını oluşturan meteorolojik bilgilerin teminindeki değerli katkılarından dolayı Meteoroloji Genel Müdürlüğü'ne şükranlarımı sunarım. Bu vesileyle, verileri büyük bir titizlikle kaydeden İstanbul Havalimanı Meteoroloji Ofisi personeline ve bu verilerin temini sürecindeki destekleri için veri merkezinde görev alan MGM veri işlemleri bölümü çalışanlarına da ayrıca teşekkür ederim. Bu araştırmanın yürütülmesini mümkün kılan kapsamlı operasyonel arşiv verilerini bilimsel kullanıma açan EUROCONTROL organizasyonuna ve bu süreçteki yardımlarından ötürü ilgili birim yetkililerine teşekkür ederim. Ayrıca, terminal hava sahasında büyük bir özveri ve profesyonellikle görev yapan İstanbul Havalimanı Hava Trafik Kontrol ekibine, bu çalışmanın dolaylı olarak temelini oluşturan operasyonel faaliyetleri için minnettarım.

Yüksek lisans eğitimim boyunca bilgi, birikim ve deneyimlerinden faydalandığım Eskişehir Teknik Üniversitesi'nin değerli akademisyenlerine ve idari süreçlerdeki destekleri için tüm üniversite personeline teşekkür ederim.

Çalışma sürecinde varlıklarıyla bana destek olan sevgili eşim İlknur ÖZÇINAR başta olmak üzere, aileme ve sevdiklerime en içten teşekkürlerimi sunarım.

Mustafa Servet ÖZÇINAR

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Eskişehir Teknik Üniversitesi tarafından kullanılan “bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Mustafa Servet ÖZÇINAR

İÇİNDEKİLER

Sayfa

BAŞLIK SAYFASI	I
JÜRİ VE ENSTİTÜ ONAYI.....	II
DANIŞMAN ONAYI	III
ÖZET	IV
ABSTRACT.....	V
TEŞEKKÜR	VI
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	VII
İÇİNDEKİLER.....	VIII
TABLolar DİZİNİ.....	XI
ŞEKİLLER DİZİNİ.....	XII
SİMGELER VE KISALTMALAR DİZİNİ.....	XIV
1. GİRİŞ.....	1
1.1. Araştırmanın Arka Planı ve Problemin Tanımı	2
1.2. Araştırmanın Amacı ve Önemi.....	4
1.3. Araştırmanın Kapsamı ve Kısıtları	5
2. KURAMSAL ÇERÇEVE.....	7
2.1. Uçuş Gecikmelerinin Nedenleri ve Sınıflandırılması.....	7
2.2. Meteorolojik Faktörlerin Uçuş Operasyonlarına Etkileri	9
2.3. Uçuş Gecikmesi Tahminlemesinde Veri Odaklı Yaklaşımlar.....	11
2.3.1. Geleneksel istatistiksel yöntemler.....	13
2.3.2. Makine öğrenmesi yöntemleri ve uygulamaları.....	14
2.3.3. Otomatik makine öğrenmesi (AutoML)	15
2.4. Tahmin Modellerinde Karşılaşılan Zorluklar.....	18
2.4.1. Veri dengesizliği problemi ve çözüm stratejileri.....	19
2.4.2. Özellik mühendisliğinin rolü ve önemi.....	20
2.5. Literatür Analizi ve Araştırmanın Konumlandırılması.....	21
2.5.1. Havacılık operasyonlarında meteorolojik koşulların etkileri.....	22

2.5.2. Uçuş gecikmesi tahmini uygulamaları ve veri denge stratejileri.....	22
2.5.3. Araştırmanın konumlandırılması.....	24
3. VERİ SETİ VE YÖNTEM.....	26
3.1. Araştırmanın Soruları	26
3.2. İstanbul Havalimanı (LTFM): Altyapı ve Operasyonel Bağlam.....	27
3.3. Araştırma Veri Seti.....	31
3.3.1. Veri kaynakları, toplama süreci ve içerik detayları	31
3.3.1.1. Meteorolojik veriler	32
3.3.1.2. Operasyonel Uçuş Verileri	34
3.3.2. Zaman aralığı ve bağlamsal faktörlerin önemi	35
3.4. Veri Setinin Yapısı, Ön İşlenmesi ve Özellik Mühendisliği	36
3.4.1. Özellik mühendisliği	37
3.4.1.1. Kategorik özelliklerin oluşturulması.....	37
3.4.1.2. Etkileşim terimleri ve veri temizliği.....	40
3.5. Gecikme Süresi Tahmini için Regresyon Modellemesi	41
3.5.1. Veri hazırlığı ve veri artırma (CTGAN).....	41
3.5.2. LightGBM modelinin kurulumu, eğitimi ve optimizasyonu.....	42
3.6. Gecikme Kategorisi Tahmini için Sınıflandırma Modellemesi.....	43
3.6.1. Veri hazırlığı ve veri dengesizlik yönetimi.....	43
3.6.2. Yenilikçi yaklaşım: AutoML ile otomatik model geliştirme	44
3.7. Deneysel Kurulum, Değerlendirme Metrikleri ve Araçlar	44
4. UYGULAMA SONUÇLARI VE DEĞERLENDİRME.....	47
4.1. Keşifsel Veri Seti Bulguları	47
4.1.1. Hedef değişkenin dağılımı	47
4.1.2. Kategorik özelliklerin dağılımları ve dengesizlik analizi	48
4.1.3. Özellikler ve hedef değişken arasındaki ilişkiler.....	49
4.1.4. Korelasyon analizi.....	53
4.2. Regresyon Modeli Sonuçları (LightGBM).....	54
4.2.1. Model performansının değerlendirilmesi	54
4.2.2. Özellik önem analizi ve meteorolojik faktörlerin etkisi (SHAP)	58
4.3. Sınıflandırma Modeli Sonuçları (AutoML- H2O)	62
4.3.1. AutoML liderlik tablosu ve seçilen modelin performansı.....	63

4.3.2. Sınıf bazı performans analizi (karmaşıklık matrisi).....	64
4.3.3. Veri dengeleme tekniklerinin model başarısına etkisi.....	67
5. SONUÇ VE GELECEK ÇALIŞMALAR.....	69
5.1. Araştırmanın Genel Değerlendirmesi ve Temel Bulgular.....	69
5.2. Modellerin Karşılaştırmalı Analizi ve Operasyonel Tartışma	72
5.2.1. Regresyon yaklaşımının değerlendirilmesi.....	72
5.2.2. Sınıflandırma yaklaşımının değerlendirilmesi	73
5.3. Araştırmanın Özgün Katkıları	74
5.4. Gelecek Araştırmalar için Öneriler.....	76
KAYNAKÇA.....	78
ÖZGEÇMİŞ	

TABLolar DİZİNİ

Sayfa

Tablo 1.1. Hava trafik operasyonlarını etkileyen başlıca meteorolojik olaylar ve tipik sonuçları	3
Tablo 2.1. Uçuş gecikmesi tahminlemede geleneksel istatistiksel yöntemlerin karşılaştırması	12
Tablo 2.2. Uçuş gecikmesi tahminlemede makine öğrenmesi yöntemlerinin karşılaştırması	13
Tablo 4.1. Regresyon modellerinin genel performans metriklerinin karşılaştırılması (Test Seti).....	55
Tablo 4.2. Regresyon modellerinin kritik gecikme eşiğine göre performansının karşılaştırılması	55
Tablo 4.3. Senaryo 1: Sadece ADASYN ile AutoML liderlik tablosu (İlk 5 Model)....	63
Tablo 4.4. Senaryo 2: ADASYN + 5 Kat aşırı örnekleme ile AutoML liderlik tablosu (İlk 5 Model)	63
Tablo 4.5. En iyi lider modellerin performans metrikleri karşılaştırması.....	64
Tablo 4.6. İki veri dengeleme senaryosu için sınıf bazlı performans metriklerinin karşılaştırması	67

ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1. Avrupa geneli ortalama uçuş gecikmesi ve nedenleri (2023-2025)	2
Şekil 1.2. Avrupa'da gecikme eşiklerine göre yıllık rötar oranları (2021)	3
Şekil 2.1. Tipik AutoML iş akışı şeması	16
Şekil 3.1. İstanbul havalimanı pist yerleşim krokisi.....	28
Şekil 3.2. İstanbul Havalimanı RNAV standart yaklaşma prosedür örneği	29
Şekil 3.3. İstanbul Havalimanı (LTFM) ATFM Varış Gecikmelerinin Nedenleri (Şub. 2023- 2025)	30
Şekil 3.4. Hâkim yatay görüş mesafesi değerlerinin veri setindeki dağılımı	33
Şekil 3.5. Veri setindeki en düşük tavan oluşturan bulutların tür dağılımı	33
Şekil 3.6. Analiz veri setindeki ortalama gecikme süresinin frekans dağılımı.....	37
Şekil 3.7. Görüş mesafe kategorisinin veri setindeki dağılımı	38
Şekil 3.8. Türetilen yağış özelliğinin veri setindeki dağılımı.....	40
Şekil 4.1. Görüş kısıtlayıcı koşulların (GORUS_KISITLI) varlığına ilişkin frekans dağılımı.....	49
Şekil 4.2. Yağış (YAGIS) durumuna ilişkin frekans dağılımı	49
Şekil 4.3. Görüş mesafesi kategorilerine göre ortalama gecikme dağılımı (Kutu Grafiği)	50
Şekil 4.4. Bulut taban yüksekliği kategorilerine göre ortalama gecikme dağılımı (Kutu Grafiği)	51
Şekil 4.5. Yağış varlığına göre ortalama gecikme dağılımı (Kutu Grafiği)	52
Şekil 4.6. Düşük görüş ve yağışın (LowVis_and_Precip) ortalama gecikmeye etkisi... ..	52
Şekil 4.7. Regresyon modelindeki sayısal özellikler arasındaki Pearson Korelasyon Matrisi	53
Şekil 4.8. Regresyon modeli tahminlerinin gerçek değerler ile karşılaştırılması (test seti)	57
Şekil 4.9. LightGBM modeli tahmin hatalarının dağılımı (test seti – CTGAN Uygulanan Senaryo)	57

Şekil 4.10. Regresyon modeli için SHAP özellik önem sıralaması ve etki yönleri	59
Şekil 4.11. Toplam bulut kapalılığının model çıktısına etkisini gösteren SHAP bağımlılık grafiği	60
Şekil 4.12. Alçak seviye bulut taban yüksekliğinin modele etkisini gösteren SHAP bağımlılık grafiği	61
Şekil 4.13. Yağış varlığının model çıktısına etkisini gösteren SHAP grafiği	62
Şekil 4.14. Karmaşıklık matrisi- Sadece ADASYN senaryosu.....	65
Şekil 4.15. Karmaşıklık matrisi- ADASYN + 5 kat aşırı örnekleme senaryosu	66



SİMGELER VE KISALTMALAR DİZİNİ

AAR	: Havalimanı Kabul Oranı (Airport Acceptance Rate)
AGL	: Yer Seviyesinden Yükseklik (Above Ground Level)
AIP	: Havacılık Bilgi Yayını (Aeronautical Information Publication)
ATC	: Hava Trafik Kontrol (Air Traffic Control)
ATFM	: Hava Trafik Akış Yönetimi (Air Traffic Flow Management)
AutoML	: Otomatik Makine Öğrenmesi (Automated Machine Learning)
EUROCONTROL	: Avrupa Hava Seyrüsefer Emniyeti Teşkilatı (European Organisation for the Safety of Air Navigation)
FAA	: Federal Havacılık İdaresi (Federal Aviation Administration)
IATA	: Uluslararası Hava Taşımacılığı Birliği (International Air Transport Association)
ICAO	: Uluslararası Sivil Havacılık Örgütü (International Civil Aviation Organization)
IFR	: Aletli Uçuş Kuralları (Instrument Flight Rules)
ILS	: Aletli İniş Sistemi (Instrument Landing System)
LVP	: Düşük Görüş Prosedürleri (Low Visibility Procedures)
METAR	: Havaalanı Meteoroloji Raporu (Meteorological Aerodrome Report)
MGM	: Meteoroloji Genel Müdürlüğü
ML	: Makine Öğrenmesi (Machine Learning)
OCC	: Havayolu Operasyon Kontrol Merkezleri (Airline Operations Control Centers)
OHE	: Tekil Kodlama (One-Hot Encoding)


PBN	: Performansa Dayalı Seyrüsefer (Performance-Based Navigation)
SHAP	: SHapley Toplamsal Açıklamaları (SHapley Additive exPlanations)
TAF	: Terminal Saha Tahmini (Terminal Aerodrome Forecast)
TMA	: Terminal Kontrol Sahası (Terminal Control Area)
VFR	: Görerek Uçuş Kuralları (Visual Flight Rules)
WMO	: Dünya Meteoroloji Örgütü (World Meteorological Organization)

1. GİRİŞ

Hava taşımacılığı, küresel bağlantısallığın ve ekonomik faaliyetlerin temel taşlarından biri olarak, operasyonel verimliliğini büyük ölçüde zamanında performansa (On-Time Performance- OTP) borçludur. Son yıllarda hava trafiğindeki istikrarlı artış, havacılık sisteminin tüm bileşenleri üzerinde önemli bir baskı oluşturmaktadır [1].

Hava trafik yönetimi (ATM) sistemi doğası gereği artan trafik hacmi, altyapı yetersizlikleri, hava sahası kısıtlamaları ve çeşitli operasyonel değişkenlerin dinamik etkileşiminden etkilenen karmaşık bir yapıya sahiptir. Bu karmaşık sistem içerisinde, uçuş gecikmeleri kaçınılmaz bir olgu olarak ortaya çıkmakta ve havayolu şirketleri, havalimanları, yolcular ile genel ekonomi gibi tüm paydaşları olumsuz yönde etkilemektedir [2, 3].

Gecikmelere yol açan çok sayıda faktör arasında, atmosferik koşulların öngörülemezliği ve değişkenliği en kritik ve yönetimi en zor unsurlardan biri olarak öne çıkmaktadır [4]. Meteorolojik olaylar, operasyonları doğrudan durdurabilmelerinin (örneğin, yoğun sis veya kar fırtınası nedeniyle pistlerin kapanması) yanı sıra, sistemin kapasitesini düşürerek veya operasyonel süreçleri tetikleyerek dolaylı etkilere de yol açmaktadır. Özellikle Avrupa gibi yoğun hava sahalarında, bu tür olaylar sıklıkla operasyonel aksamalara, havalimanı ve hava sahası kapasite düşüşlerine ve sistem geneline yayılan zincirleme gecikmelere neden olmaktadır (Şekil 1.1). Hava durumunun operasyonel performans üzerindeki bu belirleyici rolü, Avrupa Hava Seyrüsefer Emniyeti Teşkilatı (EUROCONTROL) gibi otoritelerin verileriyle de desteklenmektedir [5].




Şekil 1.1. Avrupa geneli ortalama uçuş gecikmesi ve nedenleri (2023-2025)

Şekil 1.1'de gösterildiği gibi, hava durumu kaynaklı gecikmeler, diğer ana neden grupları olan havayolu, hava trafik akış yönetimi (ATFM) ve havalimanı kaynaklı gecikmelerle birlikte sistemde önemli bir paya sahiptir [5]. Bu durum, meteorolojik koşulların sadece bir gecikme nedeni olmadığını, aynı zamanda diğer operasyonel sorunları tetikleyen veya mevcut sorunların etkisini artıran bir faktör olduğunu da göstermektedir. Örneğin, kötü hava koşulları nedeniyle bir uçuşta yaşanan ilk gecikme, o uçağın sonraki seferlerini etkileyerek kolaylıkla zincirleme gecikmelere dönüşebilmekte ve ağır geneline yayılabilmektedir [6].

1.1. Araştırmanın Arka Planı ve Problemin Tanımı

Hava taşımacılığı sisteminin operasyonel verimliliğinin temel bir göstergesi, tam zamanında performans (dakiklik) metriğidir. Özellikle olumsuz meteorolojik koşulların hâkim olduğu periyotlarda, 30 dakikayı aşan önemli gecikmelerin frekansında belirgin bir artış kaydedilmektedir [7]. Dakiklik oranlarındaki bu değişkenlik, atmosferik koşulların sistem üzerindeki hem anlık (operasyonel) hem de mevsimsel (yapısal) etkilerinin somut bir yansımasıdır (Şekil 1.2).



Şekil 1.2. Avrupa'da gecikme eşiklerine göre yıllık rötar oranları (2021)

Şekil 1.2'de görüleceği üzere, operasyonel performanstaki bu dalgalanmalar, sistemin öngörülebilirliğini azaltmaktadır.

Meteorolojik koşullar, özellikle havalimanı operasyonlarını doğrudan ve sıklıkla kesintiye uğratma potansiyeline sahiptir. Düşük görüş, kar yağışı, şiddetli rüzgarlar ve konvektif hava olayları gibi faktörler, pist kapasitesini anlık olarak düşürmekte, yer hizmetleri süreçlerini yavaşlatmakta ve uçuşların zamanında kalkışını veya inişini engellemektedir [8]. Başlıca meteorolojik olayların hava trafik operasyonları üzerindeki tipik etkileri Tablo 1.1'de özetlenmektedir [7,9].

Tablo 1.1. Hava trafik operasyonlarını etkileyen başlıca meteorolojik olaylar ve tipik sonuçları

Düşük Görüş	Şiddetli Yağış (Yağmur/Kar)	Oraj / Fırtına (Cb Bulutları)
-Düşük Görüş Prosedürleri (LVP) uygulama	-Görüş mesafesinde azalma (özellikle şiddetli yağışta)	-Havalimanı yer operasyonlarının güvenlik nedeniyle durdurulması
-Düşük pist kapasitesi (iniş/kalkış oranlarında düşüş)	-Pist yüzeyinde kontaminasyon, frenleme performansında düşüş	-Uçuş rotalarının değiştirilmesi veya beklemeye alınması
-Uçaklar arası ayırma mesafelerinin artırılması	-Uçaklar için buzlanma önleyici/giderici prosedürlerine olan ihtiyacın artması.	-Hava sahası sektörlerinin kapasitesinin düşürülmesi veya tamamen kapatılması

Meteoroloji kaynaklı ve tetiklenen gecikmeler ekonomik kayıplara, artan çevresel etkilere (ekstra yakıt tüketimi ve emisyonlar) ve yolcu memnuniyetinde düşüşlere yol

açmaktadır [10]. Ayrıca, iklim değişikliğinin etkisiyle gelecekte daha sık ve şiddetli hava olaylarının yaşanması beklentisi, bu zorlukları daha da artıracaktır [11]. Bu durum, hava durumu kaynaklı operasyonel aksaklıkların etkilerini azaltmak ve sistemin dayanıklılığını artıracak stratejiler geliştirmeyi zorunlu kılmaktadır. Bu bağlamda, büyük hacimli operasyonel ve meteorolojik verilerden yararlanarak, gecikmelerin öngörülebilirliğini artıracak modeller geliştirmek, temel bir araştırma problemi olarak ortaya çıkmaktadır.

1.2. Araştırmanın Amacı ve Önemi

Bu bilimsel çalışmanın temel amacı, havalimanı operasyonel verimliliğini önemli ölçüde etkileyen meteorolojik koşulların, uçuş gecikmeleri üzerindeki karmaşık etkisini modern veri bilimi ve makine öğrenmesi teknikleriyle modellemek ve uçuş gecikme süresini tahmin etmektir. Bu doğrultuda çalışma, meteorolojik faktörlere dayalı olarak hem gecikme süresini hem de operasyonel açıdan anlamlı olacak şekilde gecikme kategorilerini yüksek doğrulukla tahmin edebilen genel yaklaşımlar geliştirmeyi hedeflemektedir.

Çalışma ayrıca kantitatif yöntemler aracılığıyla, uçuş gecikmeleri üzerinde istatistiksel olarak anlamlı ve belirleyici etkiye sahip meteorolojik parametreleri ve bu parametrelerin nispi önemlerini tespit etmeyi amaçlamaktadır. İkinci olarak, özellikle nadir görülen yüksek gecikme vakalarından kaynaklanan ve veri setlerinde yaygın bir sorun teşkil eden sınıf dengesizliğinin olumsuz etkilerini azaltmak amacıyla, gelişmiş sentetik veri artırımı tekniklerinin model performansı üzerindeki etkinliği kapsamlı metrikler aracılığıyla değerlendirilmektedir. Nihayetinde çalışma, geliştirilen tahmin modellerinin “kara kutu” doğasını azaltarak, yorumlanabilirliği artırmayı hedeflemekte; böylece hangi spesifik meteorolojik koşulların gecikme tahminlerini ne yönde ve ne ölçüde etkilediğine dair operasyonel açıdan anlamlı içgörüler sunmayı amaçlamaktadır.

Bu araştırmanın önemi, hem havacılık endüstrisi paydaşları için sağlayacağı pratik faydalar hem de akademik literatüre yapacağı bilimsel katkı açısından çift yönlüdür. Pratik açıdan, geliştirilen başarılı tahmin modelleri; Hava Trafik Kontrol (ATC) üniteleri, havalimanı işletmecileri ve Havayolu Operasyon Kontrol Merkezleri (OCC) için değerli bir karar destek sistemi potansiyeli sunmaktadır. Meteorolojik koşullara bağlı olası gecikmelerin saatler öncesinden yüksek doğrulukla öngörülmesi; Hava Trafik Akış Yönetimi (ATFM) önlemlerinin daha proaktif planlanmasına, havalimanı kaynaklarının daha verimli kullanılmasına ve operasyonel esnekliğin artırılmasına olanak tanır. Bu

proaktif yaklaşım, gecikmelerin hava trafik ağına yayılma riskini (reaksiyoner gecikmeler) azaltarak sistemik verimliliğe katkı sağlar ve yolcu memnuniyetini iyileştirir.

Akademik ve bilimsel açıdan bu çalışma, uçuş gecikmesi tahminlemesi alanına, özellikle meteorolojik faktörlerin etkisine odaklanarak ve modern makine öğrenmesi iş akışlarının etkinliğini ampirik kanıtlarla göstererek katkı sağlamaktadır. Veri dengesizliği ve veri kıtlığı gibi problemlere yönelik yenilikçi çözümlerin karmaşık havacılık problemlerinin çözümündeki potansiyelini göstermesi, literatüre yapılan önemli bir diğer katkıdır.

1.3. Araştırmanın Kapsamı ve Kısıtları

Bu bölüm, sunulan araştırmanın kapsamı ve kısıtları, elde edilen bulguların doğru bir bağlamda yorumlanmasını sağlamak amacıyla oluşturulmuştur.

Bu araştırma, büyük ölçekli aktarma merkezi (hub) statüsünde olan havalimanı operasyonları üzerine yoğunlaşmaktadır. Analizler, bu havalimanına yönelik iniş (arrival) gerçekleştiren tarifeli ticari yolcu uçuşlarına ve bu uçuşların Terminal Kontrol Sahası (TMA) dahilindeki gecikme profillerine odaklanmıştır. Kalkış operasyonları, genel havacılık faaliyetleri ve kargo taşımacılığı gibi diğer segmentler çalışma dışında tutulmuştur.

Çalışmada, Mart 2019 ile Haziran 2022 tarihleri arasındaki dönemi kapsayan, ilgili meteoroloji otoritesi (Meteoroloji Genel Müdürlüğü) kaynaklı standart METAR (Meteorological Aerodrome Report – Havaalanı Meteoroloji Raporu) / SPECI (Special Meteorological Report – Özel Meteorolojik Rapor) raporları ile EUROCONTROL kaynaklı operasyonel uçuş kayıtlarının entegrasyonu ile oluşturulmuş bir veri seti kullanılmıştır.

Gecikme nedenlerinin incelenmesinde, METAR verilerinde yer alan ve doğrudan gözlemlenebilir meteorolojik değişkenler kullanılmıştır. Hava trafik kontrol kapasitesi, havayolu operasyonel stratejileri ve zincirleme reaksiyoner gecikmeler gibi doğrudan ölçümlenemeyen diğer potansiyel etkenler, modellere girdi olarak dahil edilmemiştir. Bu çalışmanın bazı temel kısıtları bulunmaktadır:

Veri Döneminin Özgünlüğü: Veri setinin kapsadığı Mart 2019- Haziran 2022 dönemi, çalışmanın yürütüldüğü havalimanının operasyonel başlangıç/tam kapasiteye geçiş dönemini ve küresel COVID-19 pandemisinin hava trafiğini derinden etkilediği özel koşulları içermektedir. Bu durum, normalden düşük trafik yoğunluğu nedeniyle,

geliştirilen modellerin gelecekteki tam kapasite trafik koşulları altındaki performansını tam olarak yansıtmayabilir.

Nadir Olay Temsili: Pandemi nedeniyle azalan uçuş sayısı, özellikle nadir görülen ekstrem hava olaylarının ve bunlara bağlı çok yüksek gecikme vakalarının veri setindeki temsilini kısıtlamış olabilir. Veri artırma teknikleri kullanılmış olsa da modelin bu tür çok nadir olayları öğrenme kapasitesi sınırlı kalabilir.

Model Girdi Kapsamı: Modellerin yalnızca METAR verilerine dayanması önemli bir kısıttır. Gecikmeleri etkileyen ancak METAR'da bulunmayan diğer faktörler (anlık ATC talimatları, hava sahası sektör yoğunluğu vb.) model tarafından doğrudan hesaba katılmamıştır.

Model Transfer Edilebilirliği: Geliştirilen modeller, üzerinde çalışılan havalimanının spesifik koşullarına göre eğitildiğinden, başka havalimanlarına doğrudan uygulanabilirlikleri düşüktür ve yeniden eğitilmeleri gerekir.

Bu kapsam ve kısıtların farkında olarak, araştırma bulgularının dikkatli bir şekilde yorumlanması ve pratik uygulamalarda bu sınırlılıkların göz önünde bulundurulması esastır.

2. KURAMSAL ÇERÇEVE

Bu bölümde, araştırmanın teorik altyapısını oluşturan temel kavramlar, uçuş gecikmeleri üzerine yapılmış önceki çalışmalar ve bu çalışmada kullanılan modern veri bilimi yaklaşımları detaylı bir şekilde ele alınacaktır. Amaç, araştırmanın bilimsel zeminini ve literatürdeki yerini belirlemek, ayrıca kullanılan yöntemlerin teorik dayanaklarını açıklamaktır.

2.1. Uçuş Gecikmelerinin Nedenleri ve Sınıflandırılması

Hava taşımacılığı sistemi, birçok bağımsız ancak birbirine sıkı sıkıya bağlı alt sistemin (havayolları, havalimanları, hava trafik kontrol (ATC) hizmetleri, yer hizmetleri, meteoroloji vb.) eşgüdüm içinde çalışmasını gerektiren oldukça karmaşık ve dinamik bir yapıya sahiptir. Bu karmaşık ağ içerisinde, herhangi bir alt sistemdeki aksaklık veya kapasite-talep dengesizliği, domino etkisi oluşturarak operasyonel süreçlerde sapmalara ve sonuç olarak uçuş gecikmelerine yol açabilmektedir [12]. Uçuş gecikmesi en genel tanımıyla; bir uçuşun planlanan kalkış veya varış saatine göre 15 dakika veya daha fazla bir süre sonra gerçekleşmesidir [13]. Bu 15 dakikalık eşik, Uluslararası Hava Taşımacılığı Birliği (IATA) ve Federal Havacılık İdaresi (FAA) gibi otoriteler tarafından “Zamanında Performans” (On-Time Performance- OTP) takibinde standart bir metrik olarak kullanılmaktadır [13].

Bölüm 1'de detaylandırıldığı gibi, uçuş gecikmelerinin havayolları, havalimanları, yolcular ve genel ekonomi üzerinde önemli operasyonel, ekonomik ve sosyal sonuçları bulunmaktadır [1, 9, 14]. Gecikmelerin etkin bir şekilde yönetilebilmesi ve azaltılabilmesi, öncelikle bu gecikmelere yol açan kök nedenlerin doğru bir şekilde anlaşılmasını ve sistematik olarak sınıflandırılmasını gerektirir. Havacılık otoriteleri (örn. FAA, EUROCONTROL) ve endüstri kuruluşları (örn. IATA), gecikmenin sorumluluğunu veya kaynağını belirlemek amacıyla, gecikmeleri belirli ana kategoriler altında toplamaktadır [15, 16]. Bu sınıflandırmalar, verilerin standartlaştırılmasına, karşılaştırılmasına ve hedeflenmiş iyileştirme stratejilerinin geliştirilmesine olanak tanır. Başlıca gecikme nedenleri ve uluslararası kabul görmüş kategorileri aşağıdaki gibi özetlenebilir [15, 16]:

Havayolu Kaynaklı Nedenler: Doğrudan havayolu şirketinin operasyonel kontrolü altındaki faktörlerden kaynaklanan gecikmelerdir. Bunlar arasında uçağın tarifeli veya plansız teknik bakımı (IATA Kod 4X serisi), uçak teknik arızaları, uçak

değişikliği, uçak temizliği, yakıt ikmali (IATA Kod 36), ikram hizmetlerindeki aksaklıklar (IATA Kod 37), mürettebatın planlanmasındaki sorunlar (örn. mürettebat yetersizliği, görev sürelerinin dolması (IATA Kod 61-69 serisi), yolcu ve bagaj işlemleri (örn. geç kalan yolcular, bagaj yükleme sorunları (IATA Kod 1X serisi), kargo/posta işlemleri (IATA Kod 2X serisi) gibi havayolunun iç süreçleriyle ilgili durumlar yer alır [14-18].

Hava Trafik Yönetimi (ATM) Kaynaklı Nedenler: Hava trafik akışının yönetimi ve hava sahası sisteminin genel işleyişinden kaynaklanan gecikmelerdir. Bu kategoriye ATC kapasitesinin talebi karşılayamaması (IATA Kod 81, 83), ATC personel yetersizliği (IATA Kod 82), ATC ekipman sorunları, Hava Trafik Akış Yönetimi (ATFM) düzenlemeleri (örn. slot tahsisi, yer bekletmeleri, mil-dakika kısıtlamaları (IATA Kod 87, 89), hava sahası kısıtlamaları (örn. askeri faaliyetler), hava durumu nedeniyle ATC tarafından uygulanan özel prosedürler (örn. Düşük Görüş Prosedürleri - LVP uygulaması sonucu kapasite düşüşü), havalimanı veya rota üzerindeki yoğun trafik hacmi gibi faktörler girer [14-19].

Meteorolojik Nedenler: Olumsuz atmosferik koşulların kalkış, varış meydanlarında veya rota üzerinde operasyonları doğrudan engellemesi veya kapasiteyi düşürerek gecikmelere yol açması durumudur. Sis, pus, düşük bulut tavanı gibi düşük görüş koşulları (IATA Kod 75, 77), şiddetli rüzgâr, rüzgâr kesmesi (windshear), kar, buzlanma (IATA Kod 71, 72), donan yağmur, oraj (thunderstorm) ve ilişkili yıldırımlar, türbülans, dolu (IATA Kod 76) gibi olaylar bu kategoriye dahildir. Uçağın buzdan arındırılması (de-icing/anti-icing) işlemleri de genellikle meteorolojik nedenli gecikmeler arasında sayılır (IATA Kod 71) [14-19].

Zincirleme/Reaksiyoner Gecikmeler: Bir uçağın, bir önceki uçuş bacağından gecikmeli olarak gelmesi nedeniyle mevcut seferinin de planlanan zamanda başlayamaması sonucu oluşan gecikmelerdir (IATA Kod 93). Bu kategori, genellikle “tüm nedenler” analizlerinde en yüksek paya sahip olan gecikme türüdür [12]. Ancak reaksiyoner gecikme bir kök neden değildir; daha ziyade, önceki bir gecikmenin (havayolu, ATM, hava durumu vb. kaynaklı) hava trafik ağı içerisinde yayılmasının bir sonucudur. [20].

Havalimanı Altyapısı ve Tesis Kaynaklı Nedenler (Airport/Facility Delays): Havalimanı işletmesi veya altyapısıyla ilgili sorunlardan kaynaklanan gecikmelerdir. Kapı/park pozisyonu yetersizliği, terminaldeki kısıtlamalar (örn. yolcu köprü arızası), yer

destek ekipmanlarının sorunları, pist/taksi yolu bakımı veya kapalılığı gibi durumlar bu kategori altında değerlendirilir (IATA Kod 88, 89) [17-20].

Güvenlik Kaynaklı Nedenler: Güvenlik prosedürleri, kontrolleri veya olayları nedeniyle meydana gelen gecikmelerdir. Yolcu/bagaj/kargo güvenlik taramalarında yaşanan aşırı yığılmalar, güvenlik ihlalleri veya ek güvenlik kontrolleri bu kategoride yer alır [17-20].

Diğer Nedenler: Yukarıdaki ana kategorilere girmeyen çeşitli nedenlerdir. Endüstriyel eylemler/grevler (IATA Kod 98), gümrük/pasaport/sağlık kontrolü gibi devlet prosedürleri (IATA Kod 85, 86) veya sistemsel olmayan diğer nadir faktörler bu başlık altında sınıflandırılır (IATA Kod 99) [17].

Gecikme nedenlerinin bu şekilde sınıflandırılması, problemin karmaşıklığını yönetilebilir bileşenlere ayırmaya yardımcı olur. Ancak, gecikmeler genellikle birden fazla faktörün etkileşimiyle ortaya çıktığından, raporlanan neden ile gerçek kök neden her zaman aynı olmayabilir. Yapılan çalışmada bu geniş yelpazedeki potansiyel nedenlerden özellikle meteorolojik faktörlerin iniş operasyonlarındaki gecikmelere olan etkisine odaklanmaktadır.

2.2. Meteorolojik Faktörlerin Uçuş Operasyonlarına Etkileri

Havacılık operasyonlarının emniyeti, verimliliği ve düzenliliği üzerinde en belirleyici ve aynı zamanda en az kontrol edilebilir dışsal faktörlerden biri şüphesiz meteorolojik koşullardır. Hava durumu, bir uçuşun planlama aşamasından başlayarak, kalkış, rota üzeri uçuş (en-route), yaklaşma ve iniş safhalarının tamamını doğrudan veya dolaylı olarak etkileme potansiyeline sahiptir [6, 20]. Olumsuz hava koşulları, küresel ölçekte uçuş gecikmelerinin ve iptallerinin başlıca nedenleri arasında yer almakta, hava trafik yönetimini (ATM) zorlamakta, havalimanı kapasitesini düşürmekte ve önemli ekonomik kayıplara yol açmaktadır [13]. Bu bölümde, spesifik meteorolojik faktörlerin uçuş operasyonları üzerindeki temel etkileri daha ayrıntılı olarak incelenecektir.

Görüş Koşulları (Sis, Pus, Düşük Bulut Tavanı): Yeterli görüş mesafesi (Visibility- VIS) ve Pist Görüş Mesafesi (Runway Visual Range- RVR), operasyonel emniyet için temel bir gerekliliktir. Belirlenen RVR veya bulut tavanı minimumlarının altına inildiğinde, genellikle Düşük Görüş Prosedürleri (Low Visibility Procedures- LVP) uygulanır [21]. LVP koşullarında, uçaklar arası emniyet ayırma mesafeleri artırıldığı için Havalimanı Kabul Oranı (Airport Acceptance Rate- AAR) önemli ölçüde düşer. Bu

kapasite düşüşü, havada beklemelere (holding), rota değişikliklerine veya yedek meydana inişlere (diversions) yol açarak ciddi gecikmelere neden olabilir [9].

Rüzgâr (Şiddet, Yön, Hamle, Rüzgâr Kesmesi): Rüzgâr hızı ve yönü, özellikle iniş ve kalkış operasyonları için kritik limitlere sahiptir. Uçak üreticileri tarafından belirlenen maksimum yan rüzgâr (crosswind) ve kuyruk rüzgârı (tailwind) limitleri, pist kullanımını kısıtlayabilir. Rüzgâr hamleleri (gusts) ve rüzgâr kesmesi (wind shear), uçuş emniyeti için ciddi riskler taşıdığından pas geçmelere (go-around) neden olabilir. Rüzgâr yönündeki belirgin değişiklikler ise pist konfigürasyon değişikliği gerektirerek ek gecikmelere yol açabilir [22].

Yağış (Yağmur, Kar, Donan Yağış, Dolu): Yağışın türü ve yoğunluğu, operasyonları çeşitli şekillerde etkiler. Yoğun yağmur görüşü düşürür ve pist yüzeyinde su birikintileri (hydroplaning riski) yaratarak frenleme performansını azaltır [9]. Kar yağışı, pistlerin ve taksi yollarının kapanmasına ve kalkış öncesi zorunlu buzdan arındırma (de-icing) işlemlerine neden olarak önemli gecikmelere yol açar [23]. Dolu ise uçaklarda yapısal hasara neden olabileceği için kaçınılması gereken tehlikeli bir hadisedir.

Orağlar (Thunderstorms) ve İlişkili Tehlikeler: Orağlar; şiddetli türbülans, buzlanma, yıldırım ve mikroburst (ani ve güçlü aşağı yönlü hava akımı) gibi havacılık için son derece tehlikeli olguları barındırabilir. Pilotlar, emniyet nedeniyle bu tür meteorolojik hücrelerden kaçınmak zorunda olduklarından, bu durum önemli rota değişikliklerine, havada beklemelere ve hava sahası/havalimanı kapasitesinin ani düşüşlerine neden olur [6, 13, 22].

Sıcaklık ve Basınç: Aşırı yüksek sıcaklıklar, hava yoğunluğunu azaltarak motor ve kanat performansını düşürür. Bu durum, özellikle “hot and high” (sıcak ve yüksek irtifadaki) havalimanlarında kalkış ağırlığını sınırlayabilir. Atmosferik basınç (QNH) ise uçak altimetre ayarları ve irtifa tespiti için temel veridir. [24]

Bulutlar (Tavan, Tip, Kapalılık): En alçak bulut katmanının taban yüksekliği (tavan- ceiling) ve kapalılık durumu, aletli yaklaşma prosedürlerinin minimumlarını doğrudan etkiler. Kümülönimbus (Cb) ve Tepe Yapan Kümülüs (TCU) gibi konvektif bulut tipleri, içerdikleri şiddetli hava olayları nedeniyle uçaklar için tehlike arz eder ve bu bulutlardan kaçınılması gerekir [24].

Diğer Faktörler (Volkanik Kül vb.): Nadir de olsa volkanik kül bulutları veya şiddetli kum fırtınaları gibi olaylar, geniş hava sahalarının uzun süreli kapatılmasına ve büyük ölçekli operasyonel aksamalara yol açabilir.

Meteorolojik faktörler, pilotlar ve ATC tarafından havalimanı için rutin meteorolojik rapor olan METAR, hızlı ve özellikle beklenmedik değişiklikler olduğunda yayınlanan SPECI, meydan uzun vadeli tahmini olan TAF (Terminal Aerodrome Forecast), SIGMET (Significant Meteorological Information) gibi raporlar aracılığıyla sürekli takip edilir ve operasyonel kararları doğrudan şekillendirir [24]. Bu etkilerin çeşitliliği, hava durumunun doğru tahmin edilmesini ve operasyonel planlamalara etkin bir şekilde entegre edilmesini zorunlu kılar. Bu tezde kullanılan veriler de bu karar verme süreçlerindeki temel anlık bilgi kaynaklarından olan METAR ve SPECI raporlarından elde edilmiştir.

2.3. Uçuş Gecikmesi Tahminlemede Veri Odaklı Yaklaşımlar

Uçuş gecikmeleri, Bölüm 2.1'de detaylandırıldığı gibi, hava taşımacılığı sistemindeki çok sayıda faktörün karmaşık etkileşimleri sonucunda ortaya çıkan stokastik (rassal) olaylardır. Hava durumu, zincirleme gecikme etkileri, teknik sorunlar ve anlık kapasite aşımaları gibi birçok değişken, bu etkileşim ağının yalnızca birkaç parçasını oluşturmaktadır. Bu dinamik yapı ve yüksek belirsizlik, gecikmelerin kesin olarak öngörülmesini son derece zorlaştırmaktadır. Ancak, gecikmelerin operasyonel verimlilik, maliyetler ve yolcu memnuniyeti üzerindeki derin etkileri (Bölüm 1), doğru ve zamanında tahminler yapabilmeyi hem Hava Trafik Yönetimi (ATM) hem de havayolu operasyonları açısından kritik bir ihtiyaç haline getirmektedir.

Başarılı bir tahmin modeli, kaynakların proaktif bir şekilde yönetilmesine ve potansiyel darboğazların önceden tespit edilmesine imkân tanıyacaktır. Geleneksel olarak operasyonel deneyime veya basit kurallara dayalı tahmin yöntemleri, artan sistem karmaşıklığı ve büyük veri hacimleri karşısında yetersiz kalmaktadır. Bu nedenle, büyük veriyi analiz ederek gizli örüntüleri ortaya çıkarabilen makine öğrenmesi ve yapay zekâ teknikleri, bu alanda çığır açan çözümler sunma potansiyeli taşımaktadır. Bu durum, son yıllarda havacılık sektöründe gecikme tahminlemesi problemine yönelik veri odaklı yaklaşımların geliştirilmesine olan yoğun ilgiyi beraberinde getirmiştir [25]. Veri odaklı yaklaşımlar, temel olarak büyük hacimli tarihsel verilerde (operasyonel uçuş kayıtları, meteorolojik gözlemler, hava trafik akış verileri vb.) gizli olan örüntüleri ve istatistiksel

ilişkileri ortaya çıkararak gelecekteki gecikmeleri tahmin etmeyi amaçlar. Bu yaklaşımlar, insan sezgisiyle gözden kaçırılabilir karmaşık ve doğrusal olmayan etkileşimleri yakalama potansiyeli sunar [1, 26].

Veri odaklı gecikme tahminleme yöntemleri, kullanılan algoritmik temellere göre genel olarak geleneksel istatistiksel yöntemler ve daha modern makine öğrenmesi yöntemleri olarak iki ana grupta incelenebilir. Bu iki yaklaşım kategorisi, temel avantaj ile dezavantajları, Tablo 2.1 ve Tablo 2.2’de karşılaştırmalı olarak sunulmaktadır [1, 25-27].

Tablo 2.1. Uçuş gecikmesi tahminlemede geleneksel istatistiksel yöntemlerin karşılaştırması

Yaklaşım	Avantajlar	Dezavantajlar
Geleneksel İstatistiksel Yöntemler	Yorumlanabilirlik: Model parametreleri (katsayılar) istatistiksel olarak yorumlanabilir ve değişkenlerin etkisi anlaşılabilir. Daha Az Veri İhtiyacı: Bazı modeller daha küçük veri setleriyle de uygulanabilir. Hipotez Testi: Bir değişkenin sonuç üzerindeki gözlemlenen etkisinin şans eseri mi, yoksa istatistiksel olarak anlamlı mı olduğunu formel olarak test etme imkânı sunar.	Katı Varsayımlar: Genellikle verinin dağılımı ve ilişkilerin doğrusallığı gibi katı varsayımlar gerektirir. Doğrusal Olmayan İlişkilerde Zayıflık: Karmaşık ve doğrusal olmayan ilişkileri yakalamada genellikle yetersizdir. Yüksek Boyutluluk Sorunu: Çok sayıda değişken olduğunda performans düşebilir. Düşük Tahmin Gücü: Karmaşık sistemlerde ML yöntemlerine göre genellikle daha düşük tahmin doğruluğu sunar. Aykırı Değerlere Hassasiyet: Bazı yöntemler aykırı verilere karşı hassas olabilir.

Tablo 2.2. Uçuş gecikmesi tahminlemede makine öğrenmesi yöntemlerinin karşılaştırması

Yaklaşım	Avantajlar	Dezavantajlar
Makine Öğrenmesi Yöntemleri	Yüksek Tahmin Doğruluğu: Genellikle daha yüksek tahmin performansı sunar. Karmaşık İlişkileri Yakalama: Doğrusal olmayan ilişkileri ve değişken etkileşimlerini otomatik olarak öğrenebilir. Esneklik: Daha az istatistiksel varsayıma ihtiyaç duyar. Yüksek Boyutlulukla Başa Çıkma: Çok sayıda özellikli etkin bir şekilde çalışabilir. Büyük Veri Uyumu: Büyük hacimli veri setlerini işleyebilir.	Kara Kutu Sorunu: Bazı karmaşık modellerin iç işleyişini ve karar mekanizmasını yorumlamak zordur. Aşırı Öğrenme (Overfitting) Riski: Modelin eğitim verisine aşırı uyum sağlayıp yeni verilerde genelleme yapamaması riski vardır. Veri İhtiyacı: İyi performans için genellikle büyük ve çeşitli veri setlerine ihtiyaç duyar. Hesaplama Maliyeti: Karmaşık modellerin eğitimi yüksek hesaplama gücü gerektirebilir. Parametre Ayarı: Performansı optimize etmek için dikkatli özellik mühendisliği ve hiper parametre ayarı gerektirir.

2.3.1. Geleneksel istatistiksel yöntemler

Uçuş gecikmesi tahminlemede kullanılan ilk nicel yaklaşımlar, büyük ölçüde olasılık teorisi ve ekonometri temelli yöntemlere dayanmaktadır. Bu yöntemler, genellikle verideki ilişkileri tanımlamak için belirli istatistiksel varsayımlar (örneğin, verinin normal dağılımı, değişkenler arası doğrusal ilişki) altında çalışır [26]. Başlıca yöntemler şunlardır:

Regresyon Analizi: Gecikme süresinin (sürekli değişken) tahminlenmesinde sıkça kullanılır. Doğrusal Regresyon, bağımsız değişkenler (örn. uçuş süresi, günün saati) ile gecikme süresi arasındaki doğrusal ilişkiyi modeller [28]. Gecikmenin olup olmayacağını tahmin etmek için ise Lojistik Regresyon gibi genelleştirilmiş doğrusal modeller kullanılabilir. Temel avantajları, katsayılarının yorumlanabilir olmasıdır; ancak karmaşık ve doğrusal olmayan ilişkileri yakalamada yetersiz kalırlar [29].

Zaman Serisi Analizi: Uçuş gecikmelerindeki zamansal örüntüleri ve mevsimselliği modelleyerek gelecekteki gecikmeleri tahmin etmeyi amaçlar. ARIMA

(Özbağımlı Bütünleşik Hareketli Ortalama- AutoRegressive Integrated Moving Average) ve SARIMA (Mevsimsel Özbağımlı Bütünleşik Hareketli Ortalama- Seasonal ARIMA) modelleri gecikme verilerindeki geçmiş değerlere bağımlılığı yakalamak için yaygın olarak kullanılmıştır. Ancak, çok sayıda dışsal faktörü (anlık hava durumu vb.) modele etkin bir şekilde entegre etmekte zorlanabilirler [30].

Kuyruk Teorisi ve Simülasyon Modelleri: Havalimanı operasyonları bir kuyruk sistemi olarak modellenabilir. Kuyruk Teorisi (Queueing Theory), belirli varsayımlar altında sistemdeki bekleme sürelerini (gecikmeleri) analitik olarak hesaplamak için kullanılır [31]. Gerçek operasyonların karmaşıklığı nedeniyle, genellikle Ayrık Olay Simülasyonu (Discrete Event Simulation) gibi stokastik simülasyon modelleri tercih edilir. Simülasyon, sistem düzeyinde analizler ve “eğer-öyleyse” senaryoları için güçlü bir araçtır, ancak modelin kalibrasyonu karmaşık bir süreçtir [32].

Bayes Ağları (Bayesian Networks): Gecikmeyi etkileyen faktörler arasındaki olasılıksal bağımlılıkları bir grafik yapısıyla temsil eder. Belirli kanıtlar ışığında gecikme olasılığını tahmin etmek veya en etkili faktörleri belirlemek için kullanılabilir. Belirsizliği modellemede güçlü olsalar da ağ yapısının tanımlanması uzmanlık gerektirir [33].

Geleneksel istatistiksel yöntemler, özellikle yorumlanabilirlik ve nedensel çıkarım ön planda olduğunda hala değerli araçlardır. Ancak, modern havacılık sistemlerinin karmaşıklığı ve büyük veri çağının getirdiği zorluklar, bu yöntemlerin tahmin doğruluğu açısından sınırlarını ortaya koymakta ve daha esnek makine öğrenmesi yöntemlerine olan ilgiyi artırmaktadır.

2.3.2. Makine öğrenmesi yöntemleri ve uygulamaları

Hesaplama gücündeki son yıllardaki artışla birlikte, makine öğrenmesi (ML) algoritmaları uçuş gecikmesi tahminlemesi alanında baskın bir yaklaşım haline gelmiştir. ML algoritmaları, çok sayıda potansiyel tahmin edici değişkenden oluşan girdi verilerini kullanarak, gelecekteki bir uçuşun gecikme süresini bir regresyon problemi olarak veya gecikme kategorisini bir sınıflandırma problemi olarak tahmin eden bir matematiksel model öğrenirler. Geleneksel yöntemlere kıyasla daha az varsayıma dayanan bu algoritmalar, yüksek boyutlu verilerle etkin bir şekilde çalışabilir ve özellikle doğrusal olmayan karmaşık ilişkileri otomatik olarak yakalayabilirler. Bu özellikleri sayesinde, genellikle daha yüksek tahmin doğruluğu sunabilmektedirler [34, 35].

Regresyon uygulamalarında amaç, gecikme süresini sayısal olarak (dakika cinsinden) tahmin etmektir. Bu alanda yaygın olarak kullanılan ML regresyon algoritmaları arasında yüksek boyutlu veri setlerinde etkili olabilen Destek Vektör Regresyonu (SVR- Support Vector Regression) bulunmaktadır [36]. Karar ağaçları ve topluluk yöntemleri de sıkça tercih edilir; örneğin Rastgele Orman (Random Forest), çok sayıda karar ağacının tahminlerinin ortalamasını alarak çalışan ve aşırı öğrenmeye karşı dirençli bir yöntemdir. Gradyan Artırma Makineleri (Gradient Boosting Machine- GBM) ise ağaçları sıralı bir şekilde, önceki ağaçların hatalarını düzeltecek yönde eğiten güçlü bir yöntem olup, XGBoost, LightGBM (bu çalışmada kullanılan) ve CatBoost gibi popüler uygulamaları mevcuttur [37-39]. Yapay Sinir Ağları (ANN) özellikle Derin Öğrenme (Deep Learning) modelleri ile karmaşık örüntüleri öğrenebilirler ancak genellikle büyük veri setleri gerektirirler [23].


Sınıflandırma uygulamalarında ise amaç bir uçuşun gecikmesini “Zamanında”, “Hafif Gecikme” veya “Yüksek Gecikme” gibi önceden tanımlanmış kategorik sınıflardan birine atamaktır. Bu tür problemlerde sıkça kullanılan ML sınıflandırma algoritmalarından biri, basitliği ve yorumlanabilirliği nedeniyle temel bir sınıflandırıcı olarak kullanılan Lojistik Regresyon'dur [40]. Destek Vektör Makineleri (SVM), farklı sınıfları en iyi şekilde ayıran bir karar sınırı bulmayı amaçlar. Regresyonda olduğu gibi, Karar Ağaçları ve Topluluk Yöntemleri olan Rastgele Orman ve Gradyan Artırma Makineleri (GBM) sınıflandırmada da yüksek performans göstermektedir [37]. Nitekim bu tez çalışmasında da H2O AutoML (Otomatik Makine Öğrenmesi) tarafından da lider model olarak sıklıkla GBM veya onun topluluk versiyonları seçilmiştir. Sezgisel bir algoritma olan K-En Yakın Komşu (K-Nearest Neighbour- KNN), büyük veri setlerinde hesaplama maliyetinin yüksek olabilmesiyle bilinir. Yapay Sinir Ağları (ANN) da sınıflandırma görevleri için başarıyla kullanılmaktadır [40].

Makine öğrenmesi modellerinin başarısının yalnızca algoritma seçimine değil, büyük ölçüde özellik mühendisliğine (feature engineering) de bağlı olduğunu belirtmek önemlidir. Ham veriden anlamlı sayısal özellikler türetmek, model performansını önemli ölçüde artırabilir [41].

2.3.3. Otomatik makine öğrenmesi (AutoML)

Etkili bir ML modeli geliştirmek, geleneksel olarak önemli ölçüde uzmanlık, zaman ve deneme yanılma gerektiren bir süreçtir. Otomatik Makine Öğrenmesi (Automated

Machine Learning- AutoML), makine öğrenmesi modelleri geliştirme sürecinin tamamını veya önemli bir kısmını otomatikleştirmeyi amaçlayan, hızla gelişen bir alandır (Şekil 2.1). AutoML'in temel amacı, ML'in gücünü hem alan uzmanları için daha erişilebilir kılmak hem de deneyimli veri bilimcilerinin verimliliğini artırmaktır [42].



Şekil 2.1. Tipik AutoML iş akışı şeması

Otomatik Makine Öğrenmesi (AutoML) sistemleri, tipik bir makine öğrenmesi (ML) iş akışında bulunan birçok adımı otomatikleştirmek üzere tasarlanmıştır (Şekil 2.1). Bu sistemler, veri ön işleme aşamasında, eksik değerlerin doldurulması (imputation), kategorik özelliklerin “one-hot encoding” (OHE) gibi yöntemlerle kodlanması ve sayısal özelliklerin ölçeklendirilmesi gibi işlemleri otomatik olarak yürütebilir. Özellik mühendisliği ve seçimi konusunda ise, AutoML araçları temel düzeyde otomatik özellik türetme veya seçme yetenekleri sunabilmekle birlikte, bu alan halen önemli ölçüde insan uzmanlığına dayanmaktadır [42].

Model seçimi adımı, AutoML sistemleri, Gradyan Artırma Makineleri (GBM), Rastgele Orman (Random Forest) ve Derin Sinir Ağları (Deep Neural Networks) gibi kütüphanelerinde bulunan çeşitli makine öğrenmesi algoritmalarını otomatik olarak deneyerek karşılaştırır. Ardından, her bir algoritmanın performansını optimize etmek

amacıyla hiper parametre optimizasyonu (HPO) gerçekleştirir; bu süreçte genellikle Izgara Arama (Grid Search), Rastgele Arama (Random Search) veya Bayesçi Optimizasyon (Bayesian Optimization) gibi teknikler kullanılır. Nihai olarak, AutoML sistemleri sıklıkla en iyi performansı gösteren bireysel modellerin tahminlerini birleştiren “stacking” gibi topluluk öğrenmesi (ensemble learning) yöntemlerini kullanarak daha robust(sağlam) bir nihai model oluşturur [42]. Nitekim, bu tez çalışmasının sınıflandırma bölümünde de H2O AutoML tarafından üretilen lider modellerin Yığılmış Topluluklar (Stacked Ensembles) olduğu gözlemlenmiştir.

H2O AutoML, Auto-sklearn ve TPOT gibi çeşitli açık kaynaklı AutoML kütüphaneleri mevcuttur. Bu tezde H2O AutoML, ölçeklenebilirliği, geniş algoritma desteği ve topluluk modelleri oluşturma yeteneği nedeniyle tercih edilmiştir.

Uçuş gecikmesi gibi problemler, en iyi model ve hiper parametrelerin önceden bilinmemesi ve performanstaki küçük iyileştirmelerin operasyonel açıdan önemli faydalar sağlayabilmesi nedeniyle AutoML uygulamaları için uygun adaylardır. Ancak AutoML'in sağladığı kolaylıklara rağmen göz ardı edilmemesi gereken bazı önemli sınırlılıkları da bulunmaktadır. Bunların başında; kapsamlı model arama süreçlerinin gerektirdiği yüksek hesaplama maliyeti gelir. Bir diğer önemli sorun ise AutoML tarafından bulunan en iyi modellerin yorumlanabilirliğinin düşük olabildiği ve “kara kutu” (black box) olarak adlandırılan durumdur; neyse ki SHAP gibi model-agnostik yorumlama teknikleri bu zorluğun üstesinden gelmek için çözümler sunmaktadır. Ayrıca AutoML, model optimizasyonunu büyük ölçüde otomatikleştirse de başarısı tamamen girdinin kalitesine bağlıdır; “çöp girerse çöp çıkar” prensibi burada da geçerlidir ve nihai performansı doğrudan etkileyen, iyi hazırlanmış verilere ihtiyaç duyar. Son olarak, süreçte çok sayıda modelin denenmesi, modelin yalnızca eğitim verisine aşırı uyum sağlama, yani aşırı öğrenme (overfitting) riskini de beraberinde getirir. Bu nedenle elde edilen modelin performansının, mutlaka bu süreçten tamamen ayrılmış bir test seti üzerinde doğrulanması kritik bir öneme sahiptir.

Bu tez çalışmasında, H2O AutoML'in sunduğu avantajlardan (özellikle sınıflandırma probleminde) yararlanılırken, belirtilen bu potansiyel kısıtlamalar da dikkate alınmış; özellikle veri hazırlığına, özellik mühendisliğine ve sonuçların bağımsız bir test seti üzerinde dikkatlice değerlendirilmesine özen gösterilmiştir.

2.4. Tahmin Modellerinde Karşılaşılan Zorluklar

Veri odaklı yaklaşımlar, gecikme tahminlemesinde önemli bir potansiyel sunarken, güvenilir modeller geliştirmek beraberinde çeşitli zorlukları getirmektedir. Bu zorluklar genel olarak veri kaynaklı problemler, modelleme sürecindeki teknik güçlükler ve operasyonel gerçekliklerin modele yansıtılmasındaki karmaşıklıklar olarak sınıflandırılabilir [25].

Veri kaynaklı problemler bu sürecin temelini oluşturur. Öncelikle, havacılık verilerinin farklı kaynaklardan gelmesi sebebiyle veri kalitesi ve eksikliği önemli bir engel teşkil eder; zira eksik veya hatalı kayıtlar, kapsamlı veri temizleme ve ön işleme adımlarını zorunlu kılar. Bunun yanı sıra, modern havacılık sistemlerinin ürettiği devasa veri hacmi ve yüzlerce potansiyel özellikten kaynaklanan yüksek boyutluluk, “boyutluluk laneti” olarak bilinen soruna yol açabilir ve bu noktada etkili özellik seçimi kritik bir rol oynar [43].

Gecikme verilerinin en belirgin sorunlarından biri de veri dengesizliğidir. Zamanında gerçekleşen uçuşların (çoğunluk sınıfı) veri setinin büyük bir kısmını oluşturması, kritik öneme sahip yüksek dereceli gecikmelerin (azınlık sınıfı) ise nadir görülmesi, standart algoritmaların çoğunluk sınıfına yanlı tahminler yapmasına ve azınlık sınıflarını etkin bir şekilde öğrenememesine neden olur [43]. Bu tezde, bu sorunun çözümü için ADASYN (Uyarlanabilir Sentetik Örneklem; Adaptive Synthetic Sampling) [44] ve CTGAN (Koşullu Tablosal Üretken Çekişmeli Ağ; Conditional Tabular Generative Adversarial Network) [45] yöntemleri kullanılmıştır.

Modelleme ve analiz aşamasındaki teknik güçlükler de bir diğer önemli zorluk alanıdır. Gecikmeleri etkileyen faktörler arasındaki ilişkilerin genellikle doğrusal olmaması ve karmaşık etkileşimler içermesi, doğru modelin kurulmasını zorlaştırır. Bu durum, ham verilerin makine öğrenmesi algoritmaları için anlamlı özelliklere dönüştürüldüğü ve alan bilgisi gerektiren özellik mühendisliği sürecinin kritik rolünü pekiştirir. Belirli bir problem için en uygun algoritmayı ve optimal hiper parametreleri seçmek zaman alıcı bir optimizasyon süreci gerektirirken, karmaşık modellerin tahminlerinin arkasındaki nedenleri anlamamanın zor olduğu “kara kutu” problemiyle de mücadele etmek gerekir. Bu noktada SHAP (SHapley Toplamsal Açıklamaları; SHapley Additive exPlanations) [46] gibi yorumlanabilirlik teknikleri devreye girer. Ayrıca, modelin eğitim verisine aşırı uyum sağlayarak yeni verilerde düşük performans

göstermesi olarak bilinen aşırı öğrenme (overfitting) riski, çapraz doğrulama gibi yöntemlerle etkin bir şekilde yönetilmelidir.

Son olarak, modellerin teorik başarısının operasyonel faydaya dönüşmesi de kendi içinde zorluklar barındırır. Birçok operasyonel karar için gecikme tahminlerinin gerçek zamanlı veya yakın gerçek zamanlı olarak sunulması bir gerekliliktir. Geliştirilen modellerin pratik değerini artırmak için, son kullanıcıların kolayca erişebileceği karar destek sistemlerine entegre edilmesi şarttır. Ayrıca, karar vericilerin riskleri daha etkin yönetmelerini sağlamak amacıyla, belirsizlik yönetimi kapsamında nokta tahminler yerine olasılıksal tahminler veya güven aralıkları sunmak büyük önem taşır.

Tüm bu zorlukların farkında olmak ve bunları ele almak için uygun stratejiler geliştirmek, uçuş gecikmesi tahmin modellerinin hem bilimsel geçerliliğini hem de operasyonel faydasını en üst düzeye çıkarmak için elzemdir.

2.4.1. Veri dengesizliği problemi ve çözüm stratejileri

Veri dengesizliği (data imbalance), tahmin edilmeye çalışılan hedef değişkenin farklı sınıflarının veri seti içinde çok farklı frekanslarda temsil edilmesi durumudur.

Uçuş gecikmeleri özelinde bu durum, zamanında veya az gecikmeli uçuşların (çoğunluk sınıfı) veri setinin büyük bölümünü oluşturması, operasyonel açıdan en kritik olan yüksek dereceli gecikmelerin (azınlık sınıfı) ise çok daha nadir görülmesi şeklinde ortaya çıkar [43]. Bu dengesizlik, standart makine öğrenmesi algoritmalarının, genel doğruluğu maksimize etme eğilimleri nedeniyle, azınlık sınıfına ait örüntüleri yeterince öğrenememesine ve bu sınıfı sıklıkla yanlış tahmin etmesine yol açar [43]. Sonuç olarak, modelin genel doğruluk oranı yüksek görünse bile, asıl ilgi odağı olan yüksek gecikme olaylarını tahmin etme başarısı, özellikle Geri Çağırma (Recall) metriği açısından çok düşük kalabilir. Bu problemin üstesinden gelmek için literatürde önerilen stratejiler genellikle veri seviyesi, algoritma seviyesi ve hibrit yaklaşımlar olarak üç ana grupta toplanır [43, 47].

Veri seviyesi yaklaşımları; model eğitilmeden önce veri setinin sınıf dağılımını dengelemeyi amaçlar. Bu yaklaşımlar içinde en yaygın olanı, azınlık sınıfındaki örneklerin sayısını yapay olarak artıran aşırı örnekleme (oversampling) yöntemleridir. Rastgele aşırı örnekleme gibi basit teknikler kopyalama yaptığı için aşırı öğrenmeye yol açabilirken, SMOTE gibi daha gelişmiş teknikler azınlık sınıfı örnekleri arasında interpolasyon yaparak sentetik yeni örnekler üretir [48]. Bu tezin sınıflandırma bacağında

temel dengeleme tekniği olarak kullanılan ADASYN (Adaptive Synthetic Sampling-Uyarlanabilir Sentetik Örneklem) ise, SMOTE'un bir varyantı olarak öğrenilmesi daha zor olan (sınıf sınırlarına yakın) azınlık sınıfı örneklerine odaklanır [44]. Daha modern bir yaklaşım olan ve Üretken Çekişmeli Ağlar (GANs) tabanlı çalışan CTGAN, verinin karmaşık dağılımını öğrenerek yüksek kaliteli ve gerçekçi sentetik tablosal veriler üretebilir [45]; bu yöntem de tezde regresyon problemindeki yüksek gecikme değerlerini artırmak için stratejik olarak uygulanmıştır. Veri seviyesindeki bir diğer yöntem olan eksik örneklem ise çoğunluk sınıfından veri silerek dengeleme yapar ancak değerli bilgilerin kaybolması riski taşır [49].

Algoritma seviyesi yaklaşımları ise, makine öğrenmesi algoritmalarını doğrudan dengesiz veriye daha duyarlı hale getirmeyi hedefler. Bunun en bilinen örneği olan Maliyet Duyarlı Öğrenme (Cost-Sensitive Learning), azınlık sınıfı örneklerinin yanlış sınıflandırılmasına daha yüksek bir maliyet (ceza) atayarak algoritmanın bu kritik hatalardan kaçınmasını teşvik eder. Hibrit yaklaşımlar ise veri ve algoritma seviyesi stratejilerini birleştirerek güçlü çözümler sunar [43, 47].

Bu tez çalışmasında, veri dengesizliği problemine karşı veri seviyesi yaklaşımlarına odaklanılmıştır. Sınıflandırma probleminde ADASYN tekniği temel dengeleme yöntemi olarak kullanılırken, regresyon probleminde ise yüksek gecikme aralığındaki veri yetersizliğini gidermek amacıyla CTGAN ile sentetik veri üretimi gerçekleştirilmiştir. Bu stratejilerin, modelin performansı, özellikle de kritik azınlık sınıflarını tanıma başarısı üzerindeki önemli pozitif etkileri, çalışmanın ilerleyen bölümlerinde detaylıca ortaya konmaktadır.

2.4.2. Özellik mühendisliğinin rolü ve önemi

Özellik mühendisliği (feature engineering), ham verilerden yola çıkarak, probleme özgü alan bilgisi kullanarak, makine öğrenmesi algoritmalarının performansını en üst düzeye çıkaracak girdi değişkenlerini (özellikleri) seçme, dönüştürme ve oluşturma sürecidir [41]. “Çöp girerse, çöp çıkar” prensibinin ML'deki karşılığıdır; modele ne kadar anlamlı ve problemle ilgili bilgi sunulursa, modelin öğrenme kapasitesi de o kadar artar. Uçuş gecikmesi gibi karmaşık bir problemde özellik mühendisliğinin önemi daha da belirgindir [1, 40]:

Ham Verinin İşlenmesi: METAR raporlarındaki metin kodları, tarih-saat damgaları gibi ham veriler, ML algoritmaları için doğrudan uygun değildir ve sayısal, yapılandırılmış bir formata dönüştürülmesi gerekir.

Alan Bilgisinin Entegrasyonu: Havacılık ve meteoroloji bilgisi, ham veriden operasyonel açıdan anlamlı özellikler türetmek için kritiktir. Örneğin, ham rüzgâr verisinden ziyade, pist doğrultusuna göre yan rüzgâr (crosswind) ve kafa/kuyruk rüzgârı (headwind/tailwind) bileşenlerinin hesaplanması, etkiyi daha iyi yansıtır.

Örüntülerin Vurgulanması: Zamansal bilgilerin döngüsel özelliklere çevrilmesi veya spesifik hava durumu kodlarının varlığını gösteren ikili (binary) özellikler oluşturmak, modelin örüntüleri daha iyi yakalamasını sağlar.

Kategorik Verilerin Dönüşümü: Kategorik özelliklerin One-Hot Encoding (OHE) gibi yöntemlerle sayısal temsillere dönüştürülmesi gerekir. Bu tezde OHE, sınıflandırma modeli için kullanılırken; regresyon modelinde, LightGBM'in kategorik özellikleri doğrudan işleyebilme yeteneğinden faydalanılmıştır.

Etkileşim Terimleri Oluşturma: Birden fazla özelliğin bir araya gelmesi, tek başlarına olduklarından daha güçlü bir tahmin edicilik sunabilir. Örneğin, “düşük görüş ve yağış” gibi etkileşim terimleri oluşturmak, riskli senaryoları vurgulayabilir.

Boyutluluk Yönetimi: Çok fazla sayıda özellik, modelin karmaşıklığını artırabilir. En bilgilendirici özellikleri seçmek (feature selection) veya mevcut özellikleri daha az sayıda yeni özelliğe dönüştürmek (feature extraction) önemlidir.

Etkili bir özellik mühendisliği süreci, modelin doğruluğunu, genelleme yeteneğini ve hatta yorumlanabilirliğini önemli ölçüde artırabilirken, yetersiz özellik mühendisliği, en gelişmiş ML algoritmasının bile potansiyelinin altında performans göstermesine neden olabilir [41]. Bu çalışmada elde edilen yüksek model performansı, büyük ölçüde uygulanan detaylı ve probleme özgü özellik mühendisliği adımlarının başarısına da bağlıdır.

2.5. Literatür Analizi ve Araştırmanın Konumlandırılması

Bu çalışma meteorolojik koşulların iniş fazındaki gecikmeye olan etkilerini modellemeyi, bu doğrultuda meteorolojik gecikmeleri sınıflandırmayı ve ortalama sürelerini regresyonla tahmin etmeyi hedefler. Bu bölüm, mevcut literatürün bir sentezini sunarak, araştırmanın sorularını, metodolojisini ve özgün katkısını bilimsel bir temele oturtmayı amaçlamaktadır.

2.5.1. Havacılık operasyonlarında meteorolojik koşulların etkileri

Havacılık operasyonlarının verimliliği ve güvenliği, atmosferik koşulların değişkenliğinden önemli ölçüde etkilenmektedir. Literatürde, meteorolojik faktörlerin uçuş gecikmeleri ve iptalleri üzerindeki rolü kapsamlı bir şekilde incelenmiştir.

Oo ve Oo [8], Yangon Uluslararası Havalimanı'nda orajlı yağmur (TSRA) ve sis (FG) gibi olayların operasyonel riskler oluşturduğunu vurgulamıştır. Enea vd. (2024) [50], ABD ve Avrupa havalimanlarını karşılaştırarak konvektif fırtınaların ABD'de, düşük görüş koşulları ve kış yağışlarının ise Avrupa'da daha belirgin kesintilere yol açtığını saptamıştır. Benzer şekilde, Wu, Mei ve Shao (2022) [51] New York havalimanlarında özellikle yağışın, Wang vd. (2022) [52] Pekin Başkent Havalimanı'nda düşük görüş mesafesi ve olumsuz hava koşullarının gecikmeleri artırdığını belirtmiştir. Kim vd. (2023) [53] Kore'deki uçuş iptallerinde şiddetli yağış ve rüzgârın, Bubalo ve Gaggero (2021) [54] ise Avrupa genelinde sis, kar ve orajın çeşitli düzeylerde gecikmelere yol açtığını göstermiştir.

Bu kapsamlı literatür, mevcut tez çalışmasının LTFM gibi büyük bir havacılık merkezinde, detaylı yerel METAR verilerini (bulut katmanları, RVR, yağış türleri, fırtına varlığı, rüzgâr bileşenleri vb.) kullanarak meteorolojik etkileri modelleme çabasının gerekliliğini ve özgünlüğünü ortaya koymaktadır. Literatürdeki pek çok çalışma, tekil faktörlerden ziyade, meteorolojik unsurların birleşik etkilerinin operasyonel sonuçlar doğurduğuna işaret etmektedir. Bu doğrultuda, bu tezde çeşitli meteorolojik parametrelerin etkileşimlerini dikkate alan bir özellik mühendisliği yaklaşımı benimsenerek, literatürdeki bu boşluğu dolduracak daha gerçekçi modeller geliştirilmesi hedeflenmiştir.

2.5.2. Uçuş gecikmesi tahmini uygulamaları ve veri denge stratejileri

Uçuş gecikmelerinin tahmini, içerdiği karmaşık ve doğrusal olmayan ilişkiler nedeniyle makine öğrenmesi (ML) tekniklerinin etkin olarak kullanıldığı bir alandır.

Bu tezde, gecikme sınıflandırması ve regresyon problemleri için literatürde etkinliği kanıtlanmış ML yöntemleri ve veri işleme stratejileri benimsenmiştir. Özellikle Gradyan Artırma Makineleri (GBM) ve XGBoost, LightGBM gibi gelişmiş varyantları, uçuş gecikmesi tahmininde üstün performanslarıyla öne çıkmaktadır. Khan vd. (2022) bu yöntemlerin standart karar ağaçlarına göre çok daha iyi sonuçlar verdiğini [55], Mamdouh vd. (2023) LightGBM ile isabet oranı yüksek tahminler yapabilen bir model önerdiğini,

Deng vd. (2023) [57] terminal alanı sıklığı belirlemede LightGBM'in diğer ML algoritmalarına kıyasla yüksek performans sunduğunu, Zhao vd. (2022) [58] transit uçuş gecikmeleri için CatBoost ve LightGBM'i başarıyla kullandığını ve Wang vd. (2022) [20] stratejik gecikme dağılımı tahmininde LightGBM'in iyi performans sergilediğini göstermiştir.

Bu bulgular ışığında, çalışmanın regresyon bacağına LightGBM'in seçilmesi, büyük veri kümelerindeki hızı, düşük bellek tüketimi ve yüksek doğruluk potansiyeli gibi avantajları nedeniyle literatürle uyumludur.

Sınıflandırma problemlerinde ise Otomatik Makine Öğrenmesi (AutoML) platformları, model geliştirme sürecini otomatikleştirmekte ve optimize etmektedir. LeDell ve Poirier (2020) [59], H2O AutoML'in çeşitli algoritmaları etkin bir şekilde eğitip yığılmış topluluklarda (stacked ensembles) birleştirerek daha iyi sonuçlar ürettiğini, Khan vd. (2023) [60] ağ saldırı tespiti için H2O AutoML kullanarak optimal sınıflandırıcılar seçtiğini, Schwarz (2022) [61] ABD uçuş gecikmeleri tahmininde yığınlama topluluğunun bireysel modellerden üstün olduğunu ve Celik ve Vanschoren (2021) [62] AutoML'in dinamik ortamlardaki adaptasyon potansiyelini vurgulamıştır.

Bu çalışmada, gecikmelerin düşük, orta ve yüksek olarak sınıflandırılması için H2O AutoML platformunun kullanılması, bu eğilimlerle örtüşmekte olup, platformun lider model olarak bir GBM seçmesi ve yüksek sınıflandırma doğruluğu elde etmesi, etkinliğini teyit etmektedir.

Makine öğrenmesi modellerinin, özellikle de dengesiz veri setlerinde veya nadir olayların tahmininde performansını artırmak için veri ön işleme ve artırma teknikleri kritik öneme sahiptir. Bu tezde, iki temel strateji kullanılmıştır: ADASYN (Adaptive Synthetic Sampling), He vd. (2008) [44] tarafından önerilen ve öğrenilmesi zor azınlık sınıfı örneklerine odaklanarak sentetik veri üreten SMOTE tabanlı bir aşırı örnekleme tekniğidir. Etkinliği, Teji vd. (2022) [63] tarafından tıbbi verilerde, Chen vd. (2024) [64] tarafından kanser teşhisinde SMOTE'a kıyasla üstünlüğüyle, Assegie vd. (2024) [65] tarafından meme kanseri teşhisinde ve Wadhwa vd. (2025) [66] tarafından çeşitli dengesiz veri setlerinde kanıtlanmıştır. Bu tezde, ADASYN'in sınıflandırma probleminde temel veri dengeleme yöntemi olarak seçilmesi, literatürdeki bu başarılı uygulamalarla uyumludur ve özellikle kritik azınlık sınıfları için yüksek geri çağırma oranları elde edilmesini sağlamıştır.

Regresyon problemlerinde nadir görülen yüksek gecikme sürelerinin yetersiz temsili sorununa yönelik olarak ise CTGAN (Conditional Tabular GAN) kullanılmıştır. Xu vd. (2019) [67] tarafından önerilen bu yöntem, karmaşık tablosal verilerin istatistiksel özelliklerini koruyarak yüksek kaliteli sentetik örnekler üretir. Agarwal vd. (2024) [68] siber saldırı tespitinde, Parise vd. (2025) [45] küçük tıbbi veri setlerinde, Habibi vd. (2023) [69] IoT bot net saldırı tespitinde CTGAN'ın genelleme yeteneğini ve sentetik veri kalitesini artırdığını göstermiştir. Engelman ve Lessmann (2021) kredi skorlamasında GAN tabanlı yöntemlerin potansiyelini tartışırken, Wang, A. X. vd. (2024) küçük veri setlerinde SMOTE ve ADASYN'in hızlı olabileceğini ancak CTGAN'ın karmaşık dağılımları öğrenme potansiyeli sunduğunu belirtmiştir [70, 71]. Bu tezde, CTGAN ile nadir yüksek gecikme değerlerini temsil eden sentetik örnekler üretilmesi, modelin bu kritik aralıklardaki tahmin performansını iyileştirme amacına hizmet etmektedir.

2.5.3. Araştırmanın konumlandırılması

Gerçekleştirilen kapsamlı literatür taraması, bu tez çalışmasının teorik ve metodolojik çerçevesini desteklemektedir. Mevcut araştırma, literatürdeki belirlenmiş boşluklara yanıt vermeyi ve bu bağlamda alana özgün katkılar sağlamayı hedeflemektedir:

Meteorolojik Raporlama Aralıkları Temelli Analiz Birimi: Bu tez, bireysel uçuş kayıtları yerine, meteorolojik koşulların etkisini daha bütüncül yansıtmak amacıyla standart meteorolojik raporlama zaman aralıklarını (METAR periyotları) temel analiz birimi olarak kullanmaktadır. Bu yaklaşım, belirli bir meteorolojik durumun o zaman dilimindeki genel operasyonel etki düzeyini tahmin etmeyi amaçlayarak literatürdeki yaygın bireysel uçuş bazlı yaklaşımlardan farklılaşmaktadır.

Bütüncül ve Gelişmiş Metodolojik Çerçeve: Tez, hem regresyon (örneğin, LightGBM + CTGAN gibi teknikler kullanılarak) hem de sınıflandırma (örneğin, H2O AutoML + ADASYN gibi teknikler kullanılarak) problemlerini eş zamanlı olarak ele almaktadır. Özellikle, CTGAN gibi üretken modellerin regresyon performansına etkisinin ve H2O AutoML gibi otomatik makine öğrenmesi araçlarının dengesiz ve çok sınıflı bir problemdeki etkinliğinin, ADASYN gibi veri dengesizliğiyle mücadele teknikleriyle birleştirilerek incelenmesi, metodolojik bir özgünlük sunmaktadır.

Değişken Operasyonel Koşullar Üzerinde Analiz: Çalışmada kullanılan veri setinin, bir havacılık sisteminin faaliyete geçiş veya önemli değişim dönemlerini

(örneğin, COVID-19 pandemisi gibi küresel etkiler) kapsamı, gerçek dünya koşullarını yansıtan ve standart olmayan veri dinamiklerine sahip bir ortamda analiz yapma imkânı sunmaktadır. Bu “ideal olmayan” koşullardan kaynaklanan zorlukların, CTGAN ve ADASYN gibi veri artırma ve dengeleme teknikleriyle aktif olarak ele alınması, bu tezin önemli bir yönünü oluşturmaktadır.

Model Yorumlanabilirliğine Verilen Önem: Yüksek performanslı modeller geliştirmek kadar, bu modellerin “kara kutu” olmaktan çıkarılarak anlaşılır hale getirilmesi de kritik öneme sahiptir. Bu tezde hem regresyon hem de sınıflandırma modelleri için SHAP analizlerinin kapsamlı bir şekilde kullanılması ve özellikle meteorolojik faktörlerin etkilerinin detaylı olarak ortaya konulması, model yorumlanabilirliğine verilen önemi göstermektedir.

Sonuç olarak bu tez, literatürde iyi tanımlanmış bir problemi, önemli bir havacılık operasyonel ortamını vaka çalışması olarak ele alarak, en güncel veri bilimi araçları ve özgün metodolojik kombinasyonlarla incelemektedir. Seçilen yöntemler literatürdeki başarılı uygulamalarla desteklenmekte olup, bu yöntemlerin belirli operasyonel bağlamlarda yenilikçi bir şekilde bir araya getirilerek uygulanması, hava trafik yönetimi ve havacılık operasyonları alanındaki bilgi birikimine özgün bir katkı sunma potansiyeline sahiptir.

3. VERİ SETİ VE YÖNTEM

Bu bölümde, havacılık operasyonlarında özellikle iniş süreçlerinde gözlemlenen gecikmelerin meteorolojik faktörlerle olan ilişkisini modellemek amacıyla yürütülen araştırmanın yöntemsel temelleri sunulmaktadır. Önceki bölümlerde tartışılan teorik çerçeve ışığında, bu bölüm çalışmanın nicel analizlerine odaklanmaktadır. Bir bilimsel araştırmanın sonuçlarının güvenilirliği ve geçerliliği, büyük ölçüde kullanılan verinin kalitesine, uygulanan analitik yöntemlerin uygunluğuna ve süreçlerin şeffaflığına bağlıdır. Bu nedenle, bu bölümde öncelikle araştırmanın yanıtlamayı hedeflediği temel sorular netleştirilecek, ardından araştırmanın belkemiğini oluşturan veri kaynakları, veri entegrasyon süreçleri ve nihai analiz veri setinin yapısı açıklanacaktır.

3.1. Araştırmanın Soruları

Bu araştırmanın temel amacı, belirli bir havacılık operasyonel ortamında, yerel meteorolojik koşullardan kaynaklanan iniş gecikmelerinin öngörülebilirliğini ve bu öngörülebilirliği tayin eden ana faktörleri saptamaktır. Bu doğrultuda, veri toplama, ön işleme, özellik mühendisliği ve model geliştirme süreçleri, aşağıda sıralanan temel araştırma sorularına bilimsel ve ampirik yanıtlar üretmek üzere kurgulanmıştır:

- Belirli bir havalimanı için temin edilen anlık METAR verileri ve bu verilerden türetilen meteorolojik öznitelikler aracılığıyla, belirli bir METAR raporlama periyodundaki ortalama ve ilgili bir operasyonel gecikme göstergesi (örneğin, Terminal Kontrol Sahası [TMA] transit gecikmeleri) ne ölçüde istatistiksel güvenilirlikle tahmin edilebilir (regresyon analizi kapsamında)?
- Aynı meteorolojik veri seti kullanılarak, iniş operasyonlarındaki gecikmeler, operasyonel açıdan anlamlı ve önceden tanımlanmış kategorilere (örneğin, Düşük, Orta, Yüksek Gecikme) ne düzeyde bir sınıflandırma başarısıyla atanabilir?
- İncelenen iniş gecikmeleri üzerinde istatistiksel olarak en baskın etkiye sahip olan spesifik METAR değişkenleri (örneğin, Pist Görüş Mesafesi [RVR], rüzgâr parametreleri, bulut tavanı) ve bunlardan türetilen özellikler (örneğin, rüzgârın pist doğrultusundaki ve çapraz bileşenleri, değişkenler arası etkileşim terimleri) hangileridir? Bu değişkenlerin, geliştirilen tahmin modellerindeki göreceli önem dereceleri nasıl bir dağılım göstermektedir?
- Gecikme veri setlerinde sıkça karşılaşılan sınıf dengesizliği olgusu ve nadir olayların temsiliyeti, geliştirilen modellerin genel performansını ve bilhassa operasyonel açıdan

kritik öneme haiz yüksek gecikme vakalarını tespit etme kabiliyetini ne yönde etkilemektedir?

- ADASYN gibi sentetik veri dengeleme yaklaşımlarının uygulanması, sınıflandırma modelinin performansını (özellikle F1-Skoru ve Geri Çağırma [Recall] gibi metrikler üzerinden) ve kritik azınlık sınıflarını doğru tanımlama yeteneğini hangi oranda iyileştirmektedir?
- CTGAN gibi ileri seviye sentetik veri üretimi teknikleri, regresyon modelinin özellikle seyrek gözlemlenen yüksek gecikme aralıklarındaki tahmin doğruluğunu (R^2 ve aralık bazlı Ortalama Mutlak Hata [MAE]/Kök Ortalama Kare Hata [RMSE] metrikleriyle değerlendirildiğinde) ne ölçüde artırma potansiyeline sahiptir?
- Geliştirilen regresyon (örneğin, LightGBM) ve sınıflandırma (örneğin, H2O AutoML ile optimize edilen Gradyan Artırma Makineleri [GBM]) modellerinin elde ettiği performans metrikleri, operasyonel bir perspektiften değerlendirildiğinde, pratik kullanıma elverişli bir öngörü kapasitesi sunmakta mıdır?
- Araştırmanın gerçekleştirildiği spesifik operasyonel dönemin (örneğin, küresel salgın etkileri veya yeni bir operasyonel sistemin başlangıç fazı gibi) kendine has koşulları altında geliştirilen modellerden elde edilen bulguların, gelecekteki “standart” veya “normalleşmiş” operasyonel şartlar altında ne derecede bir genellenebilirlik ve geçerlilik taşıması beklenir?

Bu araştırma sorularına getirilecek kapsamlı yanıtların, hem incelenen operasyonel bağlam özelinde meteorolojik gecikme dinamiklerinin daha derinlemesine kavranmasına katkı sağlaması hem de genel olarak makine öğrenmesi tabanlı öngörü modellerinin havacılık operasyonlarındaki stratejik ve etkin uygulamalarına yönelik değerli içgörüler sunması hedeflenmektedir.


3.2. İstanbul Havalimanı (LTFM): Altyapı ve Operasyonel Bağlam

Bu bölümde, iniş operasyonlarında gözlemlenen gecikmelerin meteorolojik faktörlerle ilişkisini modellemek amacıyla yürütülen araştırmanın yöntemsel bağlamını oluşturan İstanbul Havalimanı (ICAO: LTFM) özellikleri sunulmaktadır.

Havalimanının operasyonel verimliliği ve kapasitesi, modern altyapısının ve tanımlanmış prosedürlerin etkin ve emniyetli kullanımına doğrudan bağlıdır. Bu nedenle, LTFM'nin temel fiziksel özellikleri, pist sistemleri, hava sahası yapısı, standart varış ile yaklaşma prosedürleri ve iniş destek sistemleri, Türkiye Havacılık Bilgi Yayını (AIP)

[72] ve ilgili diğer resmi kaynaklar temel alınarak incelenmiştir. Bu özelliklerin anlaşılması, meteorolojik faktörlerin LTFM operasyonları üzerindeki potansiyel etkilerini doğru değerlendirebilmek için kritik bir zemin teşkil etmektedir.

Karadeniz kıyısına yakın konumlanan LTFM, deniz seviyesinden yaklaşık 99 metre yükseklikte yer alır [72]. Operasyonel esnekliği ve kapasiteyi maksimize etmek üzere tasarlanan havalimanı, veri toplama dönemi itibarıyla birbirine paralel ve bağımsız operasyonlara imkân tanıyan beş adet piste sahiptir. Yüksek mukavemetli asfalt yüzeyli bu pistler en büyük geniş gövdeli uçakların operasyonuna uygundur [72]. Pistlerin paralel yerleşimi, normal hava koşullarında bağımsız paralel yaklaşımlara olanak tanıyarak yüksek bir saatlik kabul kapasitesi (AAR) sağlar (Şekil 3.1).




Şekil 3.1. İstanbul havalimanı pist yerleşim krokisi

LTFM'ye yapılan iniş ve kalkışlar, çeşitli sektörlerle ayrılmış İstanbul Terminal Kontrol Sahası (TMA İstanbul) içerisinde yönetilir; Geçiş İrtifası (Transition Altitude) 10,000 feet MSL olarak belirlenmiştir. IFR trafikler, genellikle Performansa Dayalı Seyrüsefer (PBN) konseptine uygun, RNAV tabanlı Standart Terminal Varış Rotalarını

İstanbul Havalimanı (LTFM), operasyonel başlangıcından itibaren sergilediği ekspansiyonel büyüme ile Avrupa'nın yolcu ve uçak trafiği bakımından en yoğun havalimanları arasında baskın bir konuma erişmiştir [http-1]. Kıta Avrupa'sının en işlek havalimanı unvanını elde eden ve 2024 yılı itibarıyla günlük ortalama 1400 civarında trafik hacmine hizmet veren LTFM [http-1], Asya, Avrupa ve Afrika kıtaları arasında stratejik bir kıtalar arası aktarma merkezi (hub) işlevi görmektedir. Yüzlerce varış noktasına sunduğu direkt uçuş imkanlarıyla küresel hava seyrüsefer ağının vazgeçilmez bir düğüm noktasını teşkil etmektedir [http-2]. Bu ölçekte bir operasyonel yoğunluk ve jeostratejik önem, havalimanı performansının optimizasyonunu ve sürdürülebilirliğini zorunlu kılmaktadır.

Bu yüksek operasyonel tempoya rağmen, LTFM'ye yönelik varışlarda dikkate değer gecikmelerin yaşandığı gözlemlenmektedir. Şubat 2023 – Şubat 2025 periyodunu kapsayan veriler, LTFM'ye varan uçuşların yaklaşık %44'ünün tarifeli varış saatine (STA) kıyasla 5 dakika veya daha fazla gecikme yaşadığını ortaya koymaktadır [73]. Bu genel bulgunun ötesinde, detaylı ATFM (Air Traffic Flow Management) varış gecikmesi verilerinin (Şekil 3.3) incelenmesi, gecikme dinamiklerine dair daha derinlemesine bir anlayış sunmaktadır.



Şekil 3.3. İstanbul Havalimanı (LTFM) ATFM Varış Gecikmelerinin Nedenleri (Şub. 2023- 2025)

Şekil 3.3. grafik verilerine dayalı analiz şunları ortaya koymaktadır:

Hava Durumunun Dominant Etkisi: Analiz edilen periyotta, ortalama ATFM varış gecikmelerinin ana tetikleyicisinin “Hava Durumu” (sarı renk ile temsil edilen) olduğu net bir şekilde görülmektedir. Özellikle 1 Şubat 2023 civarında ortalama

gecikmelerin yaklaşık 25 dakikaya, 29 Eylül 2023 tarihinde ise 35 dakikanın üzerine çıkarak zirve yaptığı gözlemlenmektedir. Benzer şekilde, 16 Kasım 2023 (yaklaşık 15 dakika), 6 Eylül 2024 (yaklaşık 10 dakika) ve 17 Kasım 2024 (yaklaşık 8 dakika) tarihlerinde de hava durumu kaynaklı belirgin gecikme pikleri mevcuttur. Bu durum, LTFM operasyonlarının meteorolojik koşullara karşı yüksek hassasiyetini ve bu faktörün uçuş düzenliliği üzerindeki kritik etkisini vurgulamaktadır.

Diğer Faktörlerin Katkısı: Hava durumu dışındaki faktörler genellikle daha düşük seviyelerde gecikmelere neden olmakla birlikte, kümülatif etkileri ve belirli dönemlerdeki yoğunlukları önemlidir.

ATC Dışı Kapasite: Özellikle 14 Nisan 2023 ve 29 Eylül 2023 tarihlerinde hava durumu kaynaklı büyük gecikmelerin yaşandığı dönemlerde, ATC dışı kapasite sorunlarının da bir miktar katkı sağladığı görülmektedir.

Hava Trafik Kontrol (ATC) Personeli ve ATC Kapasitesi: Bu faktörler genellikle daha küçük ölçekli gecikmelere yol açmakla birlikte, özellikle 29 Eylül 2023'teki zirve gecikme periyodunda ve 23 Ekim 2023 civarında diğer faktörlerle birleşerek genel gecikme süresini artırıcı bir rol oynamışlardır.

Sonuç olarak, LTFM'nin stratejik konumu ve yüksek trafik hacmi göz önüne alındığında, ATFM varış gecikmelerinin, özellikle de hava durumu kaynaklı olanların titizlikle analiz edilmesi ve bu gecikmeleri minimize etmeye yönelik veri odaklı stratejilerin geliştirilmesi, havalimanının operasyonel verimliliğinin ve rekabetçiliğinin sürdürülebilirliği açısından hayati öneme sahiptir. Gecikme nedenlerinin ayrıştırılmış analizi, hedefe yönelik iyileştirme alanlarının belirlenmesinde kritik bir araçtır.

3.3. Araştırma Veri Seti

Bu çalışmanın nicel analizleri yapısı farklı iki temel veri akışının titizlikle birleştirilmesine dayanmaktadır: İstanbul Havalimanı (LTFM) için yüksek zamansal çözünürlüklü meteorolojik gözlem kayıtları ve aynı havalimanına iniş yapan ticari uçuşlara ait operasyonel bilgiler. Bu iki farklı veri setinin başarılı bir şekilde entegre edilmesi, hava trafik operasyonlarını etkileyen meteorolojik faktörler arasındaki karmaşık ilişkileri modelleyebilmek adına kritik bir ön koşuldur.

3.3.1. Veri kaynakları, toplama süreci ve içerik detayları

Araştırmada kullanılan veriler, güvenilirlikleri ulusal ve uluslararası düzeyde kabul görmüş kurumsal kaynaklardan temin edilmiştir. Veri entegrasyonu, çalışmanın

kapsadığı Mart 2019 – Haziran 2022 dönemi için gerçekleştirilmiştir. Bu entegrasyonun temel mantığı, bu bölümün ilerleyen kısımlarında detaylandırılacağı üzere, belirli bir METAR raporlama periyodunu analiz birimi olarak almak ve bu periyot içindeki uçuşların ortalama gecikme bilgilerini, o periyodu temsil eden meteorolojik koşullarla eşleştirmektir.

3.3.1.1. Meteorolojik veriler

LTFM Havalimanı'na ait yer seviyesi anlık hava durumu gözlem verileri, Türkiye'nin ulusal meteoroloji hizmetlerinden sorumlu resmi kurumu olan Meteoroloji Genel Müdürlüğü (MGM) tarafından sağlanmıştır [http-3]. MGM, bu hizmetleri Uluslararası Sivil Havacılık Örgütü (ICAO) Annex 3 [74] ve Dünya Meteoroloji Örgütü (WMO) [74] standartlarına tam uyum içinde sunmaktadır.


Havacılık meteorolojisinde temel raporlama formatı olan METAR, havalimanlarındaki hava koşullarını belirli aralıklarla (LTFM için genellikle her 30 dakikada bir) raporlamak için kullanılan uluslararası bir koddur. Operasyonel açıdan kritik ve ani hava değişiklikleri meydana geldiğinde ise standart raporlama zamanı beklenmeden SPECI adı verilen özel raporlar yayınlanır [75]. Kullanılarda kullanılan MGM veri seti hem düzenli METAR hem de gerektiğinde yayınlanan SPECI raporlarını içermektedir. Bu durum, veri setinin zamansal çözünürlüğünü ve operasyonel değerini artırmaktadır.

Standart METAR/SPECI formatı, uçuş operasyonları için hayati öneme sahip birçok parametreyi kodlanmış bir metin yapısında sunar. Bu çalışmada ham METAR metinlerinden ayrıştırılan (parse edilen) temel parametreler arasında öncelikle raporun yayınlandığı tam tarih ve saat (UTC) bilgisini içeren zaman bilgisi bulunmaktadır. Ayrıca, ortalama yön, hız ve maksimum hamleyi (gust) kapsayan rüzgâr verileri; hâkim yatay görüş (Şekil 3.4), minimum görüş ve Pist Görüş Mesafesini (RVR) içeren görüş mesafesi bilgileri; farklı katmanlardaki bulut kapalılık miktarını, taban yüksekliğini ve önemli bulut tiplerini (Şekil 3.5) tanımlayan bulutlar ile ilgili veriler; WMO kodlama sistemine göre çeşitli atmosferik olayları (örneğin RA-Yağmur, SN-Kar, FG-Sis, TS-Oraj) belirten mevcut hava hadiseleri ve son olarak hava sıcaklığı, işba noktası ile deniz seviyesi basıncını (QNH) içeren sıcaklık ve basınç bilgileri yer almaktadır. Ham, kodlanmış METAR metinlerinin modelleme için kullanılabilir hale getirilmesi, standart kod çözme kurallarına dayalı olarak, bu amaç için geliştirilmiş programlama

kütüphaneleri kullanılarak dikkatlice gerçekleştirilen bir ayrıştırma (parsing) işlemi gerektirmiştir.



Şekil 3.4. Hâkim yatay görüş mesafesi değerlerinin veri setindeki dağılımı



Şekil 3.5. Veri setindeki en düşük tavan oluşturan bulutların tür dağılımı

Bu sürecin daha net anlaşılması için, çalışmada kullanılan ham bir METAR raporu metni ve bu metinden Özellik Mühendisliği algoritması aracılığıyla ayrıştırılarak model için kullanılabilir hale getirilen temel parametreler aşağıda örneklendirilmiştir:

Örnek ham METAR Raporu: LTFM 160950Z 01010KT 350V040 4000 -RA BR SCT005 BKN010 OVC020 04/04 Q1017 RESHRA NOSIG

3.3.1.2. Operasyonel Uçuş Verileri

LTFM'ye iniş yapan ticari uçuşlara ait operasyonel detayları içeren veri seti, Avrupa hava sahasındaki hava trafik akışını yöneten merkezi kuruluş olan EUROCONTROL'den temin edilmiştir. Sağlanan veriler, EUROCONTROL'ün Ağ Yöneticisi (Network Manager- NM) operasyonel sistemlerinden türetilen ve genellikle Araştırma ve Geliştirme (Ar-Ge) faaliyetlerini desteklemek amacıyla sunulan arşivlenmiş veri setleridir [http-4].

Veriler, EUROCONTROL'ün akademik kurumlar için geçerli olan standart Ar-Ge veri paylaşım prosedürleri kapsamında resmi olarak talep edilerek elde edilmiştir. Kurum tarafından sağlanan meta veri dokümanı, kullanılan veri setlerinin detaylı yapısını, içerdiği alanların tanımlarını ve kullanım koşullarını açıklamaktadır. Bu koşullar tipik olarak, verinin yalnızca belirtilen akademik projede kullanılmasını, sonuçların anonimleştirilerek yayınlanmasını ve veri kaynağının açıkça belirtilmesini içermektedir [http-4].

Kullanılan Temel Alanlar ve Gecikme Hesaplaması: EUROCONTROL veri setinden, analizler için özellikle aşağıdaki temel bilgiler kullanılmıştır:

- Uçuş Tanımlama Bilgileri: Her uçuşa atanan benzersiz tanımlayıcı numara (ECTL_ID), kalkış (ADEP) ve varış (ADES) meydan kodları,
- Zaman Bilgileri: Uçağın TMA'ya (Terminal Kontrol Sahası) planlanan (Entry_Time_Filed) ve gerçekleşen (Entry_Time_Actual) giriş zamanları ile TMA'dan planlanan (Exit_Time_Filed) ve gerçekleşen (Exit_Time_Actual) çıkış zamanları.

Bu çalışmada, iniş gecikmesinin (hedef değişken Average Delay (minutes)) hesaplanmasında temel olarak, uçağın havalimanı ve yakın çevresindeki koşullardan ne kadar etkilendiğini yansıtmaya amacıyla, gerçekleşen ve planlanan İstanbul (LTFM) TMA geçiş süreleri arasındaki farklar kullanılmıştır. Bu yaklaşım, özellikle havalimanı ve yakın çevresindeki (TMA) hava durumu, pist konfigürasyonu, trafik yoğunluğu gibi faktörlerden kaynaklanan gecikme bileşenini daha iyi izole etmeye olanak tanır.

Bu verilerin pratikte nasıl görüldüğünü ve gecikme hesabında nasıl kullanıldığını göstermek için basitleştirilmiş bir örnek aşağıda sunulmuştur:

Örnek Operasyonel Uçuş Kaydı:

ECTL_ID: 1234567

ADEP (Kalkış Havalimanı): EDDF

ADES (Varış Havalimanı): LTFM

Entry_Time_Filed (LTFMTMA): 14:30:00

Entry_Time_Actual (LTFMTMA): 14:32:00

Exit_Time_Filed (LTFMTMA): 14:45:00

Exit_Time_Actual (LTFMTMA): 14:52:00

Bu örnekte uçağın TMA'ya planlanan giriş saati 14:30 iken gerçekleşen giriş 14:32'dir. Planlanan çıkış 14:45 iken gerçekleşen çıkış 14:52'dir. Uçağın TMA içindeki planlanan geçiş süresi 15 dakika (14:45- 14:30) iken, gerçekleşen geçiş süresi 20 dakikadır (14:52 - 14:32). Bu durumda, bu tekil uçuş için TMA transit gecikmesi 5 dakika olarak hesaplanır. Analiz veri setindeki hedef değişken, ilgili METAR veya yayımlanmışsa SPECI periyodundaki tüm geciken tekil uçuşların ortalama gecikme süresidir.

3.3.2. Zaman aralığı ve bağlamsal faktörlerin önemi

Birleştirilmiş veri setinin kapsadığı Mart 2019 – Haziran 2022 dönemi, analiz sonuçlarının yorumlanması açısından dikkate alınması gereken önemli bağlamsal faktörler içermektedir:

LTFM Operasyonel Başlangıç (Ramp-up) Dönemi: İstanbul Havalimanı (LTFM), Nisan 2019'da tam kapasiteyle operasyonlara başlamıştır [http-5]. Veri setinin ilk yılı, yeni altyapı ve prosedürlerin tam anlamıyla oturduğu bir “adaptasyon” dönemi olarak kabul edilebilir. Bu başlangıç dönemindeki gecikme paternleri, operasyonların daha stabil hale geldiği sonraki dönemlerden farklılık gösterebilir.

COVID-19 Pandemisinin Etkisi: 2020 yılı başından itibaren veri setinin önemli bir bölümünü etkileyen COVID-19 salgını, küresel hava trafiğinde ve dolayısıyla LTFM özelinde de benzeri görülmemiş bir azalmaya yol açmıştır [75-77]. Hava trafiğindeki bu dramatik düşüş, normal operasyonlarda sıkça görülen sıkışıklık (congestion) kaynaklı gecikmeleri büyük ölçüde ortadan kaldırmıştır. Bu durumun oluşturduğu etki sayesinde diğer gecikme nedenlerinin, özellikle bu çalışmanın odağında olan meteorolojik faktörlerin, toplam gecikme içindeki göreceli etkisinin daha belirgin hale gelmiş olması beklenebilir. Bu durum, çalışma için potansiyel bir analitik avantaj sunar. Diğer yandan, düşük trafik hacmi, özellikle ekstrem hava koşulları altındaki operasyonlara dair gözlem sayısını ve çok yüksek gecikme değerleri gibi nadir olayların veri setindeki frekansını önemli ölçüde azaltmıştır. Bu durum, makine öğrenmesi modellerinin bu nadir olayları yeterince öğrenmesini zorlaştırarak veri dengesizliği sorununu şiddetlendirebilir. Bu

nedenle, bu dönemdeki verilerle çalışırken, ADASYN, SMOTE veya CTGAN gibi dengesiz veri setleriyle başa çıkma tekniklerinin kullanımının önemi daha da artmaktadır.


Bu dönemsal ve bağlamsal faktörlerin farkında olmak, geliştirilen modellerin performansını değerlendirirken ve elde edilen sonuçların genellenebilirliğini tartışırken kritik bir öneme sahiptir.

3.4. Veri Setinin Yapısı, Ön İşlenmesi ve Özellik Mühendisliği

MGM ve EUROCONTROL veri kaynakları, dikkatli bir birleştirme ve ön işleme sürecinin ardından çalışmanın ana analiz veri setini oluşturmak üzere entegre edilmiştir. Bu çalışmada ayırt edici bir yaklaşım olarak, analiz birimi (unit of analysis) tekil uçuşlar yerine, belirli bir METAR raporunun geçerli olduğu zaman dilimi (genellikle 30 dakikalık bir pencere) olarak tanımlanmıştır. Buna göre, veri setindeki her bir satır; ilgili METAR zaman aralığında LTFM'ye iniş yapmış ve 3 dakikadan fazla gecikme yaşamış uçuşların ortalama gecikme süresini (hedef değişken) ve o zaman dilimindeki hâkim meteorolojik koşulları temsil etmektedir. Bu yaklaşım, analizin odağını doğrudan meteorolojik periyotlar ve bu periyotlardaki genel gecikme seviyesi üzerine kaydırarak, hava durumunun kümülatif etkisini modellemeyi amaçlamaktadır. Mart 2019 – Haziran 2022 dönemini kapsayan ve yaklaşık 774 gözlemden oluşan nihai veri seti, sayısal, kategorik ve döngüsel nitelikte değişkenler içermektedir.

Veri modellemeye geçmeden önce, değişken dağılımlarını, aralarındaki ilişkileri, aykırı değerleri ve eksik veri yapısını anlamak amacıyla kapsamlı bir Keşifsel Veri Analizi (Exploratory Data Analysis- EDA) yürütülmüştür. EDA sürecinde, regresyon modelinin hedef değişkeni olan Ortalama Gecikme (Dakika)- Average Delay (minutes) değerinin sağa çarpık bir dağılım sergilediği gözlemlenmiştir (Şekil 3.6).

Bu bulgu, hava trafik gecikmelerinin doğasıyla (çoğunlukla kısa süreli, nadiren çok uzun süreli gecikmeler) uyumlu olup, modelleme aşamasında hedef değişken üzerinde logaritmik dönüşüm uygulama kararını desteklemiştir.



Şekil 3.6. Analiz veri setindeki ortalama gecikme süresinin frekans dağılımı

3.4.1. Özellik mühendisliği

Makine öğrenmesi modellerinin performansını artırmak amacıyla, ham verilerden probleme özgü ve anlamlı yeni özellikler türetilmiştir. Bu süreç, havacılık meteorolojisi alan bilgisi ve EDA bulgularıyla şekillendirilmiştir.


Ham METAR verisindeki rüzgâr yönü ve hızı, LTFM pist doğrultuları (180° , 360° , 170° , 350° değerleri) dikkate alınarak, operasyonel açıdan daha anlamlı olan kafa/kuyruk rüzgârı (headwind/tailwind) ve yan rüzgâr (crosswind) bileşenlerine dönüştürülmüştür. Uygulanan fonksiyon, o anki rüzgâr koşullarında operasyonel olarak en avantajlı pistin hangisi olabileceğini varsayarak, en yüksek pozitif karşı rüzgârı ve buna karşılık gelen yan rüzgârı hesaplar. Bu yeni özellikler, rüzgârın operasyonel etkisini daha doğrudan yansıtmayı amaçlamaktadır.

3.4.1.1. Kategorik özelliklerin oluşturulması

Ham sayısal meteorolojik verilerin, havacılık operasyonları ve uçuş emniyeti açısından doğrudan yorumlanabilirliği sınırlı olabilmektedir. Bu nedenle, modelin anlam çıkarma kapasitesini artırmak ve karar destek süreçlerine daha uygun girdiler sağlamak amacıyla, sürekli (continuous) formdaki temel meteorolojik parametreler, alan uzmanlığına ve yerleşik havacılık pratiklerine dayanılarak anlamlı, kesikli (discrete) kategorilere dönüştürülmüştür. Bu dönüşüm süreci, özellikle operasyonel limitler ve

IFR/VFR (Aletli/Görerek Uçuş Kuralları) gibi düzenleyici çerçevelerle uyumlu bir temsil sağlamayı hedeflemiştir.

Görüş mesafesinin kategorilere ayrılması: Sürekli bir değişken olan yatay görüş mesafesi (visibility), metre cinsinden ölçülen değerleri üzerinden, operasyonel etki derecelerini yansıtan beş sıralı (ordinal) kategoriye ayrıştırılmıştır. Bu kategoriler, örneğin “Çok İyi” ($>10.000\text{m}$), “İyi” ($5.001-10.000\text{m}$), “Orta” ($1.501-5.000\text{m}$), “Kötü” ($501-1.500\text{m}$) ve “Çok Kötü” ($\leq 500\text{m}$) şeklinde tanımlanmıştır. Bu granüler ayırım, özellikle Düşük Görüş Prosedürleri (LVP- Low Visibility Procedures) gibi kritik operasyonel eşiklerin potansiyel aktivasyonunu ve bununla ilişkili risk düzeylerini modelin daha etkin bir biçimde algılamasına olanak tanımaktadır. Kategorilerin sıralı yapısı, görüş koşullarının kötüleşmesiyle artan riskin monotonik ilişkisini de korumaktadır (Şekil 3.7).




Şekil 3.7. Görüş mesafe kategorisinin veri setindeki dağılımı

Bulut taban yüksekliğinin kategorilere ayrılması: Uçuş operasyonlarında belirleyici bir faktör olan bulut taban yükseklikleri (cloud base height), feet (ft) cinsinden raporlanan değerler kullanılarak dört temel kategoriye atanmıştır: “Bulut Yok” (SKC/CLR veya raporlanmış bir taban olmaması durumu), “Alçak Bulutlar” ($<2000\text{ ft AGL}$ - Yer Seviyesinden Yükseklik), “Orta Seviye Bulutlar” ($2000-6499\text{ ft AGL}$) ve “Yüksek Seviye Bulutlar” ($\geq 6500\text{ ft AGL}$). Bu sınıflandırma, havacılıkta “tavan”

(ceiling) olarak adlandırılan ve özellikle Aletli Uçuş Kuralları (IFR) kapsamında tanımlanan minimum meteorolojik koşulları (minima) doğrudan etkileyen en alçak bulut tabakasının yüksekliğini modellemeye yardımcı olur. “Alçak Bulutlar” kategorisi, operasyonel kısıtlamaların en sık yaşandığı senaryoları temsil etmesi açısından özel bir öneme sahiptir.

Hava Olayı Gruplarının Oluşturulması: METAR (Meteorological Aerodrome Report) raporlarında yer alan çok çeşitli ve spesifik hava durumu kodları (örn. SHRA: Sağanak Yağmur, BCFG: Parçalı Sis, HZ: Toz Pusu, BLDU: Savrulan Toz, TSSN: Orajlı Kar), bireysel olarak yüksek boyutluluk ve seyrekliğe (sparsity) yol açabileceğinden, operasyonel etkileri ve fenomenolojik benzerlikleri temel alınarak daha genel ve yorumlanabilir gruplara indirgenmiştir. Bu kapsamlı yeniden gruplandırma ve birleştirme işlemi neticesinde, ilgili hava olayının varlığını (1) veya yokluğunu (0) belirten yeni ikili (binary) özellikler türetilmiştir. Bu binarizasyon (ikilileştirme) stratejisi kapsamında, örneğin, yağmur (RA), çisenti (DZ) ve sağanak yağmur (SHRA) gibi sıvı formdaki çeşitli presipitasyon türleri “YAGIS” (Yağış) olarak adlandırılan tek bir kategorik değişkende birleştirilmiştir (Şekil 3.8). Benzer bir yaklaşımla, kar (SN), karla karışık yağmur (RASN), buz kristalleri (IC) ve kar granülleri (SG) gibi katı formdaki yağışlar “KAR” (Kar Yağışı) başlığı altında toplanmıştır. Havaalanı operasyonlarını doğrudan etkileyen ve görüş mesafesini önemli ölçüde düşüren fenomenler olan sis (FG), pus (BR), duman (FU) ve haze (HZ) ise “GORUS_KISITLI” (Görüş Kısıtlayıcı Fenomenler) kategorisinde birleştirilmiştir. Son olarak, oraj/gök gürültülü fırtına (TS), şiddetli sağanaklar (SR) gibi potansiyel olarak tehlikeli ve konvektif hadiseler “FIRTINA” (Fırtına ve Şiddetli Olaylar) ortak paydasında gruplandırılmıştır.



Şekil 3.8. Türetilen yağış özelliğinin veri setindeki dağılımı

Bu kategorizasyon ve gruplama adımları, ham meteorolojik verilerin bilgi içeriğini zenginleştirerek ve operasyonel bağlamla daha uyumlu hale getirerek, makine öğrenmesi modelinin karmaşık hava durumu senaryolarını daha iyi anlamasına ve kritik olayları daha doğru bir şekilde öngörmesine zemin hazırlamıştır.

3.4.1.2. Etkileşim terimleri ve veri temizliği

Meteorolojik hadiselerin karmaşık ve çoğu zaman doğrusal olmayan doğası göz önüne alındığında, değişkenler arasındaki sinerjistik etkileşimlerin modellenmesi, öngörü performansının artırılması açısından kritik bir öneme sahiptir. Bu bağlamda, alan uzmanlığından faydalanılarak, belirli meteorolojik koşulların eşzamanlı varlığının potansiyel etkilerini temsil eden yeni etkileşim özellikleri türetilmiştir. Örneğin, “düşük görüş ve eşzamanlı yağış” (LowVis_and_Precip) kombinasyonu, tek başına düşük görüş veya yağış durumlarından daha farklı ve potansiyel olarak daha riskli bir senaryoyu işaret edebilir. Benzer şekilde, “alçak ve yoğun bulut kapallığı” (Low_Cloud_Cover_High) gibi bir özellik, belirli bir eşiğin üzerindeki alçak bulut varlığının ve kapallılık oranının birlikte değerlendirilmesiyle oluşturulmuştur. Bu tür kompozit özelliklerin tanımlanmasındaki temel motivasyon, modelin ham verilerde örtük olarak bulunan ancak açıkça temsil edilmeyen yüksek seviyeli örüntüleri ve riskli meteorolojik senaryoları daha etkin bir biçimde ayırt edebilme kapasitesini artırmaktır.

Özellik mühendisliği sürecinin bir diğer önemli adımı, gereksiz veya ilgisiz olduğu değerlendirilen sütunların veri setinden çıkarılmasıdır. Bu işlem, birincil olarak model

karmaşıklığını azaltmayı, aşırı öğrenme (overfitting) riskini minimize etmeyi ve hesaplama verimliliğini artırmayı hedefler. Özellikle, çalışmanın analiz periyodu ve odak alanı dışında kalan, önceki zaman dilimlerine ait historik veriler veya analitik hedeflerle doğrudan ilintili olmayan ham METAR (Meteorological Aerodrome Report) alanları bu kapsamda değerlendirilerek çıkarılmıştır. Bu seçim süreci, öznelik uzayının boyutunu optimize ederek, modelin daha genelleştirilebilir ve yorumlanabilir olmasına katkıda bulunur.

Neticede, uygulanan bu kapsamlı özellik mühendisliği ham meteorolojik veri setini, makine öğrenmesi algoritmaları tarafından daha etkin ve verimli bir biçimde işlenebilecek, bilgi yoğunluğu yüksek (information-rich) ve operasyonel açıdan anlamsal değeri olan bir özellik matrisine dönüştürmüştür. Bu dönüşüm süreci, geliştirilen tahmin modelinin performansını ve güvenilirliğini doğrudan etkileyerek, çalışmanın genel metodolojik sağlamlığına ve nihai başarısına kritik düzeyde katkı sağlamıştır.

3.5. Gecikme Süresi Tahmini için Regresyon Modellemesi

Bu çalışmanın temel hedeflerinden biri, belirli bir METAR zaman penceresindeki ortalama TMA (Terminal Kontrol Sahası) transit geçiş gecikmesini dakika cinsinden tahmin etmektir. Bu nicel tahmin problemini çözmek amacıyla, denetimli öğrenme paradigmalarından regresyon tekniği kullanılmıştır. Regresyon analizi, meteorolojik özellikler ile sürekli bir hedef değişken olan “Ortalama Gecikme (Dakika)” arasındaki fonksiyonel ilişkiyi modellemeyi amaçlar. Bu bölümde, gecikme miktarını tahmin etmek için seçilen LightGBM modelinin kurulumu, optimizasyonu ve bu sürece özel veri hazırlama adımları detaylandırılmaktadır.

3.5.1. Veri hazırlığı ve veri artırma (CTGAN)

Genel veri temizleme ve özellik mühendisliği adımlarına ek olarak, regresyon modelinin performansını ve genelleme yeteneğini artırmak amacıyla spesifik hazırlıklar yapılmıştır:

Aykırı Değer Temizliği: Modelin, nadir görülen aşırı yüksek gecikme değerlerinden orantısız şekilde etkilenmesini önlemek amacıyla, hedef değişken üzerinde IQR (Çeyrekler Açıklığı) tabanlı bir aykırı değer temizleme işlemi uygulanmıştır. $Q3 + 1.5 * IQR$ sınırını aşan veri noktaları, daha sağlam (robust) bir model elde etmek için veri setinden çıkarılmıştır [43].

Veri Artırma (CTGAN): IQR temizliği sonrası veri setinde, operasyonel açıdan kritik olan yüksek gecikme değerlerinin (bu çalışmada ≥ 7 dakika) sayısı yetersiz olduğu tespit edilmiştir. Modelin bu nadir fakat önemli aralıktaki davranışları daha iyi öğrenebilmesi için, modern bir üretken model olan **CTGAN (Conditional Tabular Generative Adversarial Networks)** [66] ile hedeflenmiş bir veri artırma stratejisi uygulanmıştır. Orijinal veri setindeki 7 dakika ve üzeri gecikmeye sahip örneklerle benzeyen, istatistiksel olarak tutarlı ve yüksek kaliteli sentetik veri örnekleri üretilmiştir. Bu sentetik veriler orijinal veri setine eklenerek, modelin eğitimi için daha zengin ve dengeli bir veri seti oluşturulmuştur.

Bu adımlar sonucunda, modelin özellikle kritik yüksek gecikme aralıklarındaki tahmin performansını iyileştirmesi hedeflenmiştir.

3.5.2. LightGBM modelinin kurulumu, eğitimi ve optimizasyonu

Gecikme süresini tahmin etmek amacıyla, literatürde etkinliği kanıtlanmış, yüksek performanslı bir gradyan artırma algoritması olan LightGBM (Light Gradient Boosting Machine) tercih edilmiştir. LightGBM, büyük veri setlerinde hızlı eğitim süreleri ve yüksek tahmin doğruluğu sunmasıyla bilinir. Modelin kurulumu ve optimizasyonu aşağıdaki adımları içermektedir:

Veri Setinin Bölünmesi ve Dönüşümü: Veri seti, modelin eğitimi için %80 eğitim ve performansının test edilmesi için %20 test alt kümelerine ayrılmıştır. Hedef değişkenin sağa çarpık dağılımını dengelemek ve model performansını iyileştirmek amacıyla, hedef değişken üzerinde logaritmik bir dönüşüm ($\log_{1p}$) uygulanmıştır [48]. LightGBM'in bu özellikleri doğrudan işleyebilme yeteneği sayesinde, kategorik özellikler için özel bir kodlama (One-Hot Encoding gibi) yerine, veri tipleri kategori olarak ayarlanmıştır.

Hiper parametre Optimizasyonu: Modelin performansını en üst düzeye çıkarmak için en uygun hiperparametre setini bulmak amacıyla, scikit-learn kütüphanesindeki RandomizedSearchCV aracı kullanılmıştır. Bu süreçte, num_leaves, learning_rate, n_estimators, max_depth gibi kritik hiperparametreleri içeren geniş bir arama uzayından rastgele 100 farklı kombinasyon denenmiştir. Her bir kombinasyonun performansı, eğitim verisi üzerinde 3-katlı çapraz doğrulama (cross-validation) ile, Ortalama Mutlak Hata (MAE) metriğine göre değerlendirilmiştir.

Modelin Eğitimi ve Seçimi: Optimizasyon süreci, tanımlanan 100 farklı hiper parametre kombinasyonunu çapraz doğrulama ile deneyerek en düşük MAE değerini

veren seti otomatik olarak bulmuştur. Bu en iyi hiper parametre setine sahip LightGBM modeli, çalışmanın nihai regresyon modeli olarak seçilmiş ve performansı test seti üzerinde değerlendirilmiştir.

Bu sistematik süreç sonucunda, veri artırma ve hedef dönüşümü uygulanmış bir veri seti üzerinde, hiper parametreleri optimize edilmiş bir LightGBM regresyon modeli geliştirilmiştir.

3.6. Gecikme Kategorisi Tahmini için Sınıflandırma Modellemesi

Regresyon yaklaşımına ek olarak, bu çalışmada problem ayrıca bir sınıflandırma (classification) problemi olarak da modellenmiştir. Bu yaklaşımın temel amacı, sürekli bir gecikme süresi yerine, gecikmeyi operasyonel açıdan anlamlı, önceden tanımlanmış kategorilere (Düşük, Orta, Yüksek Gecikme) atamaktır. Sınıflandırma, özellikle belirli gecikme eşiklerinin aşıp aşılmayacağına dair bir risk değerlendirmesi yapmak ve sınıf dengesizliği gibi zorluklarla başa çıkmak için özel tekniklerin uygulanmasına olanak tanınması açısından değerlidir [42].

3.6.1. Veri hazırlığı ve veri dengesizlik yönetimi

Sınıflandırma modellemesi için, regresyondan farklı olarak ham hedef değişken değerleri kullanılarak spesifik hazırlıklar yapılmıştır:

Hedef Değişkenin Oluşturulması: Sürekli gecikme değeri, belirli eşiklere göre üç sınıfa ayrılmıştır: Sınıf 1 (Düşük Gecikme: 3-6 dk), Sınıf 2 (Orta Gecikme: 6-10 dk) ve Sınıf 3 (Yüksek Gecikme: >10 dk). Bu yeni kategorik hedef değişken, Gecikme Sınıfları (Delay_Class) olarak adlandırılmıştır. Bu işlem sonucunda, özellikle Sınıf 3'ün (Yüksek Gecikme) diğer sınıflara göre anlamlı ölçüde daha az örneğe sahip olduğu ve belirgin bir sınıf dengesizliği bulunduğu doğrulanmıştır.

Kategorik Özelliklerin Kodlanması: Algoritmaların işleyebilmesi için, metin tabanlı kategorik özellikler, aralarında yapay bir sıralama ilişkisi kurmayan One-Hot Encoding (OHE) tekniği kullanılarak sayısal formata dönüştürülmüştür [44].

Veri Dengeleme Stratejileri: Sınıf dengesizliğinin, modelin azınlık sınıfını (Yüksek Gecikme) öğrenmesini engellememesi için iki farklı senaryo tasarlanmıştır. Birinci senaryo (ADASYN ile Dengeleme), temel strateji olarak, öğrenilmesi daha zor olan sınıf sınırlarındaki azınlık sınıfı örneklerine odaklanarak sentetik veri üreten ADASYN (Adaptive Synthetic Sampling) tekniği kullanılmıştır [42, 44]. Bu yöntem, sınıflar arası örnek sayısı dağılımını daha dengeli hale getirmiştir. İkinci senaryoda ise alternatif bir

yaklaşım olarak ADASYN ile dengelenmiş veri setinin tamamı basit bir tekrarla 5 katına çıkarılarak veri hacmi daha da artırılmıştır. Bu strateji, özellikle veri-aç algoritmaların daha fazla veri ile daha karmaşık örüntüleri öğrenme potansiyelini test etmeyi amaçlamaktadır.

Her iki senaryoda veri setleri, sınıf oranlarını koruyacak şekilde (%80 eğitim, %20 test) tabakalı olarak bölünmüştür.

3.6.2. Yenilikçi yaklaşım: AutoML ile otomatik model geliştirme

Sınıflandırma görevi için en iyi performansı verecek algoritmayı ve hiper parametreleri sistematik olarak bulmak amacıyla, modern bir yaklaşım olan Otomatik Makine Öğrenmesi (Automated Machine Learning- AutoML) benimsenmiştir. Bu görev için, dağıtık ve ölçeklenebilir yapısıyla bilinen, açık kaynaklı H2O.ai platformunun AutoML modülü [http-6] tercih edilmiştir. H2O AutoML, Gradient Boosting Machine (GBM), Random Forest, Deep Learning ve bunların yığılmış (Stacked Ensembles) versiyonları gibi çok çeşitli algoritmaları otomatik olarak eğitir, ayarlar ve karşılaştırır.

AutoML süreci, her iki senaryo için ayrı ayrı, belirli bir süre (~22 dakika) ve model sayısı (20 model) ile sınırlandırılarak çalıştırılmıştır. Modellerin performansını güvenilir bir şekilde değerlendirmek için 5-katlı çapraz doğrulama kullanılmış ve modellerin sıralanmasında temel metrik olarak Logaritmik Kayıp (LogLoss) belirlenmiştir. Süreç tamamlandığında, H2O AutoML denediği tüm modelleri sıralayan bir liderlik tablosu (leaderboard) ve bu tabloya göre en iyi performansı gösteren lider modeli otomatik olarak üretmiştir. Bu lider modelin performansı Bölüm 4'te değerlendirilmiştir.

3.7. Deneysel Kurulum, Değerlendirme Metrikleri ve Araçlar

Bu alt bölüm, çalışmada benimsenen standart deneysel prosedürleri, geliştirilen modellerin performansını ölçmek için kullanılan metrikleri ve yararlanılan yazılım altyapısını kapsamlı bir şekilde açıklamaktadır.

Deneysel tasarımın temelini, modellerin eğitilmemiş veriler üzerindeki genelleştirme kabiliyetini tarafsız bir biçimde değerlendirmek oluşturmaktadır. Bu doğrultuda hem regresyon hem de sınıflandırma görevleri için mevcut veri kümesi, literatürde yaygın olarak kabul gören bir pratikle %80 eğitim ve %20 test verisi olarak ayrıştırılmıştır. Model hiper parametrelerinin optimum konfigürasyonunu belirlemek ve elde edilen performans tahminlerinin sağlamlığını artırmak amacıyla, eğitim verisi üzerinde K-katlı çapraz doğrulama (K-Fold Cross-Validation) [78] tekniği prensip olarak

benimsenmiştir. Bu kapsamda, regresyon modelleri için 3-katlı, sınıflandırma modelleri için ise 5-katlı çapraz doğrulama uygulanmıştır.

Geliştirilen modellerin öngörü performansının nicel olarak değerlendirilmesi amacıyla, görevin niteliğine (regresyon veya sınıflandırma) uygun, literatürde kabul görmüş standart metrikler kullanılmıştır [79]:

Regresyon Görevleri için Performans Ölçütleri: Tahminlerin doğruluğunu ve hata düzeyini ölçmek amacıyla Ortalama Mutlak Hata (MAE) ve Kök Ortalama Karesel Hata (RMSE) metrikleri kullanılmıştır. MAE, tahminlerin gerçek değerlerden ortalama sapma miktarını dakika cinsinden ifade ederken; RMSE, büyük hataları daha fazla ağırlıklandırarak cezalandıran ve yine dakika cinsinden bir hata metriği sunmaktadır. Ek olarak, modelin bağımlı değişkendeki varyansın ne kadarlık bir kısmını açıklayabildiğini gösteren ve 0 ile 1 arasında değer alan oransal bir ölçüt olan Belirlilik Katsayısı (R^2) da hesaplanmıştır.

Sınıflandırma Görevleri için Performans Ölçütleri: Sınıflandırma modellerinin performansının çok boyutlu değerlendirilmesi amacıyla öncelikle bir Karmaşıklık Matrisi (Confusion Matrix) oluşturularak, sınıf bazındaki doğru ve yanlış tahmin sayıları incelenmiştir. Genel sınıflandırma başarısını yansıtan Doğruluk (Accuracy) metriğinin, özellikle dengesiz veri kümelerinde yanıltıcı olabileceği göz önünde bulundurularak, Kesinlik (Precision) ve Duyarlılık (Recall) metriklerine özel önem atfedilmiştir. Kesinlik, pozitif olarak tahmin edilen örneklerin ne kadarının gerçekten pozitif olduğunu; duyarlılık ise gerçek pozitiflerin ne kadarının model tarafından doğru bir şekilde tespit edilebildiğini ölçer – ki bu metrik, özellikle çalışmanın odak noktasındaki yüksek gecikme sınıfının tespiti açısından kritik öneme sahiptir. Bu iki metriğin harmonik ortalaması olan F1-Skoru, dengesiz sınıf dağılımlarına karşı daha dirençli bir birleşik performans göstergesi sunar. Ayrıca, modelin ürettiği sınıf olasılıklarının kalitesini değerlendiren Logaritmik Kayıp (LogLoss) ve modelin sınıfları genel ayırt etme gücünü gösteren Eğri Altında Kalan Alan (AUC- Area Under the ROC Curve) gibi daha ileri düzey metrikler de hesaplanmıştır.

Tüm veri ön işleme, analiz, model geliştirme ve değerlendirme süreçleri, açık kaynaklı Python programlama dili ve bu dilin zengin ekosistemi içerisinde yer alan kütüphaneler aracılığıyla yürütülmüştür. Veri manipülasyonu ve sayısal hesaplamalar için temel pandas ve numpy kütüphanelerinden [80]; makine öğrenmesi algoritmalarının implementasyonu için scikit-learn, LightGBM ve H2O gibi yaygın kullanılan çatılardan

(frameworks) [80]; dengesiz veri setleriyle başa çıkmak ve sentetik veri üretmek amacıyla imbalanced-learn [81] kütüphanelerinden ve son olarak, modelin karar verme mekanizmalarının yorumlanabilirliğini artırmak için SHAP [46] kütüphanesinden faydalanılmıştır.



4. UYGULAMA SONUÇLARI VE DEĞERLENDİRME

Bu bölüm, önceki bölümlerde ana hatları çizilen metodolojik yaklaşımlar kullanılarak iniş gecikmelerinin tahminlenmesi amacıyla geliştirilen regresyon ve sınıflandırma modellerinin uygulama sonuçlarını sunmakta ve bu sonuçları kapsamlı bir şekilde değerlendirmektedir.

Öncelikle modelleme çalışmalarına temel teşkil eden nihai analiz veri setinin temel karakteristikleri özetlenecektir. Ardından, hem regresyon (gecikme süresi tahmini) hem de sınıflandırma (gecikme kategorisi tahmini) modellerinin performansları, bağımsız test verileri üzerinde standart değerlendirme metrikleri kullanılarak nicel olarak ortaya konulmakta ve yorumlanmaktadır. Geliştirilen modellerin tahmin yeteneklerini, güçlü ve zayıf yönlerini, ayrıca veri artırma gibi spesifik tekniklerin model performansına olan katkılarını aydınlatmayı ve elde edilen bulguları havacılık operasyonları bağlamında yorumlayarak çalışmanın temel çıkarımlarını sunmayı hedeflemektedir.

4.1. Keşifsel Veri Seti Bulguları

Modelleme sürecinin etkinliği ve sonuçların doğru yorumlanabilmesi için kullanılan verinin özelliklerinin anlaşılması kritik öneme sahiptir. Bu kapsamda, Bölüm 3'te açıklanan veri toplama, temizleme, filtreleme ve özellik mühendisliği adımları sonucunda elde edilen nihai analiz veri seti üzerinde kapsamlı bir keşifsel veri analizi (EDA) gerçekleştirilmiştir. EDA'dan elde edilen temel bulgular, modelleme stratejilerinin belirlenmesinde ve sonuçların değerlendirilmesinde önemli şekilde yol gösterici olmuştur.

4.1.1. Hedef değişkenin dağılımı


Regresyon modeli için hedef değişken olan (Ortalama Gecikme (dakika)), 3 dakika üzeri gecikmeler filtrelendikten ve IQR (Çeyrekler Arası Aralık) metodu ile aykırı değer temizliği uygulandıktan sonra incelenmiştir. Nihai veri setinde, ortalama gecikme süresinin 5,92 dakika, medyan gecikme süresinin ise 4,50 dakika olduğu tespit edilmiştir. Ortalamanın medyan değerinden yüksek olması, dağılımın sağa çarpık (pozitif çarpık) olduğunu açıkça göstermektedir (Bkz. Şekil 3.6). Bu durum, hava trafik gecikmelerinin doğasıyla, yani çoğunlukla kısa süreli gecikmelerin yaşanması ancak az sayıda çok uzun süreli gecikmenin ortalamayı yukarı yönlü artırmasıyla uyumludur. Bu sağa çarpık dağılım, regresyon modelinin performansını olumsuz etkileyebileceği için, metodoloji

bölümünde açıklandığı üzere hedef değişken üzerinde logaritmik dönüşüm (np.log1p) uygulama kararını istatistiksel olarak desteklemiştir.


4.1.2. Kategorik özelliklerin dağılımları ve dengesizlik analizi

Sınıflandırma problemi için hedef değişken olan “Delay_Class” (Gecikme Sınıfı), sürekli gecikme değeri kullanılarak üç kategoriye ayrılmıştır: Sınıf 1 (Düşük Gecikme: 3-6 dk), Sınıf 2 (Orta Gecikme: 6-10 dk) ve Sınıf 3 (Yüksek Gecikme: >10 dk). Orijinal 774 gözlem üzerinde yapılan bu ayırım sonucunda belirgin bir sınıf dengesizliği gözlemlenmiştir. Sınıf dağılımı şu şekildedir: Sınıf 1 için 578 örnek, Sınıf 2 için 113 örnek ve Sınıf 3 için 83 örnek. Bu dengesizlik, özellikle operasyonel açıdan kritik olan “Yüksek Gecikme” sınıfının veri setinde nadir temsil edildiğini ve standart makine öğrenmesi algoritmalarının çoğunluk sınıfına yanlı tahminler yapmasına neden olabileceğini göstermiştir.

Meteorolojik hava durumu olaylarını temsil eden ikili (binary) kategorik özelliklerin (örn. “YAGIS”, “KAR”, “GORUS_KISITLI”, “FIRTINA”, “LowVis_and_Precip”, “LowCloudCoverHigh”, “BadWeatherCombo”) frekans dağılımları incelendiğinde de benzer bir dengesizlik gözlemlenmiştir. Örneğin, “YAGIS” özelliği için “YAGIS YOK (0)” durumu %83'lük bir oranla baskınken, “YAGIS VAR (1)” durumu %17'lik bir orana sahiptir. “KAR” ve “FIRTINA” gibi daha nadir görülen meteorolojik olayların varlığı (1) durumunun çok düşük frekanslarda olduğu tespit edilmiştir. Bu durum, veri artırma tekniklerinin (ADASYN, CTGAN) gerekliliğini ortaya koymuştur.



Şekil 4.1. Görüş kısıtlayıcı koşulların (GORUS_KISITLI) varlığına ilişkin frekans dağılımı



Şekil 4.2. Yağış (YAGIS) durumuna ilişkin frekans dağılımı


Türetilen ikili özelliklerden örnek olarak seçilen iki özelliğin (Kısıtlı Görüş ve Yağış Durumları) veri setindeki dağılımları sırasıyla Şekil 4.1. ve Şekil 4.2’de gösterilmektedir.

4.1.3. Özellikler ve hedef değişken arasındaki ilişkiler

Kategorik özelliklerin farklı seviyelerinin ortalama gecikme üzerindeki etkisi kutu grafikleri (box plots) ile incelendiğinde, beklentilere uygun ilişkiler gözlemlenmiştir.


Görüş Mesafesinin Etkisi: Görüş mesafesi kategorileri incelendiğinde, koşulların “İyi” düzeyden “Çok Kötü” düzeye doğru kademeli olarak kötüleşmesiyle, hem ortalama

(medyan) gecikme süresinde hem de gecikmelerin dağılımındaki değişkenlikte sistematik bir artış olduğu açıkça görülmektedir. Bu bulgu, azalan görüşün operasyonel akışkanlığı doğrudan ve gecikmeyi artırıcı yönde etkilediğini göstermektedir. Bu ilişki, Şekil 4.3.'da sunulmaktadır.




Şekil 4.3. Görüş mesafesi kategorilerine göre ortalama gecikme dağılımı (Kutu Grafiği)

Bulut Yüksekliğinin Etkisi (BLTOYUK): Bulut taban yüksekliği kategorileri değerlendirildiğinde, “Alçak” bulut tavanı olarak sınıflandırılan durumların, “Orta” düzey bulutlar veya “Bulut Yok” olarak tanımlanan senaryolara kıyasla daha yüksek gecikmelere yol açtığı görülmüştür. Bu durum, havacılık operasyonlarında alçak bulutların getirdiği operasyonel kısıtlamalarla uyumludur. Bu ilişki, Şekil 4.4.'te sunulmaktadır.




Şekil 4.4. Bulut taban yüksekliği kategorilerine göre ortalama gecikme dağılımı (Kutu Grafiği)

İkili Hava Durumu Göstergelerinin Etkisi: “YAGIS” (Şekil 4.5), “KAR” ve görüşü kısıtlayan olgular (Yağışla Birlikte Görüşü Kısıtlayan Koşulların Olduğu Durum-LowVis_and_Precip) (Şekil 4.6) gibi belirli hava olaylarının varlığını işaret eden ikili göstergeler mevcut olduğunda (değer=1), bu olayların bildirilmediği durumlara (değer=0) kıyasla gecikme sürelerinin hem merkezi eğilim (ortanca/ortalama) değerlerinin hem de yayılımının (değişkenliğinin) istatistiksel açıdan anlamlı düzeyde daha yüksek olduğu saptanmıştır. Bu durum, belirli olumsuz hava olaylarının gecikme dağılımları üzerinde kritik bir tetikleyici rol oynadığını ortaya koymaktadır.



Şekil 4.5. Yağış varlığına göre ortalama gecikme dağılımı (Kutu Grafiği)




Şekil 4.6. Düşük görüş ve yağışın (LowVis_and_Precip) ortalama gecikmeye etkisi

Bu genel bulguya ek olarak, grafikler incelendiğinde hava koşullarının etki derecelerinin farklılaştığı net bir şekilde görülmektedir. Örneğin, sadece yağış olduğu koşulların (Şekil 4.5) medyan gecikme üzerinde daha düşük oranda bir artışa neden olduğu görülmektedir. Bununla birlikte, gecikmeler üzerinde en dramatik etkiyi oluşturan faktör, Şekil 4.6'da gösterilen düşük görüş ve yağışın bir arada olduğu (LowVis_and_Precip) durumlarıdır. Bu koşul altında medyan gecikme yaklaşık iki katına çıkmakta ve gecikmelerin değişkenliği de belirgin şekilde artmaktadır.

Diğer yandan, kar yağışı “KAR” hadiselerinin sezgilerin aksine medyan gecikmeleri artırmadığı, aksine verinin çok dar bir aralıkta dağıldığı gözlemlenmiştir. Bu durum, kar gibi bazı aşırı koşulların seyahat talebini düşürerek trafik hacmini azaltması, uçuşun gerçekleştirilmeden iptal edilmesi ve dolayısıyla “tipik” gecikmeleri sınırlamasıyla açıklanabilir. Sonuç olarak, gecikmelerle en güçlü ve anlamlı ilişkiyi kuran faktörün, sürücülerin hızını ve dikkatini en çok zorlayan “düşük görüş ve yağış” kombinasyonu olduğu anlaşılmaktadır.

4.1.4. Korelasyon analizi

Sayısal özellikler arasındaki ilişkileri daha iyi anlamak amacıyla bir korelasyon matrisi analizi gerçekleştirilmiştir. Şekil 4.7.'de sunulan korelasyon ısı haritası, özellikler arasındaki Pearson korelasyon katsayılarını göstermektedir.



Şekil 4.7. Regresyon modelindeki sayısal özellikler arasındaki Pearson Korelasyon Matrisi

Hedef değişken olan “Ortalama Gecikme (dakika)” ile açıklayıcı özellikler arasındaki korelasyonlar incelendiğinde, hava koşullarının gecikmeler üzerindeki etkisinin gücü açısından belirgin bir hiyerarşi gözlemlenmektedir. Isı haritasında belirgin turuncu-kırmızı tonlarla görüldüğü üzere, en güçlü pozitif ilişkiye sahip olan özellikler;

düşük görüş ve yağışı birleştiren “LowVis_and_Precip”, “FIRTINA”, “BadWeatherCombo” ve tek başına “GORUS_KISITLI” özellikleridir. Bu durum, gecikmeler üzerindeki en kritik tetikleyicinin, uçuş personelinin davranışını doğrudan kısıtlayan ve risk algısını artıran koşullar olduğunu ortaya koymaktadır. Özellikle görüş mesafesinin azalması gibi faktörler, tekil hava olaylarından daha güçlü bir doğrusal etkiye sahiptir. Bu durumun yanı sıra, sadece “YAGIS” ve “LowCloudCoverHigh” (yüksek seviye bulut örtüsü) gibi özellikler de gecikmelerle pozitif bir korelasyon sergilemekle birlikte, bu ilişkinin şiddetinin daha ılımlı olduğu görülmektedir. Analizin en dikkat çekici bulgularından biri ise “KAR” ve rüzgâr bileşenleri olan rüzgâr özelliklerinin ortalama gecikme ile neredeyse sıfıra yakın bir korelasyona sahip olmasıdır. Bu durum, operasyonların doğası gereği özellikle kar yağışının trafiği artırmaktan ziyade seyahat talebini düşürerek gecikmeleri sınırlayabildiğine, rüzgârın etkisinin ise doğrusal olmaktan çok karmaşık ve eşik değerlere bağlı olabileceğine işaret etmektedir.

Bu kapsamlı keşifsel veri analizi, veri setindeki önemli örüntüleri, sınıf dengesizliklerini ve özellikler arası ilişkileri net bir şekilde ortaya koymuştur. Elde edilen bu bulgular, takip eden modelleme adımlarında (örneğin, hedef değişken dönüşümü, veri dengeleme stratejileri, uygun algoritma seçimi) alınan kararları gerekçelendirmiş ve modelin operasyonel gerçekliği yansıtmaya kapasitesini artırmıştır.

4.2. Regresyon Modeli Sonuçları (LightGBM)

Bu bölüm, LTFM'deki METAR penceresi başına ortalama iniş gecikmesini tahmin etmek üzere geliştirilen LightGBM regresyon modelinin performansını ve bu performansın değerlendirme yöntemlerini ana hatlarıyla sunmaktadır. Modelin etkinliği, ayrılmış bir test seti üzerinde standart regresyon metrikleri kullanılarak ölçülmüştür.

4.2.1. Model performansının değerlendirilmesi

Bu bölümde, CTGAN (Conditional Tabular Generative Adversarial Network) ile zenginleştirilmiş veri seti üzerinde hiper parametreleri optimize edilmiş ve eğitilmiş nihai LightGBM regresyon modelinin, daha önce hiç görmediği bağımsız test seti üzerindeki performansı kapsamlı bir şekilde incelenmekte ve CTGAN stratejisinin sonuçlara olan katkısı kantitatif olarak değerlendirilmektedir. Karşılaştırma amacıyla, CTGAN uygulanmamış bir LightGBM modelinin ve bir “Baseline (Ortalama)” modelin performansları da Tablo 4.1.' ve Tablo 4.2.'de sunulmuştur.

Tablo 4.1. Regresyon modellerinin genel performans metriklerinin karşılaştırılması (Test Seti)

Model	MAE	RMSE
Ortalama Model (Baseline)	1,06	1,41
LightGBM (CTGAN Uygulanan)	1,28	1,72
LightGBM (CTGAN Uygulanmayan)	1,05	1,55

Tablo 4.2. Regresyon modellerinin kritik gecikme eşiğine göre performansının karşılaştırılması

Model	MAE (<7)	RMSE (<7)	MAE (>= 7)	RMSE (>= 7)
LightGBM (CTGAN)	0,77	1,00	1,86	2,27
LightGBM (CTGAN Uygulanmayan)	0,71	0,92	3,09	3,45

Tablo 4.1. ve Tablo 4.2.'deki sonuçlar ışığında şu temel çıkarımlar yapılabilir:


Genel Performans: CTGAN destekli LightGBM modelinin test seti üzerindeki genel MAE (Ortalama Mutlak Hata) değeri yaklaşık 1,29 dakika, RMSE (Kök Ortalama Karesel Hata) değeri ise yaklaşık 1,73 dakika olarak hesaplanmıştır. Bu değerler, CTGAN uygulanmamış modelin sırasıyla 1,05 dakika MAE ve 1,56 dakika RMSE olan performansından bir miktar daha yüksek görünmektedir. Ancak bu durum, modellerin öğrendiği veri dağılımının ve odaklandığı problem zorluğunun bir yansıması olarak değerlendirilmelidir. CTGAN uygulanmayan model, veri setindeki çoğunluğu oluşturan ve tahmini görece kolay olan düşük gecikmelere (<7dk) odaklanarak bu dar aralıkta nispeten bir genel başarı sergilerken, operasyonel açıdan kritik olan nadir yüksek gecikmeleri etkin bir şekilde yakalayamamaktadır. Düşük gecikme aralığında her iki modelin hata oranları birbirine yakın seviyededir.

CTGAN Uygulamasının Yüksek Gecikmelere Etkisi: Sentetik veri artırımının temel faydası, operasyonel açıdan en kritik olan yüksek gecikme aralığında (≥ 7 dk) belirginleşmektedir. CTGAN ile zenginleştirilmiş veri seti üzerinden eğitilen model, özellikle nadir fakat önemli yüksek gecikme vakalarını daha iyi temsil eden bir veri dağılımını öğrenmiştir. Bu sayede, CTGAN uygulanan modelin yüksek gecikme aralığındaki MAE değeri (yaklaşık 1,86 dakika), CTGAN uygulanmamış modelin MAE'sine (yaklaşık 3,10 dakika) kıyasla yaklaşık %40 oranında azalmıştır. Bu iyileşme, genel ortalama hata metriklerinde küçük bir artışa yol açsa da (çünkü model daha zorlu

bir tahmin görevini üstlenmektedir) modelin operasyonel değeri yüksek, zorlu senaryolardaki tahmin kapasitesini artırmış ve daha dengeli, genellenebilir bir öğrenme süreci sağlamıştır.


LightGBM (CTGAN) modeli ile gerçekleştirilen tahmin çalışmasında, R-kare (R^2) değeri 0,42 olarak hesaplanmıştır. Bu değer, nominal olarak bağımlı değişkendeki varyansın %42'sinin model tarafından açıklandığını ifade etse de bu yorum doğrusal olmayan modeller için yanıltıcı olabilir. Geliştirilen LightGBM modelinin, METAR verilerine dayalı iniş gecikme tahmini probleminde 0.42 gibi bir R^2 değeri sergilemesi, modelin içsel doğrusal olmayan yapısı ve özellikler ile hedef değişken arasındaki karmaşık bağımlılıklar göz önüne alındığında beklenen bir sonuçtur. R^2 metriğinin matematiksel temeli, Toplam Hata Kareleri'nin yalnızca doğrusal regresyon varsayımı altında geçerli olan bileşenlere ayrıştırılmasına dayanır. R^2 , temel olarak değişkenler arasında doğrusal bir ilişki olduğunu varsayar ve bu varsayımın karşılanmadığı durumlarda modelin gerçek performansını yansıtmakta yetersiz kalır. LightGBM gibi ağaç tabanlı algoritmalar, verideki karmaşık ve doğrusal olmayan ilişkileri modelleme kapasitesine sahiptir ve bu nedenle bu tür modellerde R^2 'nin tek başına bir “uyum iyiliği” (goodness-of-fit) ölçütü olarak kabul edilmesi standart bir pratik değildir. Nitekim, Spiess ve Neumeyer (2010) tarafından yapılan kapsamlı çalışma, R^2 'nin doğrusal olmayan modellerin performansını karşılaştırmada ve değerlendirmede tek başına güvenilir bir metrik olmadığını ampirik olarak kanıtlamıştır [82]. Bu bağlamda, modelin MAE (Ortalama Mutlak Hata) gibi hata metriklerindeki dikkate değer başarısı göz önüne alındığında, elde edilen 0.42'lik R^2 değeri, modelin tahmin gücünün zayıflığına işaret etmek yerine, R^2 metriğinin model tarafından yakalanan doğrusal olmayan örüntüleri ölçmedeki yapısal sınırlılığını teyit etmektedir. Sonuç olarak, modelin performansının bütüncül değerlendirmesinde, R^2 'ye kıyasla MAE ve RMSE gibi doğrudan tahmin hatasını ölçen metriklerin önceliklendirilmesi, bilimsel olarak daha sağlam bir yaklaşım olacaktır.

Gerçek gecikme değerleri ile modelin tahmin ettiği gecikme değerleri arasındaki ilişki Şekil 4.8.'de, tahmin hatalarının dağılımı ise Şekil 4.9.'da sunulmaktadır.



Şekil 4.8. Regresyon modeli tahminlerinin gerçek değerler ile karşılaştırılması (test seti)

Şekil 4.8.'de tahminlerin ideal eşleşme çizgisi (kırmızı kesikli çizgi) etrafında dağılımı, modelde belirgin bir sistematik yanlılık (bias) olmadığını, yani modelin genel eğilimi başarıyla yakaladığını göstermektedir. Ancak, beklendiği gibi yüksek gecikme değerlerinde (özellikle 7 dakika üzeri) tahmin belirsizliğinin bir miktar arttığı ve noktaların çizgi etrafında daha fazla saçıldığı gözlenmektedir.



Şekil 4.9. LightGBM modeli tahmin hatalarının dağılımı (test seti – CTGAN Uygulanan Senaryo)

Şekil 4.9.'daki hata dağılımının sıfır etrafında yoğunlaşması ve dağılımın çan eğrisine benzerliği, modelin çoğunlukla tutarlı tahminler ürettiğini teyit etmektedir. Kuyruk kısımlarındaki hataların varlığı, modelin uç değerleri tahmin etme kapasitesinin nispeten sınırlı olabileceğine işaret etmektedir.

4.2.2. Özellik önem analizi ve meteorolojik faktörlerin etkisi (SHAP)

Geliştirilen LightGBM modelinin içsel karar verme mekanizmasını aydınlatmak ve modelin yorumlanabilirliğini artırmak amacıyla, teorik temelleri oyun teorisine dayanan SHAP (SHapley Additive exPlanations) analizinden yararlanılmıştır. Bu yöntem, her bir özelliğin modelin tahminlerine yaptığı bireysel katkıyı niceliksel olarak hesaplayarak, hangi faktörlerin tahmin sonucunu ne yönde ve ne ölçüde etkilediğini ortaya koyar. Yüksek ortalama mutlak SHAP değerine sahip olan özellikler, modelin genel yordamsal gücüne en önemli katkıyı sunan faktörler olarak tanımlanır.


Bu analizin en güçlü çıktılarından biri olan SHAP özet grafiği, özelliklerin tekil tahminlere olan katkısının hem yönünü (pozitif/negatif) hem de büyüklüğünü veri kümesinin tamamı için bütüncül bir şekilde görselleştirir. Bu grafikteki her bir nokta, test setindeki tek bir veri örneğini temsil eder. Noktaların x eksenindeki konumu, o özelliğin ilgili örnek için hesaplanan SHAP değerini, yani model çıktısına olan pozitif (gecikmeyi artırıcı) veya negatif (gecikmeyi azaltıcı) etkisini ifade eder. Noktaların rengi ise o özelliğin orijinal değerinin göreceli büyüklüğünü (genellikle yüksek değerler için kırmızı, düşük değerler için mavi) sembolize eder. Dolayısıyla, bir özellik için kırmızı noktaların pozitif SHAP değerleri bölgesinde (eksenin sağ tarafında) yoğunlaşması, bu özelliğin yüksek değerlerinin model tarafından gecikmeyi artırıcı bir faktör olarak öğrenildiğini güçlü bir şekilde göstermektedir. Buna karşılık, mavi noktaların negatif SHAP değerleri bölgesinde (eksenin sol tarafında) kümelenmesi ise, özelliğin düşük değerlerinin model tarafından gecikmeyi azaltıcı bir etkiyle ilişkilendirildiğini ortaya koymaktadır.

Mevcut çalışmada bu yorumlanabilirlik analizi, CTGAN ile eğitilmiş nihai LightGBM modelinin tahminlerini açıklamak amacıyla, daha önce ayrılmış olan bağımsız test veri seti kullanılarak titizlikle gerçekleştirilmiştir.

SHAP analizinden elde edilen ve özelliklerin genel önem sıralamasını gösteren özet grafiği Şekil 4.10.'da sunulmuştur. Bu grafikte özellikler, ortalama mutlak SHAP değerlerine göre (en önemlisi en üstte olacak şekilde) sıralanmıştır. Her bir özellik için gözlemlenen bu SHAP değeri dağılımları, özelliğin farklı seviyelerinin modelin gecikme

tahminlerini ne yönde ve ne ölçüde etkilediğine dair güçlü ve ayrıntılı içgörüler sunmaktadır.

Özelliklerin Model Çıktısına Etkisi



Şekil 4.10. Regresyon modeli için SHAP özellik önem sıralaması ve etki yönleri

Şekil 4.10 detaylı olarak incelendiğinde, modelin gecikme tahminleri üzerinde en baskın etkiye sahip olan faktörler ve bu etkilerin yönü hakkında şu önemli içgörüler elde edilmiştir:


Bulut Yapısı: Modelin tahminleri üzerinde en etkili faktör grubunun bulutların detaylı yapısı olduğu görülmektedir. Özellikle BLT1CINS (Orta seviye bulut tipi), BLTTOPKAP (bulut katmanları toplam kapalılığı) ve BLTOYUK (en alt bulut tabanı yüksekliği) gibi özellikler en üst sıralarda yer almaktadır. SHAP değerleri, beklendiği gibi, alçak bulut tavanlarının, yoğun bulutluluğun ve Kümülönimbus (Cb) gibi operasyonel açıdan riskli bulut tiplerinin gecikmeyi artırıcı (pozitif SHAP değeri) bir etkiye sahip olduğunu göstermektedir.

Görüş Koşulları: PIST1GORUS (Pist Görüş Mesafesi) ve GORUSMIN (minimum görüş) gibi özellikler de yüksek öneme sahiptir. Düşük görüş mesafesi değerlerinin gecikmeyi artırıcı etki yaptığı gözlemlenmiştir.

Mühendislik Özellikleri: Manuel olarak oluşturulan LowCloudCoverHigh (düşük seviyede yüksek kapalılık) gibi etkileşim terimlerinin varlığı, neredeyse her zaman gecikmeyi artıran bir faktör olarak model tarafından öğrenilmiştir. Bu durum, birden fazla olumsuz koşulun bir araya gelmesinin tekil etkilerden daha büyük bir risk oluşturduğunu teyit etmektedir.

Yağış: YAGIS özelliğinin (yağış varlığı) de (genellikle pozitif SHAP değerleri ile) gecikmeler üzerinde artırıcı bir etkiye sahip olduğu SHAP analizi ile teyit edilmiştir.


Belirli özelliklerin değerleri değiştikçe SHAP değerlerinin (ve dolayısıyla model tahmininin) nasıl değiştiğini, ayrıca bu özelliğin diğer bir özellik (renk kodlamasıyla gösterilen etkileşim özelliği) nasıl bir etkileşim içinde olduğunu gösteren örnek SHAP bağımlılık grafikleri Şekil 4.11, Şekil 4.12 ve Şekil 4.13'te sunulmaktadır.



Şekil 4.11. Toplam bulut kapalılığının model çıktısına etkisini gösteren SHAP bağımlılık grafiği


Şekil 4.11'de BLTTOPKAP (bulut katmanı toplam kapalılığı) arttıkça (0'dan 8'e doğru), SHAP değerlerinin genel olarak pozitif yönde arttığı gözlemlenmektedir. Bu, daha kapalı bir gökyüzünün (yüksek BLTTOPKAP değeri) gecikmeyi artırma eğiliminde olduğunu göstermektedir. Grafikteki noktaların rengi (LowCloudCoverHigh) ile gösterilen etkileşim, bu özelliğin yüksek değerlerinin (kırmızı noktalar) genellikle daha

yüksek pozitif SHAP değerleriyle, yani daha fazla gecikmeyle ilişkili olduğunu ortaya koymaktadır.



Şekil 4.12. Alçak seviye bulut taban yüksekliğinin modele etkisini gösteren SHAP bağımlılık grafiği

Şekil 4.12.'de benzer şekilde, BLTOYUK (en düşük irtifalardaki bulut tabanı yüksekliği) düştükçe (örneğin 'Alçak' kategoriye doğru gidildikçe), SHAP değerlerinin pozitif olma eğiliminde olduğu, yani alçak bulutların gecikmeyi artırdığı görülmektedir. 'Bulut Yok' kategorisinde ise SHAP değerleri genellikle sıfıra yakındır. BLT1KAP (birinci bulut katmanı kapalılığı) ile olan etkileşim (renk skalası) incelendiğinde, yüksek BLT1KAP değerlerinin (kırmızıya yakın renkler) alçak bulut durumunda daha yüksek pozitif SHAP değerlerine yol açtığı, yani bu iki durumun birleştiğinde gecikme riskini daha da artırdığı anlaşılmaktadır.



Şekil 4.13. Yağış varlığının model çıktısına etkisini gösteren SHAP bağımlılık grafiği

Yağışın varlığı (YAGIS=1), gecikme süreleri üzerinde pozitif bir etkiye sahiptir. SHAP grafiği, yağış olduğunda SHAP değerlerinin genel olarak pozitif olduğunu göstermektedir.

Bu bulgular, modelin “kara kutu” olmaktan ziyade, operasyonel gerçeklikle tutarlı ve meteorolojik alan bilgisiyle uyumlu faktörlere dayandığını güçlü bir şekilde göstermektedir. Modelin, özellikle Instrument Meteorological Conditions (IMC) oluşturan durumlara (düşük tavan, düşük görüş, yoğun bulutluluk) büyük önem atfetmesi, geliştirilen tahmin yaklaşımının sağlamlığını desteklemektedir.

4.3. Sınıflandırma Modeli Sonuçları (AutoML- H2O)

Bu bölümde iniş gecikmelerinin metodoloji bölümünde tanımlanan kategorilere (Sınıf 1: Düşük, Sınıf 2: Orta, Sınıf 3: Yüksek) göre sınıflandırmak amacıyla geliştirilen modellerin sonuçları sunulmaktadır.

Model geliştirme süreçleri için H2O AutoML çatısından yararlanılmış ve sınıf dengesizliği sorununa yönelik iki farklı veri örnekleme stratejisi (Senaryo 1: Sadece ADASYN; Senaryo 2: ADASYN + 5 Kat Tekrarlama) test edilmiştir. Bu bölümde, her iki senaryo için en iyi performans gösteren modeller, bu modellerin bağımsız test seti üzerindeki başarıları ve uygulanan veri dengeleme stratejilerinin etkileri incelenmektedir.

4.3.1. AutoML liderlik tablosu ve seçilen modelin performansı

H2O AutoML süreci, her iki örnekleme senaryosu için de çeşitli makine öğrenmesi algoritmalarını ve bunların yığılmış (Stacked Ensembles) versiyonlarını otomatik olarak eğitmiştir. Modellerin sıralamasında temel metrik olarak Logaritmik Kayıp (LogLoss) kullanılmıştır. Senaryo 1 ve Senaryo 2'ye ait AutoML Liderlik Tabloları (İlk 5 Model) Tablo 4.3 ve Tablo 4.4'te sunulmaktadır.

Tablo 4.3. Senaryo 1: Sadece ADASYN ile AutoML liderlik tablosu (İlk 5 Model)

Model	Logloss	Sınıf başına ortalama hata	RMSE	MSE
StE_AllMo_1	0,607	0,252	0,447	0,200
StE_BOF_1	0,610	0,252	0,449	0,202
GBM_4	0,659	0,265	0,463	0,214
DRF_1	0,664	0,267	0,478	0,228
GBM_grid_1	0,665	0,269	0,466	0,217

Tablo 4.4. Senaryo 2: ADASYN + 5 Kat aşırı örnekleme ile AutoML liderlik tablosu (İlk 5 Model)

Model	Logloss	Sınıf Başına Ortalama Hata	RMSE	MSE
GBM_4	0,051	0,022	0,124	0,015
GBM_3	0,054	0,023	0,124	0,015
GBM_2	0,057	0,022	0,125	0,015
GBM_1	0,064	0,022	0,126	0,016
XGBoost_2	0,070	0,022	0,130	0,017

Tablo 4.3 ve Tablo 4.4'te belirtilen liderlik tabloları incelendiğinde; Senaryo 1'de (Sadece ADASYN) liderliği farklı temel modelleri birleştiren bir StackedEnsemble AllModels modeli almıştır. Bu model bireysel modellerden daha stabil performans sağlayabilen bir model geliştirildiğini göstermektedir. Lider modelin çapraz doğrulama LogLoss değeri yaklaşık 0,61 civarındadır.

Senaryo 2'de (ADASYN + 5 Kat Aşırı Örnekleme), liderliği bir GBM (Gradient Boosting Machine) modeli almıştır. Bu senaryodaki modellerin, Senaryo 1'e kıyasla çok daha düşük LogLoss değerlerine (lider model için 0,05) ulaştığı gözlemlenmektedir. Bu durum, artırılmış veri hacminin, özellikle GBM gibi güçlü algoritmaların potansiyelini daha iyi ortaya çıkardığını ve daha iyi bir model uyumu sağladığını düşündürmektedir.

Her iki senaryo için AutoML tarafından en iyi olarak belirlenen lider modellerin, bağımsız test seti üzerindeki genel performans metrikleri Tablo 4.5.'te karşılaştırmalı olarak sunulmuştur.

Tablo 4.5. *En iyi lider modellerin performans metrikleri karşılaştırması*

Senaryo	LogLoss	RMSE	MSE	Sklearn Doğruluk	Makro F1 Skoru
Sadece ADASYN	0,511	0,409	0,167	0,218	0,781
ADASYN + 5 Katı Aşırı Örneklem	0,028	0,093	0,008	0,016	0,983


Tablo 4.5.'teki sonuçlar, iki örneklem stratejisi arasında performans açısından çok büyük bir fark olduğunu net bir şekilde göstermektedir. ADASYN uygulandıktan sonra ek olarak 5 kat tekrarlama ile veri hacminin artırıldığı Senaryo 2'de eğitilen lider GBM modeli, Senaryo 1'deki modele kıyasla tüm temel metriklerde keskin bir iyileşme sergilemektedir. Özellikle:

- Doğruluk (Accuracy) ~%78,16'dan ~%98,33'e yükselmiştir.
- Makro F1-Skoru ~%78.05'ten ~%98,33'e yükselmiştir.
- LogLoss 0.51'den 0.03'e düşmüştür.

Bu çarpıcı sonuçlar, veri setindeki örnek sayısını artırmanın, özellikle GBM gibi güçlü algoritmaların daha sağlam örüntüler yakalamasına ve genelleme performansını önemli ölçüde artırmasına olanak tanıdığını açıkça göstermektedir.

4.3.2. Sınıf bazı performans analizi (karmaşıklık matrisi)

Modelin her bir gecikme sınıfını ne kadar başarılı tahmin ettiğini anlamak için karmaşıklık matrisleri (confusion matrix) ve bunlardan türetilen sınıf bazlı metrikler incelenmiştir. Senaryo 1 ve Senaryo 2 için lider modellerin test seti üzerindeki karmaşıklık matrisleri sırasıyla Şekil 4.14. ve Şekil 4.15.'te sunulmuştur.




Şekil 4.14. Karmaşıklık matrisi- Sadece ADASYN senaryosu

Şekil 4.14.'te Senaryo 1 (Sadece ADASYN) için karmaşıklık matrisi incelendiğinde, modelin performansı aşağıdaki gibi özetlenebilir:

Sınıf 1 (Düşük Gecikme): Gerçekte Düşük Gecikme olan 116 vakanın 81'i doğru tahmin edilmiştir (Geri Çağırma: %69,83). Ancak, 15 vaka Orta Gecikme, 20 vaka ise Yüksek Gecikme olarak yanlış sınıflandırılmıştır. Sınıf 2 (Orta Gecikme): Gerçekte Orta Gecikme olan 117 vakanın 94'ü doğru tahmin edilmiştir (Geri Çağırma: %80,34). 17 vaka Düşük Gecikme, 6 vaka ise Yüksek Gecikme olarak yanlış sınıflandırılmıştır. Sınıf 3 (Yüksek Gecikme): Gerçekte Yüksek Gecikme olan 115 vakanın 97'si doğru tahmin edilmiştir (Geri Çağırma: %84,35). 9 vaka Düşük Gecikme, 9 vaka ise Orta Gecikme olarak yanlış sınıflandırılmıştır.

Bu sonuçlar, Senaryo 1'deki modelin özellikle Düşük Gecikme sınıfını diğer sınıflarla karıştırma eğiliminde olduğunu ve Yüksek Gecikme sınıfı için görece daha iyi bir geri çağırma oranına sahip olsa da tüm sınıflar için yanlış sınıflandırma oranlarının dikkate değer olduğunu göstermektedir.



Şekil 4.15. Karmaşıklık matrisi- ADASYN + 5 kat aşırı örnekleme senaryosu

Şekil 4.15.'te Senaryo 2 (ADASYN + 5 Kat Aşırı Örnekleme) için karmaşıklık matrisi ise Senaryo 1'e kıyasla çok daha üstün bir performansı ortaya koymaktadır:

Sınıf 1 (Düşük Gecikme): Gerçekte Düşük Gecikme olan 578 vakanın 564'ü doğru tahmin edilmiştir (Geri Çağırma: %97,58). Sadece 11 vaka Orta Gecikme, 3 vaka ise Yüksek Gecikme olarak yanlış sınıflandırılmıştır. Sınıf 2 (Orta Gecikme): Gerçekte Orta Gecikme olan 583 vakanın 576'sı doğru tahmin edilmiştir (Geri Çağırma: %98,80). 5 vaka Düşük Gecikme, 2 vaka ise Yüksek Gecikme olarak yanlış sınıflandırılmıştır. Sınıf 3 (Yüksek Gecikme): Gerçekte Yüksek Gecikme olan 576 vakanın 568'i doğru tahmin edilmiştir (Geri Çağırma: %98,61). Sadece 6 vaka Düşük Gecikme, 2 vaka ise Orta Gecikme olarak yanlış sınıflandırılmıştır.

Karmaşıklık matrislerinin karşılaştırmalı analizi, iki strateji arasındaki başarı farkını açıkça ortaya koymaktadır. Senaryo 1'de yanlış sınıflandırmalar daha fazlayken, Senaryo 2'de köşegen elemanlar (doğru sınıflandırmalar) baskındır. Özellikle Sınıf 3 (Yüksek Gecikme) için yanlış negatif sayısındaki, yani yüksek gecikme durumunun kaçırılması olayındaki, dramatik azalma Senaryo 2'nin üstünlüğünü göstermektedir. Tablo 4.6.'da sunulan sınıf bazlı F1-Skorları da Senaryo 2 için tüm sınıflarda %97'nin üzerine çıkarak bu yüksek performansı doğrulamaktadır. Bu, veri artırma stratejisinin sadece genel doğruluğu değil, özellikle operasyonel açıdan en kritik olan yüksek gecikme

sınıfının tanınma başarısını ve genel sınıflandırma dengesini önemli ölçüde iyileştirdiğini kanıtlamaktadır.

Tablo 4.6. İki veri dengeleme senaryosu için sınıf bazlı performans metriklerinin karşılaştırması

Senaryo	Sınıf	Kesinlik	Geri Çağırma (Recall)	F1-Puanı	Destek (Support)
Senaryo 1	Sınıf 1	0,7570	0,6983	0,7265	116
	Sınıf 2	0,7966	0,8034	0,8000	117
	Sınıf 3	0,7886	0,8435	0,8151	115
	Doğruluk		0,7816		348
	Makro ort.	0,7807	0,7817	0,7805	348
Senaryo 2	Sınıf 1	0,9809	0,9758	0,9783	578
	Sınıf 2	0,9779	0,9880	0,9829	583
	Sınıf 3	0,9913	0,9861	0,9887	576
	Doğruluk		0,9833		1737
	Makro ort.	0,9834	0,9833	0,9833	1737

Tablo 4.6. incelendiğinde, Senaryo 1'de metrikler ortalama ~%78 seviyesindeyken; Senaryo 2'de tüm sınıflar için Precision, Recall ve F1-Skor değerlerinin %97'nin üzerine çıktığı görülmektedir. Operasyonel açıdan en kritik metrik olan Sınıf 3 için Geri Çağırma-Recall değerinin ~%98,61'e yükselmesi, modelin yüksek gecikme durumlarını tespit etme yeteneğinde olağanüstü bir iyileşme olduğunu ve yanlış negatif oranının son derece düştüğünü göstermektedir.

4.3.3. Veri dengeleme tekniklerinin model başarısına etkisi

Bu çalışmada test edilen iki veri dengeleme stratejisi arasında, Strateji 2 (ADASYN + 5 Kat Aşırı Örnekleme), Strateji 1'e (Sadece ADASYN) göre belirgin ve istatistiksel olarak anlamlı ölçüde daha üstün bir model performansı sağlamıştır. Bu büyük performans farkının altında yatan temel nedenin ikinci senaryoda sağlanan veri hacmindeki dramatik artış olduğu düşünülmektedir. ADASYN ile sınıf dengesizliği

giderildikten sonra, veri setinin basit tekrarlar ile 5 katına çıkarılması, Senaryo 2'de lider olarak seçilen GBM gibi güçlü ve veri-aç algoritmaların eğitim sürecini olumlu etkilemiştir. Daha büyük bir veri seti, GBM'in daha güvenilir bölünme noktaları bulmasını, karmaşık ilişkileri daha iyi modellemesini ve daha sağlam bir topluluk modeli oluşturmasını sağlamıştır. Basit tekrarların teorik olarak aşırı öğrenme (overfitting) riskini artırma potansiyeli bulunsada H2O AutoML içindeki çapraz doğrulama ve GBM'in kendi düzenleme mekanizmaları sayesinde bu riskin gerçekleşmediği ve modelin bağımsız test seti üzerinde de yüksek performans sergilediği görülmüştür.

Sonuç olarak, iniş gecikmesi sınıflandırması problemi özelinde, ADASYN ile sentetik veri ürettikten sonra aşırı örnekleme yaparak veri hacmini artırma yaklaşımının, çok daha yüksek ve dengeli bir sınıflandırma doğruluğuna ulaştığı net bir şekilde tespit edilmiştir.

Bu bölümde sunulan keşifsel analiz ve model uygulama bulguları, meteorolojik faktörlerin uçuş gecikmeleri üzerindeki etkisini nicel ve nitel olarak ortaya koymuştur. Geliştirilen regresyon ve sınıflandırma modelleri, veri dengesizliği gibi zorluklara rağmen güçlü tahmin yetenekleri sergilemiş ve operasyonel açıdan anlamlı içgörüler sunmuştur. Modellerin performansları ve meteorolojik değişkenlerin gecikmeler üzerindeki belirleyici rolü, bir sonraki bölümde kapsamlı bir şekilde karşılaştırılıp tartışılacak, çalışmanın özgün katkıları ve gelecekteki araştırma potansiyeli ele alınacaktır.

5. SONUÇ VE GELECEK ÇALIŞMALAR

Bu bölümde, Terminal Kontrol Sahası (TMA) içerisindeki varış gecikmelerinin meteorolojik faktörlere bağlı olarak tahminlenmesi amacıyla yürütülen bu tez çalışmasının genel bir değerlendirmesi yapılacak, elde edilen temel bulgular özetlenecek, geliştirilen modellerin karşılaştırmalı analizi ve operasyonel anlamları tartışılacak, araştırmanın literatüre sunduğu özgün katkılar vurgulanacak ve gelecek araştırmalar için potansiyel çalışma alanlarına dair öneriler sunulacaktır.

5.1. Araştırmanın Genel Değerlendirmesi ve Temel Bulgular

Bu tez çalışması, İstanbul Havalimanı (LTFM) gibi stratejik bir hub'da, meteorolojik koşullara bağlı uçuş gecikmelerini öngörmenin karmaşık problemini, modern makine öğrenmesi metodolojileriyle başarıyla çözümlemiştir. Çalışma, gecikmeleri hem nicel olarak süre bazında (regresyon) hem de operasyonel risk kategorileri bazında (sınıflandırma) yüksek doğrulukla tahmin eden modeller geliştirmiştir. Bu amaçla, kapsamlı bir veri ön işleme ve probleme özgü özellik mühendisliği sürecinin ardından, regresyon görevi için LightGBM ve CTGAN ile sentetik veri üretimi; sınıflandırma görevi için ise H2O AutoML platformu ile ADASYN ve ek aşırı örnekleme gibi ileri düzey metodolojiler başarıyla uygulanmıştır. Çalışmanın yürütüldüğü Mart 2019-Haziran 2022 dönemi, LTFM'nin operasyonel “ramp-up” sürecini ve küresel COVID-19 pandemisinin etkilerini içermesi açısından özgün bir bağlam sunmuştur.

Çalışmanın temel bulguları şu şekilde özetlenebilir:

Meteorolojik Faktörlerin Gecikmeler Üzerindeki Belirleyici Etkisi: Elde edilen sonuçlar, literatürdeki genel kanıyı destekler nitelikte olup, çeşitli meteorolojik parametrelerin iniş gecikmeleri üzerinde istatistiksel olarak anlamlı ve operasyonel açıdan önemli bir etkiye sahip olduğunu, SHAP analizleriyle net bir şekilde ortaya koymuştur. Özellikle bulut tavanı yüksekliği (BLT0YUK), pist görüş mesafesi (RVR), çeşitli bulut katmanlarının cinsi ve kapallığı ile yağış (YAGIS) ve fırtına (FIRTINA) hadiselerinin gecikmeler üzerinde en belirleyici faktörler arasında olduğu tespit edilmiştir. Düşük görüş koşulları, alçak bulut tavanları ve olumsuz hava hadiseleri, beklendiği gibi gecikmeleri artırmaktadır.

Bu bulgu, havalimanı ve hava trafik yönetimi (ATM) operasyonlarında meteorolojik koşulların proaktif olarak izlenmesinin ve bu koşullara göre kapasite

planlaması yapılmasının önemini vurgular. Özellikle Aletli Uçuş Meteorolojik Şartları- Instrument Meteorological Conditions (IMC) oluşturan faktörlerin, gecikmelerde anahtar rol oynaması, Düşük Görüş Prosedürleri- Low Visibility Procedures (LVP) gibi özel prosedürlerin zamanında ve etkin uygulanmasının yanı sıra, gelişmiş meteorolojik tahmin sistemlerine yatırım yapılmasının gerekliliğini ortaya koyar.

Regresyon Modeli Performansı (LightGBM + CTGAN): Meteorolojik faktörlere bağlı ortalama gecikme süresinin tahmini için geliştirilen LightGBM modeli, özellikle CTGAN ile sentetik veri üretimi stratejisi uygulandıktan sonra başarılı sonuçlar vermiştir. Test seti üzerinde elde edilen yaklaşık 1,29 dakika Ortalama Mutlak Hata (MAE) ve 1,73 dakika Kök Ortalama Karesel Hata (RMSE) değerleri, modelin genel eğilimi yakalayabildiğini göstermektedir. Daha da önemlisi, CTGAN kullanımı sayesinde Belirlilik Katsayısı (R^2) değeri ~%42'ye yükselmiş, bu da modelin özellikle nadir görülen yüksek gecikme olaylarını (≥ 7 dakika) daha iyi öğrendiğini ve genel genelleme kapasitesinin arttığını kanıtlamıştır. CTGAN yönteminin nadir yüksek gecikmeleri öğrenme kapasitesini artırması, operasyonel açıdan en maliyetli ve rahatsız edici durumların öngörülmesinde önemli bir avantaj sağlar. Bu durum, kaynakların (örneğin, bekleme paternleri, yer hizmetleri) daha etkin yönetilmesine yardımcı olabilir.

Sınıflandırma Modeli Performansı (H2O AutoML + ADASYN): Meteorolojik gecikmelerin “Düşük”, “Orta” ve “Yüksek” olarak sınıflandırıldığı problemde, H2O AutoML platformu ile elde edilen sonuçlar olağanüstü bir başarı sergilemiştir. Özellikle, ADASYN ve ek aşırı örnekleme stratejisinin uygulandığı Senaryo 2'de, lider GBM modeli test seti üzerinde ~%98,33 genel doğruluk ve çok düşük bir Logaritmik Kayıp (0.028) değeri elde etmiştir. En dikkat çekici bulgu ise, operasyonel açıdan en kritik olan Sınıf 3 (Yüksek Gecikme) için elde edilen ~%98,61 geri çağırma (recall) oranıdır. Bu, modelin yüksek gecikme durumlarını çok yüksek oranda doğru bir şekilde tespit edebildiğini göstermektedir.

Sınıflandırma modelinin bu yüksek performansı, operasyonel karar vericiler için son derece değerli bir “erken uyarı sistemi” potansiyeli taşır. Özellikle yüksek gecikme sınıfını ~%98'lik bir başarıyla tespit edebilmesi, ATFM uzmanlarının ve havalimanı operatörlerinin, gecikmelerin yayılmasını önlemek veya etkilerini azaltmak için zamanında ve doğru önlemler (örneğin, akış düzenlemeleri, slot tahsislerinin revizyonu, yerdeki bekletmeler) almasına olanak tanır. Bu, operasyonel verimliliği artırır, yolcu memnuniyetini yükseltir ve maliyetleri düşürür.

Veri Dengesizliği ve Örnekleme Tekniklerinin Kritik Rolü: Hem regresyon (CTGAN ile) hem de sınıflandırma (ADASYN ile) problemlerinde uygulanan veri artırma ve dengeleme stratejilerinin, özellikle kritik ve nadir olayların tahmin başarısını dramatik bir şekilde iyileştirdiği gözlemlenmiştir. Bu, bu tür zorlukların üstesinden gelmek için uygulanan stratejilerin kritik önemini ve başarısını göstermektedir.

Havacılık gibi karmaşık ve dinamik sistemlerde nadir ama önemli olayların (ekstrem hava koşulları, çok yüksek gecikmeler) doğru bir şekilde modellenmesi büyük bir zorluktur. Bu çalışmadaki sonuçlar, ADASYN ve CTGAN gibi ileri düzey veri artırma tekniklerinin, bu zorluğun üstesinden gelmede ve modellerin pratik değerini önemli ölçüde artırmada kritik bir rol oynayabileceğini göstermektedir. Bu, benzer veri zorluklarıyla karşılaşan diğer havacılık uygulamaları için de yol gösterici olabilir.

Model Yorumlanabilirliği (SHAP) ve Operasyonel Anlamlılık: Geliştirilen ağaç tabanlı modellerin (LightGBM, GBM) SHAP analizleri ile yorumlanması, modellerin karar verme mekanizmalarının büyük ölçüde meteorolojik alan bilgisi ve operasyonel beklentilerle uyumlu olduğunu göstermiştir. Bu durum, modellerin pratik değerini ve operasyonel kullanıcılar tarafından kabul edilebilirliğini artırmaktadır.

Modellerin “kara kutu” olmaktan çıkarılıp, hangi faktörlere ne ölçüde tepki verdiğinin anlaşılması, bu modellere olan güveni artırır. Operatörler, modelin mantıklı ve beklentilerle uyumlu sonuçlar ürettiğini gördüklerinde, bu tahminlere dayalı kararları daha rahat alabilirler. Ayrıca, hangi meteorolojik faktörlerin daha kritik olduğunu anlamak, izleme ve tahmin sistemlerinde önceliklendirme yapılmasına da yardımcı olabilir.

Sonuç olarak, bu tez çalışması, LTFM gibi stratejik bir havalimanında meteorolojik kaynaklı iniş gecikmelerinin, modern veri bilimi ve makine öğrenmesi teknikleri kullanılarak yüksek bir doğrulukla tahminlenebileceğini ve sınıflandırılabileceğini başarılı bir şekilde ortaya koymuştur. Özellikle veri artırma ve dengeleme stratejilerinin, model performansını, özellikle de operasyonel açıdan kritik olan yüksek gecikme durumlarının tespitinde, olağanüstü düzeyde iyileştirdiği kanıtlanmıştır. Geliştirilen modeller, SHAP analizleri ile desteklendiği üzere, havacılık operasyonlarındaki gerçek dinamiklerle uyumlu ve yorumlanabilir kararlar üretebilmektedir. Bu bulgular, elde edilen modellerin sadece akademik bir başarı olmanın ötesinde, hava trafik akış yönetimi, havalimanı operasyonel planlaması ve kaynak tahsisi gibi alanlarda pratik bir karar destek aracı olarak kullanılabilme potansiyeline sahip olduğunu güçlü bir şekilde

göstermektedir. Meteorolojik faktörlerin gecikmeler üzerindeki karmaşık etkilerinin daha iyi anlaşılması ve öngörülmesi, LTFM'nin operasyonel direncini ve verimliliğini artırmaya yönelik önemli bir adım teşkil etmektedir.

5.2. Modellerin Karşılaştırmalı Analizi ve Operasyonel Tartışma

Bu bölümde, söz konusu iki metodolojinin elde edilen sonuçlar ışığında göreceli üstünlükleri, potansiyel kısıtlılıkları ve operasyonel bir karar destek sistemi çatısı altında nasıl sinerjik bir şekilde kullanılabileceği kapsamlı bir biçimde irdelenmektedir.

5.2.1. Regresyon yaklaşımının değerlendirilmesi

Regresyon modeli, gecikme süresini doğrudan dakika bazında tahmin etmeyi hedefleyerek, operasyonel planlama için çeşitli avantajlar sunmaktadır. Bu yaklaşımın en öne çıkan güçlü yönlerinden biri, şüphesiz sağladığı nicel ve granüler tahmin yeteneğidir. Modelin, gecikmenin spesifik süresini (örneğin, 3 dakika, 17 dakika vb.) öngörebilme potansiyeli, Hava Trafik Akış Yönetimi (ATFM) birimlerinin kapasite-talep dengesi ayarlamaları, yer hizmetleri ve havayolu operasyon merkezlerinin kaynak tahsisi optimizasyonu ve gecikme kaynaklı maliyetlerin detaylı ve proaktif analizi gibi kritik operasyonel ve stratejik planlama faaliyetleri için doğrudan kullanılabilir, yüksek çözünürlüklü bir çıktı sağlamaktadır.

Yapılan çalışmada CTGAN ile desteklenen LightGBM modelinin özellikle yüksek gecikme aralıklarında (≥ 7 dk) MAE değerini 3,09 dakikadan 1,86 dakikaya düşürmesi, bu tahmin hassasiyetinin nadir olaylarda dahi anlamlı olabileceğini göstermiştir. Bir diğer önemli üstünlüğü ise özellik etkilerinin detaylı yorumlanabilirliğidir. SHAP (SHapley Additive exPlanations) analizleri başarıyla uygulandığında hangi meteorolojik faktörlerin (örneğin, bulut taban yüksekliği, pist görüş mesafesi, rüzgâr hızı yönü gibi temel meteorolojik parametreler ve hatta mühendislik ürünü etkileşim terimleri) gecikme süresini ne yönde (artırıcı/azaltıcı) ve ne ölçüde etkilediğine dair ayrıntılı ve nicel içgörüler sunmaktadır. Bu durum, modelin karar verme mekanizmalarını şeffaflaştırarak bir “kara kutu” olmaktan çıkmasına ve operasyonel personelin model tahminlerine olan güveninin artmasına yardımcı olur.

Bununla birlikte, regresyon yaklaşımının doğasında var olan bazı zayıf yönler ve metodolojik zorluklar da göz ardı edilmemelidir. Bu zorluklardan belki de en önemlisi, modelin aşırı değerlere (outliers) karşı olan duyarlılığıdır. Havacılık operasyonlarındaki gecikme verileri, doğası gereği genellikle sağa çarpık (pozitif skewness) bir dağılım

sergilemekte ve nadir fakat çok yüksek (ekstrem) gecikme değerleri içerebilmektedir. Her ne kadar IQR gibi tekniklerle bir miktar aykırı değer temizliği yapılmış ve logaritmik dönüşüm uygulanmış olsa da modelin bu ekstrem uç değerleri tam isabetlilikle tahmin etme kabiliyeti sınırlı kalabilir. Diğer bir kısıtlılık ise, modelin doğrudan operasyonel kategori bilgisi sunmamasıdır. Model, gecikme süresini nicel olarak (örneğin “17 dakika”) tahmin etmekle birlikte, bu sürenin operasyonel açıdan hangi risk seviyesine (örneğin, Düşük Risk, Orta Risk, Acil Eylem Gerektiren Yüksek Risk) tekabül ettiğine dair doğrudan bir kategorik çıkarım sağlamaz. Bu tür bir değerlendirme için, elde edilen nicel tahminlerin operasyonel eşik değerleriyle karşılaştırıldığı ek bir yorumlama veya karar kuralı katmanı gereklidir.

5.2.2. Sınıflandırma yaklaşımının değerlendirilmesi

Sınıflandırma modeli, gecikmeleri önceden belirlenmiş ve operasyonel açıdan doğrudan anlam taşıyan kategorilere (bu çalışmada “Düşük”, “Orta”, “Yüksek” olarak tanımlanan sınıflar) atamayı amaçlayarak, regresyondan farklı ancak son derece değerli avantajlar sergilemektedir. Bu metodolojinin en baskın güçlü yönlerinden biri, sunduğu yüksek operasyonel anlamlılık ve doğrudan eyleme geçirilebilirliktir. Gecikmelerin kategorik olarak (örneğin, “Yüksek Gecikme Riski Mevcut”) sınıflandırılması, hava trafik kontrolörleri, havayolu operasyon merkezleri (OCC), havalimanı yönetimi ve yer hizmetleri gibi paydaşlar için hızlı, net ve kolay anlaşılır bilgiler sunar. Özellikle “Yüksek Gecikme” kategorisine yönelik bir tahmin, zemin bekletmeleri (ground delay programs), uçuş seviyesi veya rota değişiklikleri, hatta alternatif meydan planlamaları gibi proaktif ATFM önlemlerinin zamanında ve etkin bir şekilde devreye alınması için kritik bir tetikleyici olarak işlev görebilir. Bu çalışmada elde edilen sonuçlar, sınıflandırma yaklaşımının, özellikle de ADASYN ve aşırı örnekleme teknikleriyle desteklendiğinde, dengesiz veri kümeleriyle baş etmede kayda değer bir üstünlük sergilediğini göstermiştir. Nadir görülen ancak operasyonel etkisi büyük olan “Yüksek Gecikme” sınıfının dahi %98,6 gibi olağanüstü bir geri çağırma (Recall) oranıyla tanımlanabilmesi, bu stratejinin gücünü açıkça ortaya koymaktadır. Ayrıca, H2O AutoML platformunun kullanımı sayesinde gerçekleştirilen kapsamlı ve otomatik model arayışı, farklı algoritmik yaklaşımların (GBM, DRF, XGBoost, Stacked Ensembles vb.) ve çeşitli hiperparametre konfigürasyonlarının sistematik ve otomatik bir biçimde denenerek, incelenen problem

özelinde en yüksek performansı sunan sınıflandırma modelinin verimli bir şekilde belirlenmesini sağlamıştır.

Diğer yandan, sınıflandırma yaklaşımının da beraberinde getirdiği bazı zayıf yönler ve metodolojik zorluklar mevcuttur. En belirginlerinden biri, nicel süre bilgisinin potansiyel kaybıdır. Sınıflandırma, gecikmenin operasyonel ciddiyeti (şiddeti) hakkında net bir gösterge sunarken (örneğin “Yüksek Risk”), bu kategorinin tam olarak kaç dakikalık bir gecikmeye tekabül ettiği (örneğin, Yüksek gecikme 12 dakika mı, yoksa 45 dakika mı sürecekt?) bilgisini doğrudan vermez; bu detay kategori içinde kaybolur. Bir başka kritik ve dikkatle yönetilmesi gereken husus, modelin performansının ve operasyonel faydasının sınıf tanımları için kullanılan süre eşiklerine olan doğrudan bağımlılığıdır. Hangi süre aralığının “Orta Gecikme” veya “Yüksek Gecikme” olarak kabul edileceği, alan uzmanları ve operasyonel paydaşlarla birlikte dikkatle belirlenmesi gereken, modelin pratik değerini doğrudan etkileyen kritik bir tasarım seçimidir. Son olarak, özellikle AutoML tarafından otomatik olarak bulunan ve genellikle en iyi performansı veren lider modeller (örneğin, Stacked Ensembles), yapıları itibarıyla karmaşık olabilir ve bir “kara kutu” potansiyeli taşıyabilirler. Ancak, bu durum, regresyon modelinde olduğu gibi, SHAP gibi modelden bağımsız yorumlama teknikleri kullanılarak önemli ölçüde hafifletilebilmekte ve modelin karar mantığına dair değerli içgörüler elde edilebilmektedir.

5.3. Araştırmanın Özgün Katkıları

Bu tez çalışması, mevcut literatüre çeşitli ve derinlemesine özgün katkılar sunmaktadır:

Stratejik Bir Mega Hub (LTFM) için Lokalize Modelleme: Bu tez, Avrupa'nın en yeni ve en büyük aktarma merkezlerinden biri olan İstanbul Havalimanı'na (LTFM) spesifik olarak odaklanarak literatürde önemli bir boşluğu doldurmaktadır. LTFM'nin kendine has coğrafi, meteorolojik ve operasyonel özelliklerini, yüksek çözünürlüklü lokal METAR verileriyle modellemesi, daha önceki genel veya farklı havalimanı çalışmalarından ayrılmaktadır.

İleri Düzey Metodolojilerin Bütünleşik Uygulanması: Çalışma, gecikme problemini hem regresyon hem de sınıflandırma olarak ele alırken, her bir problem için literatürdeki en güncel ve güçlü teknikleri probleme özgü bir şekilde entegre etmiştir:

Regresyon için CTGAN Kullanımı: Regresyon probleminde karşılaşılan nadir yüksek gecikme değerleri sorununu çözmek için CTGAN tabanlı sentetik veri üretimini stratejik bir şekilde kullanması ve bu tekniğin R^2 gibi genel model uyumunu ~%42'ye çıkarma etkisini kantitatif olarak ortaya koyması, bu çalışmayı farklılaştırmaktadır.

Sınıflandırma için Güçlü Sinerji: Ciddi derecede dengesiz ve çok sınıflı bir problem için H2O AutoML, ADASYN ve stratejik aşırı örnekleme yaklaşımlarını birleştirmesi, bu kombinasyonun en kritik sınıf (Yüksek Gecikme) için %98 geri çağırma (recall) oranı gibi yüksek bir performans elde etmesini sağlamıştır. Bu başarı, bu tezin en çarpıcı sonuçlarından ve literatüre önemli bir metodolojik katkılarından biridir.

Özgün Operasyonel Dönem Analizi: Çalışma, LTFM'nin “ramp-up” süreci ve COVID-19 pandemisini içeren, meteorolojik faktörlerin etkisini ortaya çıkarma potansiyeli en yüksek benzersiz bir dönemi analiz etmektedir. Bu “ideal olmayan” ve veri açısından zorlu dönemdeki verilerle, CTGAN ve ADASYN gibi veri artırma tekniklerini kullanarak başarılı modeller geliştirilebileceğini göstermesi, çalışmanın önemli bir pratik ve metodolojik katkısıdır.

Yorumlanabilirlik ile Operasyonel Değeri Artırma: Yüksek performanslı modeller geliştirmekle yetinmeyip, SHAP analizlerini kapsamlı bir şekilde kullanarak bu modellerin “kara kutu” olmaktan çıkarılması, hangi meteorolojik faktörlerin gecikmelerde rol oynadığının net bir şekilde ortaya konulması ve böylece operasyonel kabulün artırılması, bu tezin önemli bir özelliğidir.

Eylem Planlarının Basitleştirilmesi ve Otomasyona Uygunluk: Modern hava trafik yönetim sistemleri, artan otomasyon ve dijitalleşmeye dayanmaktadır. Sınıflandırma modelinin ürettiği "Düşük/Orta/Yüksek Risk" gibi ayrık çıktılar, otomatize edilmiş karar destek sistemlerine ve "eğer-öyleyse" (if-then) kural tabanlı sistemlere entegre edilmek için son derece uygundur. Örneğin, modelin "Yüksek Risk" çıktısı, otomatik olarak ilgili personele bir uyarı gönderebilir veya bir sonraki saat dilimi için kapasite planlama parametrelerini otomatik olarak güncelleyebilir. Regresyonun ürettiği sürekli bir değerin (örn. 13,7 dakika) bu tür bir otomasyon sistemine entegrasyonu ise daha karmaşık eşikleme kuralları gerektirir.

Regresyon ve sınıflandırma modelleri farklı sorulara cevap verir. Regresyon, "Ne kadar gecikme bekliyoruz?" sorusunu cevaplayarak maliyet analizi ve kaynak planlaması gibi nicel analizler için temel oluştururken; sınıflandırma, "Mevcut durum ne kadar ciddi ve ne yapmalıyız?" sorusunu cevaplayarak, anlık, taktiksel ve stratejik operasyonel

kararlar için vazgeçilmez, net ve güvenilir bir çerçeve sunar. Özellikle kritik ve nadir olayların tespitindeki kanıtlanmış başarısı, onu sadece bir tahmin aracı değil, güçlü bir risk yönetim aracı haline getirmektedir.

Sonuç olarak bu tez; LTFM gibi stratejik bir bağlama odaklanması, ileri düzey metodolojileri bütünleşik bir yaklaşımla uygulaması, benzersiz bir dönemdeki veri zorluklarını yenilikçi tekniklerle ele alması ve model yorumlanabilirliğini ön plana çıkarması gibi çok boyutlu katkılarla mevcut literatürü zenginleştirmektedir.

5.4. Gelecek Araştırmalar için Öneriler

Bu tez çalışması, havacılık meteorolojisi ve uçuş gecikmesi tahmini alanında önemli bulgular sunsa da problemin daha da derinlemesine araştırılması ve modellerin pratik uygulanabilirliğinin artırılması için çeşitli gelecek çalışma alanları bulunmaktadır. İlk olarak, veri entegrasyonunun zenginleştirilmesi yoluyla modellerin tahmin kapasitesi artırılabilir. Daha uzun vadeli gecikme tahminleri için Terminal Aerodrome Forecast (TAF) ve Sayısal Hava Durumu Modeli (NWP) tahminlerinin entegrasyonu, modellerin proaktif yeteneklerini önemli ölçüde geliştirebilir. Ayrıca, anlık hava sahası sektörü yoğunluğu, pist konfigürasyon değişiklikleri ve uygulanan Hava Trafik Akış Yönetimi (ATFM) önlemleri gibi dinamik operasyonel verilerin modele dahil edilmesi, tahmin doğruluğunu daha da yükseltecektir.

İkinci olarak, model geliştirme ve iyileştirme konusunda derinleşmeler yapılabilir. Özellikle zamansal bağımlılıkları yakalamak için Uzun Kısa Vadeli Bellek Ağları (LSTM) veya transformer tabanlı derin öğrenme modelleri denenebilir. Nokta tahminler yerine, gecikme süresi veya kategorisi için olasılıksal tahminler veya güven aralıkları üreten modeller (örneğin, Quantile Regression, Bayesian metodlar) geliştirilmesi, karar vericilere tahminlerdeki belirsizliği de sunarak daha risk-temelli kararlar almalarına yardımcı olacaktır.

Mevcut çalışmada, H2O AutoML platformu kullanılarak en iyi sınıflandırma modelini bulma sürecinde her senaryo için yaklaşık 22 dakikalık (1320 saniye) bir arama süresi tanımlanmıştır. Bu süre, kapsamlı bir model ve hiper parametre taraması için yeterli olsa da operasyonel bir karar destek sisteminde daha hızlı yanıtlar gerekebilir. Gelecek çalışmalarda, bu model arama süresinin 5 veya 10 dakika gibi daha kısa periyotlara indirilmesi durumunda elde edilecek model performansları ile mevcut sonuçlar karşılaştırılabilir. Böyle bir analiz, model doğruluğu ile hesaplama süresi arasındaki

dengeyi (trade-off) ortaya koyacak ve gerek zamanlı operasyonel kullanım iin "yeterince iyi" modellerin daha kısa srede elde edilip edilemeyeceđini test ederek, metodolojinin pratik uygulanabilirliđi hakkında deđerli bilgiler sunacaktır.

Son olarak, modellerin operasyonel entegrasyonu ve kapsamın geniřletilmesi zerine odaklanılabilir. Geliřtirilen modellerin, LTFM operasyon merkezlerinde kullanılacak gerek zamanlı bir karar destek aracına entegre edilmesi, bu alıřmanın pratik deđerini en st dzeye ıkaracaktır. Bařarılı gecikme tahminlerinin yakıt tketimi, emisyonlar ve operasyonel maliyetler zerindeki potansiyel ekonomik ve evresel faydalarının nicel olarak analiz edilmesi, karar alıcılar iin somut bir deđer nerebilir. Ayrıca, bu alıřmada LTFM iin geliřtirilen modellerin, Transfer đrenmesi teknikleri kullanılarak benzer zelliklere sahip diđer byk havalimanlarına ne lde uyarlanabileceđi arařtırılabilir.

Bu neriler, havacılık meteorolojisi ile hava trafik ynetimi alanlarında veri bilimi uygulamalarının daha da geliřtirilmesi ve havacılık sektrnn daha emniyetli, verimli ve direnli hale gelmesine katkı sađlaması beklenen potansiyel arařtırma yolları sunmaktadır.

KAYNAKÇA

- [1] Hatipoğlu, I. and Tosun, Ö. (2024). Predictive modeling of flight delays at an airport using machine learning methods. *Applied Sciences*, 14 (13), 5472. <https://doi.org/10.3390/app14135472>
- [2] Alfarhood, M., Alotaibi, R., Abdulrahim, B., Einieh, A., Almousa, M. and Alkhanifer, A. (2024). Predicting flight delays with machine learning: A case study from Saudi Arabian Airlines. *International Journal of Aerospace Engineering*, 2024, 3385463. <https://doi.org/10.1155/2024/3385463>
- [3] Giannikas, V., Ledwoch, A., Stojković, G., Costas, P., Brintrup, A., Saeed Al-Ali, A. A., Chauhan, V. K. and McFarlane, D. (2022). A data-driven method to assess the causes and impact of delay propagation in air transportation systems. *Transportation Research Part C: Emerging Technologies*, 143, 103862. <https://doi.org/10.1016/j.trc.2022.103862>
- [4] Wang, F., Bi, J., Xie, D. and Zhao, X. (2022). Flight delay forecasting and analysis of direct and indirect factors. *IET Intelligent Transport Systems*, 16, 890–907. <https://doi.org/10.1049/itr2.12183>
- [5] EUROCONTROL. (2024). All-causes delays to air transport in Europe: Annual 2023. *CODA Digest*. <https://www.eurocontrol.int/publication/all-causes-delays-air-transport-europe-annual-2023> (Erişim tarihi: 20.10.2024)
- [6] Li, N. and Yao, H. G. (2025). A review of research on flight delay propagation: Current situation and prospect. *Journal of Advanced Transportation*, 2025, 4851103. <https://doi.org/10.1155/atr/4851103>
- [7] Eurocontrol Central Office for Delays Analysis. (2025). European airspace delay data and monthly event summaries. <https://ext.eurocontrol.int/> (Erişim tarihi: 05.12.2023)
- [8] Oo, K. T. and Oo, K. L. (2022). Analysis of the most common aviation weather hazard and its key mechanisms over the Yangon flight information region. *Advances in Meteorology*, 2022, 5356563. <https://doi.org/10.1155/2022/5356563>
- [9] Bazargan, M. (2010). *Airline operations and scheduling* (2.nd ed.). Abingdon: Routledge. <https://doi.org/10.4324/9781315566474>
- [10] Rosenow, J., Michling, P., Schultz, M. and Schönberger, J. (2020). Evaluation of strategies to reduce the cost impacts of flight delays on total network costs. *Aerospace*, 7 (11), 165. <https://doi.org/10.3390/aerospace7110165>
- [11] Dissanayaka, D. M. M. S., Adikariwattage, V. and Pasindu, H. R. (2020). Evaluation of CO₂ emission from flight delays at taxiing phase in Bandaranaike

- International Airport (BIA). *Transportation Research Procedia*, 48, 2108-2126. <https://doi.org/10.1016/j.trpro.2020.08.270>
- [12] Natarajan, V., Meenakshisundaram, S., Balasubramanian, G. and Sinha, S. (2018). A novel approach: Airline delay prediction using machine learning. *2018 IEEE International Conference on Computational Science and Communication*, 1081-1086. <https://doi.org/10.1109/CSCI46756.2018.00210>
- [13] Khan, W. A., Chung, S. H., Eltoukhy, A. E. E. and Khurshid, F. (2024). A novel parallel series data-driven model for IATA-coded flight delays prediction and features analysis. *Journal of Air Transport Management*, 114, 102488. <https://doi.org/10.1016/j.jairtraman.2023.102488>
- [14] Biswas, M. E., Sultana, T., Mandal, A. K., Morshed, M. G. and Hossain, M. D. (2024). Spatio-temporal feature engineering and selection-based flight arrival delay prediction using deep feedforward regression network. *Electronics*, 13(24), 4910. <https://doi.org/10.3390/electronics13244910>
- [15] International Air Transport Association (IATA). *Delay codes*. <https://ansperformance.eu/library/iata-delay-codes.pdf> (Erişim tarihi: 20.10.2024)
- [16] International Air Transport Association. *IATA delay codes*. <https://ansperformance.eu/definition/iata-delay-codes/> (Erişim tarihi: 20.10.2024)
- [17] Federal Aviation Administration. *Types of delay*. https://aspm.faa.gov/aspmhelp/index/Types_of_Delay.html (Erişim tarihi: 20.10.2024)
- [18] Bureau of Transportation Statistics. (2024). *Understanding the reporting of causes of flight delays and cancellations*. <https://www.bts.gov/topics/airlines-and-airports/understanding-reporting-causes-flight-delays-and-cancellations> (Erişim tarihi: 20.10.2024)
- [19] Rupp, N. G. (2007). *Further investigations into the causes of flight delays*. Department of Economics, East Carolina University. <https://economics.ecu.edu/wp-content/pv-uploads/sites/165/2019/07/ecu0707.pdf> (Erişim tarihi: 27.10.2024)
- [20] Zámková, M., Prokop, M. and Stolín, R. (2017). Factors influencing flight delays of a European airline. *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis*, 65 (5), 1799–1807. <https://doi.org/10.11118/actaun201765051799>
- [21] ICAO. (2008). *Manual on low-visibility operations (Doc 9817)*. Montreal.

- [22] Khattak, A., Chan, P. W., Chen, F., Peng, H. and Matara, C. M. (2023). Missed approach, a safety-critical go-around procedure in aviation: Prediction based on machine learning-ensemble imbalance learning. *Advances in Meteorology*, 2023, 9119521. <https://doi.org/10.1155/2023/9119521>
- [23] Milošević, S., Šelmić, M., Nikolić, M. and Mirković, B. (2024). Prediction of flight delays due to the aircraft de-icing and anti-icing process using Artificial Neural Network. *Transportation Research Procedia*, 81, 187-194. <https://doi.org/10.1016/j.trpro.2024.11.020>
- [24] Sanaei, R. (2024). Exploratory research on European ATM network resilience through supervised learning. <https://doi.org/10.57676/wn5j-e845>
- [25] Hastie, T., Tibshirani, R. and Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2.nd ed.). New York: Springer. <https://doi.org/10.1007/978-0-387-84858-7>
- [26] Gui, G., Liu, F., Sun, J., Yang, J., Zhou, Z. and Zhao, D. (2020). Flight delay prediction based on aviation big data and machine learning. *IEEE Transactions on Vehicular Technology*, 69 (1), 140–150. <https://doi.org/10.1109/TVT.2019.2954094>
- [27] Tu, Y., Ball, M. and Jank, W. (2008). Estimating flight departure delay distributions, a statistical approach with long-term trend and short-term pattern. *Journal of the American Statistical Association*. <https://doi.org/10.2139/ssrn.923628>
- [28] Nigam, R. and Govinda, K. (2017). Cloud based flight delay prediction using logistic regression. *2017 International Conference on Intelligent Sustainable Systems (ICISS)*. <https://doi.org/10.1109/ISS1.2017.8389254>
- [29] Özmen, A. ve Poyraz, K. (2015). Zaman serilerini mevsimlik etkiden arındırmada uygun tekniğin belirlenmesine ilişkin bir yaklaşım. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, (3).
- [30] Thiagarajan, B., Srinivasan, L., Sharma, A., Sreekanthan, D. and Vijayaraghavan, V. (2017). A machine learning approach for prediction of on-time performance of flights. *2017 IEEE/AIAA 36th Digital Avionics Systems Conference (DASC)*. <https://doi.org/10.1109/DASC.2017.8102138>
- [31] Varenna, S., Li, H., Ribeiro, M. and Santos, B. F. (2025). Stochastic discrete event simulation of airline network and maintenance operations. *Journal of Air Transport Management*, 125, 102789. <https://doi.org/10.1016/j.jairtraman.2025.102789>

- [32] Liu, F., Sun, J., Liu, M., Yang, J. and Gui, G. (2020). Generalized flight delay prediction method using gradient boosting decision tree. *2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring)*. <https://doi.org/10.1109/VTC2020-Spring48590.2020.9129110>
- [33] Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Corrado, G. S., Davis, A., Dean, J., Devin, M., Ghemawat, S., Goodfellow, I., Harp, A., Irving, G., Isard, M., Jia, Y., Jozefowicz, R., Kaiser, L., Kudlur, M. and Zheng, X. (2016). TensorFlow: Large-scale machine learning on heterogeneous distributed systems. <https://doi.org/10.48550/arXiv.1603.04467>
- [34] Basturk, O. and Cetek, C. (2021). Prediction of aircraft estimated time of arrival using machine learning methods. *The Aeronautical Journal*, 125 (1289), 1245-1259. <https://doi.org/10.1017/aer.2021.13>
- [35] Lian, G., Zhang, Y., Desai, J., Xing, Z. and Luo, X. (2018). Predicting taxi-out time at congested airports with optimization-based support vector regression methods. *Mathematical Problems in Engineering*, 2018. <https://doi.org/10.1155/2018/7509508>
- [36] Ferreira, L., Pilastrri, A., Martins, C., Pires, P. and Cortez, P. (2021). A comparison of AutoML tools for machine learning, deep learning and XGBoost. *2021 International Joint Conference on Neural Networks (IJCNN)*, 1-8. <https://doi.org/10.1109/IJCNN52387.2021.9534091>
- [37] Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q. and Liu, T. Y. (2017). LightGBM: A highly efficient gradient boosting decision tree. *Proceedings of the 31st International Conference on Neural Information Processing System*, 3149–3157. Red Hook, NY: Curran Associates Inc.
- [38] Hancock, J. T. and Khoshgoftaar, T. M. (2020). CatBoost for big data: An interdisciplinary review. *Journal of Big Data*, 7 (1), 94. <https://doi.org/10.1186/s40537-020-00369-8>
- [39] Anderson, A., Kumar, A. and Christopher, A. (2019). Analysis of flight delays in aviation system using different classification algorithms and feature selection methods. *The Aeronautical Journal*, 123 (1267), 1415-1436 <https://doi.org/10.1017/aer.2019.72>
- [40] Zheng, A. and Casari, A. (2018). *Feature engineering for machine learning: Principles and techniques for data scientists*. Sebastopol, CA: O'Reilly Media.
- [41] Hutter, F., Kotthoff, L. and Vanschoren, J. (Eds.). (2019). *Automated machine learning: Methods, systems, challenges*. Cham: Springer. <https://doi.org/10.1007/978-3-030-05318-5>

- [42] Kuhn, M. and Johnson, K. (2013). *Applied predictive modeling*. New York: Springer. <https://doi.org/10.1007/978-1-4614-6849-3>
- [43] He, H., Bai, Y., Garcia, E. A. and Li, S. (2008). ADASYN: Adaptive synthetic sampling approach for imbalanced learning. *2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)*. Hong Kong. <https://doi.org/10.1109/IJCNN.2008.4633969>
- [44] Parise, O., Kronenberger, R., Parise, G., De Asmundis, C., Gelsomino, S. and La Meir, M. (2025). CTGAN-driven synthetic data generation: A multidisciplinary, expert-guided approach (TIMA). *Computer Methods and Programs in Biomedicine*, 259, 108523. <https://doi.org/10.1016/j.cmpb.2024.108523>
- [45] Ribó, M. B. (2024). *Explainable machine learning using SHAP: An application in Alzheimer's disease diagnosis*. Dipòsit Digital de la Universitat de Barcelona. <http://hdl.handle.net/2445/210860> (Erişim tarihi: 20.10.2025)
- [46] Branco, P., Torgo, L. and Ribeiro, R. P. (2016). A survey of predictive modeling on imbalanced domains. *ACM Computing Surveys*, 49 (2), 1–50. <https://doi.org/10.1145/2907070>
- [47] Chawla, N. V., Bowyer, K. W., Hall, L. O. and Kegelmeyer, W. P. (2002). SMOTE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321–357. <https://doi.org/10.1613/jair.953>
- [48] Yu, B., Guo, Z., Asian, S., Wang, H. and Chen, G. (2019). Flight delay prediction for commercial air transport: A deep learning approach. *Transportation Research Part E: Logistics and Transportation Review*, 125, 203–221. <https://doi.org/10.1016/j.tre.2019.03.013>
- [49] Enea, G., Reynolds, T., Weber, M., Dalmau, R. and Schaefer, D. (2024). Analysis of weather-driven air traffic management challenges for major U.S. and European Airports. https://www.sesarju.eu/sites/default/files/documents/sid/2024/papers/SIDs_2024_paper_106_final.pdf (Erişim tarihi: 20.10.2025)
- [50] Wu, Y., Mei, G. and Shao, K. (2022). Revealing influence of meteorological conditions and flight factors on delays using XGBoost. *Journal of Computational Mathematics and Data Science*, 3, 100030. <https://doi.org/10.1016/j.jcmds.2022.100030>
- [51] Wang, X., Wang, Z., Wan, L. and Tian, Y. (2022). Prediction of flight delays at Beijing Capital International Airport based on ensemble methods. *Applied Sciences*, 12 (20), 10621. <https://doi.org/10.3390/app122010621>

- [52] Kim, K., Lee, H., Lee, M., Bae, Y. H., Kim, H. S. and Kim, S. (2023). Analysis of weather factors on aircraft cancellation using a multilayer complex network. *Entropy*, 25 (8), 1209. <https://doi.org/10.3390/e25081209>
- [53] Bubalo, B. and Gaggero, A. A. (2021). Flight delays in European airline networks. *Research in Transportation Business and Management*, 41, 100631. <https://doi.org/10.1016/j.rtbm.2021.100631>
- [54] Khan, R., Akbar, S. and Ali Zahed, T. (2022). Flight delay prediction based on gradient boosting ensemble techniques. *2022 25th International Conference on Computer and Information Technology (ICOSST)*, 1-5. <https://doi.org/10.1109/ICOSST57195.2022.10016828>
- [55] Mamdouh, M., Ezzat, M. and Hefny, H. (2023). A novel intelligent approach for flight delay prediction. *Journal of Big Data*. <https://doi.org/10.1186/s40537-023-00854-w>
- [56] Deng, C., Zhang, Q., Zhang, H., Li, J. and Ning, C. (2023). Research on rapid congestion identification method based on TSNE-FCM and LightGBM. *Sustainability*, 15 (14), 11322. <https://doi.org/10.3390/su151411322>
- [57] Zhao, Z., Feng, S., Song, M. and Liang, Q. (2022). A delay prediction method for the whole process of transit flight. *Aerospace*, 9 (11), 645. <https://doi.org/10.3390/aerospace9110645>
- [58] LeDell, E. and Poirier, S. (2020). H2O AutoML: Scalable automatic machine learning. *Proceedings of the 7th ICML Workshop on Automated Machine Learning*. https://www.automl.org/wp-content/uploads/2020/07/AutoML_2020_paper_61.pdf (Erişim tarihi: 20.10.2025)
- [59] Khan, M. A., Iqbal, N., Imran, Jamil, H. and Kim, D. H. (2023). An optimized ensemble prediction model using AutoML based on soft voting classifier for network intrusion detection. *Journal of Network and Computer Applications*, 212, 103560. <https://doi.org/10.1016/j.jnca.2022.103560>
- [60] Schwarz, P. (2022). *Stacking ensemble classification applied to US flight delay prediction during the COVID-19 pandemic*. Uppsala University. <https://urn.kb.se/resolve?urn=urn:nbn:se:uu:diva-489493> (Erişim tarihi: 20.10.2025)
- [61] Celik, B. and Vanschoren, J. (2021). Adaptation strategies for automated machine learning on evolving data. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43 (9), 3067-3078. <https://doi.org/10.1109/TPAMI.2021.3062900>

- [62] Teji, J. S., Jain, S., Gupta, S. K. and Suri, J. S. (2022). NeoAI 1.0: Machine learning-based paradigm for prediction of neonatal and infant risk of death. *Computers in Biology and Medicine*, 147, 105639. <https://doi.org/10.1016/j.compbiomed.2022.105639>
- [63] Chen, H., Tan, C., Lin, Z., Chen, M. and Cheng, B. (2024). Applying virtual sample generation and ensemble modeling for improving the spectral diagnosis of cancer. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 318, 124518. <https://doi.org/10.1016/j.saa.2024.124518>
- [64] Assegie, T. A., Salau, A. O., Sampath, K., Govindarajan, R., Murugan, S. and Lakshmi, B. (2024). Evaluation of adaptive synthetic resampling technique for imbalanced breast cancer identification. *Procedia Computer Science*, 235, 1000-1007. <https://doi.org/10.1016/j.procs.2024.04.095>
- [65] Wadhwa, K., Kumari, R. and Gosain, A. (2025). Enhancing model performance in hybrid class imbalance techniques. *Procedia Computer Science*, 258, 288-297. <https://doi.org/10.1016/j.procs.2025.04.266>
- [66] Xu, L., Skoularidou, M., Cuesta-Infante, A. and Veeramachaneni, K. (2019). Modeling tabular data using conditional GAN. <https://doi.org/10.48550/arXiv.1907.00503>
- [67] Agarwal, L., Jaint, B. and Mandpura, A. K. (2024). Reducing overfitting in deep learning intrusion detection for power systems with CTGAN. *Chaos, Solitons and Fractals*, 188, 115603. <https://doi.org/10.1016/j.chaos.2024.115603>
- [68] Habibi, O., Chemmakha, M. and Lazaar, M. (2023). Imbalanced tabular data modelization using CTGAN and machine learning to improve IoT botnet attacks detection. *Engineering Applications of Artificial Intelligence*, 118, 105669. <https://doi.org/10.1016/j.engappai.2022.105669>
- [69] Engelmann, J. and Lessmann, S. (2021). Conditional Wasserstein GAN-based oversampling of tabular data for imbalanced learning. *Expert Systems with Applications*, 174, 114582. <https://doi.org/10.1016/j.eswa.2021.114582>
- [70] Wang, K., Zhou, T., Luo, M., Li, X. and Cai, Z. (2024). Generative adversarial minority enlargement-A local linear over-sampling synthetic method. *Expert Systems with Applications*, 237, 121696. <https://doi.org/10.1016/j.eswa.2023.121696>
- [71] DHMİ. (2024). *AIP Türkiye*. <https://dhmi.gov.tr/Sayfalar/aipturkey.aspx> (Erişim tarihi: 11.11.2024)

- [72] Eurocontrol. *Airport arrival ATFM delay*. https://www.eurocontrol.int/performance/data/download/xls/Airport_Arrival_ATFM_Delay.xlsx (Erişim tarihi: 19.11.2024)
- [73] ICAO. (2023). *Annex 3-Meteorological service for international air navigation* (20.th.ed.). https://applications.icao.int/postalhistory/annex_3_meteorological_service_for_international_air_navigation.html (Erişim tarihi: 05.03.2024)
- [74] WMO. (2019). *Manual on codes (WMO-No. 306, Vol. I.1, Part A)*. <https://community.wmo.int/en/activity-areas/wis/publications/306-vI.1> (Erişim tarihi: 07.04.2024)
- [75] ICAO. (2021). Effects of novel coronavirus (COVID-19) on civil aviation: Economic impact analysis. <https://www.icao.int/sites/default/files/sp-files/sustainability/Documents/COVID-19/ICAO%20COVID%202021%2012%2021%20Economic%20Impact%20TH%20Toru.pdf> (Erişim tarihi: 16.05.2024)
- [76] Eurocontrol. (2021). EUROCONTROL comprehensive assessment of COVID-19's impact on European aviation. <https://www.eurocontrol.int/sites/default/files/2021-12/covid19-eurocontrol-comprehensive-air-traffic-assessment-16122021.pdf> (Erişim tarihi: 16.05.2024)
- [77] Heiets, I., and Xie, Y. (2021). The Impact of the COVID-19 Pandemic on the Aviation Industry. *Journal of Aviation*, 5 (2), 111-126. <https://doi.org/10.30518/jav.933296>
- [78] Guyon, I. and Elisseeff, A. (2003). An introduction of variable and feature selection. *Journal of Machine Learning Research*, 3, 1157-1182. <https://doi.org/10.1162/153244303322753616>
- [79] Colliot, O. (Ed.). (2023). Machine learning for brain disorders. New York, NY: Humana <https://doi.org/10.1007/978-1-0716-3195-9>
- [80] Stancin, I. and Jovic, A. (2019). An overview and comparison of free Python libraries for data mining and big data analysis. *2019 42nd International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, 977-982. <https://doi.org/10.23919/MIPRO.2019.8757088>
- [81] Lemaître, G., Nogueira, F. and Aridas, C. K. (2017). Imbalanced-learn: A python toolbox to tackle the curse of imbalanced datasets in machine learning. *Journal of Machine Learning Research*, 18 (17), 1–5. <https://doi.org/10.48550/arXiv.1609.06570>

- [82] Spiess, A. N. and Neumeyer, N. (2010). An evaluation of R2 as an inadequate measure for nonlinear models in pharmacological and biochemical research: A Monte Carlo approach. *BMC Pharmacology*, 10 (1), 6. <https://doi.org/10.1186/1471-2210-10-6>
- http-1: <https://www.igairport.aero/tr/iga-dunyasi/hakkimizda/biz-kimiz> (Erişim tarihi: 24.10.2024)
- http-2: <https://www.aa.com.tr/en/turkiye/istanbul-airport-keeps-crown-of-europe-s-busiest-air-hub-in-2024/3460499> (Erişim tarihi: 31.10.2024)
- http-3: <https://mevbis.mgm.gov.tr/mevbis/ui/index.html#/Workspace> (Erişim Tarihi: 01.12.2023)
- http-4: <https://ext.eurocontrol.int/> (Erişim Tarihi: 09.12.2023)
- http-5: <https://www.aa.com.tr/tr/turkiye/buyuk-gocun-yuzde-96si-tamamlandi/1444163> (Erişim Tarihi: 15.08.2024)
- http-6: <https://docs.h2o.ai/h2o/latest-stable/h2o-docs/automl.html> (Erişim Tarihi: 01.09.2024).

ÖZGEÇMİŞ

ORCID NO: 0000-0001-7163-3911

Ad Soyad : Mustafa Servet ÖZÇINAR

Yabancı Dil : İngilizce

Eğitim:

- Hava Harp Okulu / Havacılık ve Uzay Mühendisliği

