

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

UÇAK BAKIMLARININ GÜRBÜZ (ROBUST) PLANLANMASI

MEHMET İKBAL KARACA

YÜKSEK LİSANS TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

DANIŞMAN: DR. ÖĞR. ÜYESİ FİGEN ÖZTOPRAK TOPKAYA

ŞUBAT 2025

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

UÇAK BAKIMLARININ GÜRBÜZ (ROBUST)
PLANLANMASI

MEHMET İKBAL KARACA

YÜKSEK LİSANS TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

DANIŞMAN: DR. ÖĞR. ÜYESİ FİGEN ÖZTOPRAK TOPKAYA

ŞUBAT 2025

T.R.
GEBZE TECHNICAL UNIVERSITY
GRADUATE SCHOOL

ROBUST PLANNING OF AIRCRAFT MAINTENANCE



MEHMET İKBAL KARACA

A THESIS OF MASTER OF SCIENCE
DEPARTMENT OF INDUSTRIAL ENGINEERING

ADVISOR: ASSIST PROF. FİGEN ÖZTOPRAK TOPKAYA

FEBRUARY 2025

YÜKSEK LİSANS JÜRİ ONAY FORMU

GTÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulunun 03/02/2025 tarih ve 2025/08 sayılı kararıyla oluşturulan jüri tarafından 17/02/2025 tarihinde tez savunma sınavı yapılan Mehmet İkbal KARACA'nın tez çalışması Endüstri Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI) : Dr. Öğr. Üyesi Figen ÖZTOPRAK TOPKAYA

ÜYE

: Dr. Öğr. Üyesi Özgür UNSAL

ÜYE

: Dr. Öğr. Üyesi Umman Mahir YILDIRIM

ONAY

Gebze Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Yönetim Kurulunun

..../..../..... tarih ve sayılı kararı.

İMZA/MÜHÜR



Aileme...

ÖZET

Havayolları arasındaki artan rekabet, her operatörün operasyonlarındaki verimliliğini artırmalarını zorunlu kılmaktadır. Havayolları, genellikle uygulanacak bakım görevlerinin büyük çoğunluğunu, harf kontrolleri (A, B, C) olarak adlandırılan kapsamlı kontrollerde bakım paketinde bir araya getirerek çalışmaktadır. Her bakım tipi için uçakta yapılacak incelemeler ve bakım işlemleri büyük ölçüde standarttır. Bu işlemlerin her birisi 'görev kartları' denilen kartlar kullanılarak tanımlanır. Elbette yapılacak işlemler belirli öncelik-sonralık ilişkilerine sahiptir. Örneğin, koltuklar sökülmeden zemin panelinin denetimi yapılamaz. Dolayısıyla, bakım sürecinin tamamı bir proje süreci olarak tanımlanabilir. Tüm bakımın nihai tamamlanma süresi, bakım kartlarının alacağı süreler ve bu kartların tanımladığı işlemlerin öncelik ilişkilerine bağlıdır.

Bu tez çalışmasını bir uçak bakım firmasında planlama departmanında karşılaşılan pratik bir sorun motive etmiştir: Planlamada öngörülen bakım süreleri ile gerçekleşen bakım süreleri önemli derecede farklılıklar gösterebilmektedir. Bunun nedeni incelendiğinde, rutin bakım kartlarının yanı sıra, uçağın denetimi sırasında fark edilen ek problemler sebebiyle (onarım, vb. bakım gereksinimleri) çok sayıda rutin-olmayan bakım kartlarının da üretildiği görülmüştür. Örneğin koltukların görsel denetimi rutin bir işlemdir, ancak koltukta yırtık varsa bunun değiştirilmesi rutin-olmayan bir işlemdir. Bu tür ek rutin-olmayan işlemlerin içeriğine göre planlamadan çok büyük sapmalar oluşabilmektedir; halbuki hem operatör hem de bakım kuruluşunun beklentisi bakım tamamlanma süresinin ve adam saatinin planlanandan düşük bir tolerans limiti içerisinde gerçekleşmesidir.

Gürbüz eniyileme, belirsizlikleri matematiksel modele bir küme olarak dahil ederek, tüm belirsizlik kümesi üzerindeki en iyi çözümleri hesaplamayı amaçlayan bir yaklaşımdır. Yakın zaman önce önerilmiş olmasına rağmen oldukça popüler hale gelmiş bir yaklaşımdır çünkü klasik stokastik optimizasyon çerçevesinden farklı olarak problemdeki belirsizliklerin bilinen belirli bir olasılık dağılımından geldiği varsayımına dayanmaz. Bunun yerine belirsizlik içeren verilerin belirli bir kümede bulunduğunu varsayar.

Açıkça görülebileceği gibi gürbüz eniyileme açısından en kritik konulardan birisi bu belirsizlik kümelerinin tanımlanmasıdır. Bizim uygulama problemimiz özelinde bu, her bir bakım tipi için rutin-olmayan kartlarla ortaya çıkan ek bakım sürelerinin yarattığı belirsizliğin modellenmesini gerektirmektedir. Esasında bu belirsizlik tamamen rassal değildir; uçağın yaşı ve tipi, uçuş süresi, bakımın tipi, vb. faktörler rutin-olmayan bakım ihtiyaçlarını büyük ölçüde etkilemektedir. Bu tez çalışmasının ilk bölümünde, bu ilişkiyi makina öğrenmesi teknikleri ile önceki bakım verilerinden öğrenme fikri üzerinde durulmuştur. Seçilen iki bakım kartının verileri ve farklı makina öğrenmesi teknikleriyle kapsamlı bir deneysel çalışma yapılmıştır.

Çalışmanın ikinci bölümünde, bakım planlama probleminin matematiksel modeli kurulmuştur. Burada, örnek bir bakım için ve farklı gerçekleşme senaryoları düşünülerek gürbüz çözümlerin etkinliği incelenmiştir. Belirsizlik kümesini bir önceki bölümdeki tahmin modellerine dayandırarak gerçekleştirilen gürbüz optimizasyon, en kötü durum senaryosu da dahil olmak üzere uygun planlama sonuçları vermiştir.

Anahtar Kelimeler: Gürbüz Optimizasyon, Makine Öğrenim Yöntemleri, Uçak Bakım

ABSTRACT

The increasing competition among airlines necessitates that every operator enhances the efficiency of their operations. Airlines typically consolidate most of the maintenance tasks to be performed into maintenance packages, referred to as letter checks (A, B, C), which are comprehensive inspections. For each type of maintenance, the inspections and maintenance tasks to be carried out on the aircraft are largely standardized. Each of these tasks is defined using "task cards." Naturally, these tasks are subject to specific precedence relationships. For instance, floor panel inspections cannot be performed without first removing the seats. Thus, the entire maintenance process can be defined as a project process. The final completion time of maintenance depends on the durations of the task cards and the precedence relationships defined by these cards.

This thesis is motivated by a practical problem encountered in the planning department of an aircraft maintenance company: there are significant deviations between the planned maintenance durations and the actual maintenance durations. Upon investigation, it was found that, in addition to routine task cards, a substantial number of non-routine task cards are also generated due to additional problems identified during aircraft inspections (repairs, maintenance requirements, etc.). For instance, the visual inspection of seats is a routine task, but replacing a torn seat is a non-routine task. Depending on the nature of such additional non-routine tasks, significant deviations from the initial plan can occur. However, both the operator and the maintenance organization expect the maintenance completion time and man-hours to remain within a tolerable deviation from the plan.

Robust optimization is an approach that aims to compute the best solutions over an entire set of uncertainties by incorporating these uncertainties into the mathematical model as a set. Despite being a relatively recent concept, it has gained significant popularity because, unlike classical stochastic optimization, it does not assume that the uncertainties in the problem follow a known probability distribution. Instead, it assumes that the data containing uncertainties lie within a specific set.

As can be clearly seen, one of the most critical aspects of robust optimization is defining these uncertainty sets. In the context of our application problem, this requires modeling the uncertainties caused by the additional maintenance durations arising from non-routine task cards for each type of maintenance. In essence, this uncertainty is not entirely random; factors such as the aircraft's age and type, flight duration, and type of maintenance significantly influence the need for non-routine maintenance.

In the first part of this thesis, the idea of learning this relationship from historical maintenance data using machine learning techniques was explored. A comprehensive experimental study was conducted with data from two selected task cards and various machine learning techniques.

In the second part of the study, a mathematical model of the maintenance planning problem was developed. The effectiveness of robust solutions was examined by considering different realization scenarios for a sample maintenance case. Robust optimization, performed by basing the uncertainty set on the predictive models from the previous section, provided feasible planning outcomes, including the worst-case scenario.

Keywords: Robust Optimization, Machine Learning Methods, Aircraft Maintenance

TEŞEKKÜR

Yüksek Lisans tez sürecim boyunca bana rehberlik eden, sabır gösteren, teşvik eden ve tavsiyelerini esirgemeyen danışmanım Dr. Öğr.Üyesi Figen ÖZTOPRAK TOPKAYA'ya şükranlarımı ve içten teşekkürlerimi sunarım.

Bu süreçte bana olan desteği ve sabrı için çok kıymetli eşime ve biricik oğluma sonsuz teşekkürlerimi sunuyorum. Hayatım boyunca her an yanımda olan, destekleri ve motivasyonları ile bana sürekli katkı sağlayan aileme teşekkür ederim.

Yüksek Lisans eğitimim boyunca TÜBİTAK Bilim İnsanı Destek Programları Başkanlığı'na (BİDEB) 2210-D Programı kapsamında vermiş oldukları burs desteği dolayısıyla teşekkür ederim.



İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	vi
ABSTRACT	vii
TEŞEKKÜR	viii
İÇİNDEKİLER	ix
SİMGELER ve KISALTMALAR DİZİNİ	xi
ŞEKİLLER DİZİNİ	xii
TABLOLAR DİZİNİ	xiii
1. GİRİŞ	1
1.1. Problem Tanımı	5
1.2. Tez Çalışmasının Amacı ve Kapsamı	6
2. UÇAK BAKIM VE ONARIM SÜREÇLERİ	8
2.1. Uçak Bakım Süreçlerine İlişkin Temel Bilgiler	8
2.2. Bakım Kartları	12
3. BELİRSİZLİK MODELLEME	15
3.1. Literatür	15
3.2. Arka Plan	16
3.2.1. Makine Öğrenmesi	16
3.2.2. Doğrusal Regresyon	19
3.2.3. Polinomsal Regresyon	20
3.2.4. Düzenlileştirme	21
3.2.5. Rastgele Orman Regresyon	22
3.2.6. Gradyan Arttırma Regresyon	24
3.3. Uygulama	24
3.3.1. Veriler	24
3.3.2. Veri Önileme	25
3.3.3. Uygulama Detayları ve Deneysel Kurgu	27
3.3.4. Sonuçlar	37
4. GÜRBÜZ(ROBUST) PLANLAMA	41
4.1. Literatür	41
4.2. Model	44
4.2.1. Parametreler	45
4.2.2. Değişkenler	45
4.2.3. Matematiksel Model	46
4.2.4. Kısıtlar	47
4.3. Gürbüz Formülasyon	49
4.4. Testler	50
4.4.1. Deney Tasarımı	50
4.4.2. Sonuçlar	51
4.4.3. Değerlendirmeler	53
5. SONUÇ VE DEĞERLENDİRMELER	57

KAYNAKLAR	60
ÖZGEÇMİŞ	63
TEZ METNİNDEN TÜRETİLEN YAYINLAR/SUNUMLAR	64



SİMGELER ve KISALTMALAR DİZİNİ

TAT	: Turn around Time (Dönüş Süresi)
CAA	: Civil Aviation Authority- Sivil Havacılık Otoritesi
MRO	: Maintenance, Repair and Overhaul-Uçak Bakım Kuruluşu
SHGM	: Sivil Havacılık Genel Müdürlüğü
MOE	: Maintenance Organisation Exposition
ICAO	: International Civil Aviation Organization
EASA	: European Aviation Safety Agency
FAA	: Federal Aviation Administration
AMP	: Aircraft Maintenance Planning
ML	: Machine Learning (Makine Öğrenmesi)
MPD	: Maintenance Planning Document (Bakım Planlama Dokümanı)
MRI	: Minimum Requirement Inspection (Minimum Gerekli muayene)
AMM	: Aircraft Maintenance Manuel (Uçak Bakım Kılavuzu)
RF	: Random Forest (Rastgele Orman)
OAM	: Original Aircraft Manufacturer
OHE	: One Hot Encoding
MSE	: Mean Squared Error
RPK	: Revenue Passenger Kilometers (Ücretli Yolcu Kilometre)
IATA	: International Air Transport Association (Uluslararası Hava Taşımacılığı Birliği)

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 1.1: Küresel RPK'lar (Ocak 2020'den Aralık 2022'ye kadar)	1
Şekil 1.2: Küresel MRO Harcama Tahmini (2019-2033)	3
Şekil 3.1: Doğrusal Regresyon Grafiği	20
Şekil 3.2: Rastgele Orman Teknik Görseli	23
Şekil 3.3: Kabin ısı haritası	30
Şekil 3.4: Koltuk ısı haritası	30
Şekil 4.1: Bakım kartlarının öncelik ilişkisi	50




TABLÖLER DİZİNİ

	<u>Sayfa</u>
Tablo 1.1: Havayolu Endüstrisi Performansı	2
Tablo 1.2: Küresel MRO Harcaması ile Toplam Giderler ve Gelirler	2
Tablo 2.1: MRO'nun tanımlamalarına göre hava yolunun geniş gövdeli filosunun harf kontrol aralıklarının spesifikasyonu	9
Tablo 2.2: En son Tanımlarla Görev Türlerinin listesi	14
Tablo 3.1: Kabin Koltuk Rastgele Orman Analiz Sonuçları	31
Tablo 3.2: Kabin Koltuk Rastgele Orman Hipermatre Ayarlaması Sonrası Analiz Sonuçları	32
Tablo 3.3: Kabin Koltuk Gradyan Arttırma Regresyon Analiz Sonuçları	34
Tablo 3.4: Kabin Koltuk Gradyan Arttırma Regresyon GridSearchCV ile Hiperparametreler Optimizasyon Sonrası Analiz Sonuçları	35
Tablo 3.5: Kabin Koltuk Gradyan Arttırma Regresyon GridSearchCV ile Daha Detaylı Hiperparametreler Optimizasyon Sonrası Analiz Sonuçları	35
Tablo 3.6: Kabin Rutin Olmayan Kartlar için Regresyon Analiz Tablosu	39
Tablo 3.7: Koltuk Rutin Olmayan Kartlar için Regresyon Analiz Tablosu	40
Tablo 4.1: Belirsizlik Setinin Özeti	44
Tablo 4.2: 1. Senaryo Gürbüz Optimizasyon Deney Çıktısı	54
Tablo 4.3: 2. Senaryo Gürbüz Optimizasyon Deney Çıktısı	55
Tablo 4.4: 3. Senaryo Gürbüz Optimizasyon Deney Çıktısı	56

1. GİRİŞ

Mevcut havacılık pazarında, düşük maliyetli taşıyıcıların ucuz hava yolculuğuna yönelik artan talebe hâkim olduğu; personel grevlerinin ve sektörler arasındaki personel transferlerinin havayollarını zora soktuğu ve belli sebeplerle dalgalanan petrol fiyatlarının kâr marjlarını erittiği bir ortamda, özellikle köklü havayolu şirketleri, gelecekteki pazarda da rekabet edebilmek ve hayatta kalabilmek için operasyonel maliyetleri düşürmenin yeni yollarını aramak zorunda kalmaktadır. IATA'ya göre 2022 yılında dünya genelinde filo sayısı 32.070 uçak ve bunların %78'i hizmettedir. Küresel ölçekte havayolları, Maintenance, Repair and Overhaul-Uçak Bakım Kuruluşu (MRO) için 76,8 milyar dolar harcamıştır. Bu tutar, havayolu operasyonel maliyetlerinin toplam 722 milyar dolar (%10,9) ve toplam gelirlerinin 732 milyar dolar (%10,5) olduğu bir dönemi temsil etmektedir [Cros, 2022]. Ağır uçak bakımları ise bu maliyetlerin %70'inden fazlasını kapsamakta ve uçak bakımında en fazla kaynağı gerektirmektedir. Bu önemli maliyetler göz önüne alındığında, uçak bakımı, en yüksek güvenlik standartlarını korumaya yönelik bir zorunluluk olmanın ötesinde, havayolu şirketlerinin rekabet gücü açısından stratejik bir ilgi alanına dönüşmüştür [Pintelon & Parodi-Herz, 2008].

2022 yılı boyunca, hava yolcu taşımacılığı, gelir yolcu-kilometre (RPK) cinsinden ölçüldüğünde, birikmiş talep ve hava yolu seyahat pazarlarının yeniden açılmasıyla birlikte istikrarlı bir şekilde toparlanmaya devam etti. Yolcu trafiği, 2021'de 2019 hacimlerinin %41,7'sinden 2022'de %68,5'e kadar yükseldi (Şekil 1).



Şekil1.1: Küresel RPK'lar (Ocak 2020'den Aralık 2022'ye kadar) Kaynak: [Cros,2022]

Havayolu finansal performansı, 2020'de kaydedilen büyük kayıplardan toparlanmaya devam etti. Endüstri gelirleri 2021'e göre %44 arttı, ancak net sonuç olarak havayolu endüstrisi 3,6 milyar dolar zarar etti. 2021'de varil başına 77,8 dolar olan yakıt fiyatının 2022'de 135,6 dolara yükselmesi, toplam giderlerin %30,5 artmasına sebep oldu (bkz. Tablo 1).


Tablo 1.1: Havayolu Endüstrisi Performansı (2019-2022) Kaynak: [Cros, 2022]

	2019	2020	2021	2022
REVENUES, USB bn	838	384	509	732
% Change year-on-year	3.2%	-54.4%	32.3%	44%
EXPENSES, USD bn	795	495	554	722
% Change year-on-year	3.7%	-37.9%	11.8%	30.5
RPK growth, % change year-on-year	4.1%	-65.8%	21.9%	64.2%
Passenger numbers, billion	607	189	239	430
Break-even weight load factor, % ATK	66.4%	76.7%	67.2%	65.9%
Weight load factor achieved, % ATK	70.0%	59.5%	61.7%	66.8%
Passenger load factor, % ASK	82.6%	65.2%	66.9%	78.7%
Passenger yield, % change year-on-year	-3.7%	-9.1%	3.7%	9.8%
Cargo yield, % change year-on-year	-8.2%	54.7%	25.9%	7.4%
Jet kerosene price, USD/barrel	79.7	46.6	77.8	135.6
Non-fuel unit cost (cents per ATK)	39.2	48.3	45.2	41.7
Non-fuel unit costs, % change year-on-	-0.3%	23.3%	-6.5%	-7.8%
OPERATING PROFIT, USD bn	43.2	-110.8	-45.1	10.1
Operating margin, % revenue	5.2%	-28.8%	-8.9%	1.4%
NET PROFIT, USD bn	26.4	-137.7	-41.9	-3.6
Return on Invested Capital, %	5.8%	-19.3%	-8.0%	1.3%

2022 yılında küresel MRO harcaması 78,6 milyar dolar olarak gerçekleşmiştir (Şekil 8) ve bu, havayollarının operasyonel maliyetlerinin %11'ine karşılık gelmektedir (Tablo 1.2).

Tablo 1.2: Küresel MRO Harcaması ile Toplam Giderler ve Gelirler Kaynak: [Cros,2022]

	2019	2020	2021	2022
Global MRO Spend (US\$ Bill.)	95	56	66	79
% of Global Expenses	12%	11%	12%	11%
% of Global Revenues	11%	15%	13%	11%



Şekil 1.2: Küresel MRO Harcama Tahmini (2019-2033) *Kaynak: [Cros, 2022]*

Tüm mali ve operasyonel verimlilikten ziyade, güvenlik her şeyden önce dikkate alınmalıdır. Bu nedenle, tüm MRO hizmeti sağlayan kuruluşların, bakım görevlerinin yanı sıra uçak ve ekipman üreticileri (Orijinal Aircraft Manufacturer, OAM ve OEM'ler) tarafından belirlenen ve düzenleyici otoriteler tarafından onaylanan bakım görevlerinin ve aralıklarının yer aldığı sözde bakım planlama belgesinde (MPD) belirtilen katı bakım gerekliliklerine uyması gerekmektedir. Ancak, sıkı bir uyum sağlanması gerekmesine rağmen, bakım görevlerinin MPD'de belirtilen önceden tanımlanmış sınırlar içinde en verimli şekilde planlanması ve programlanması MRO hizmet sağlayıcılarına bırakılmıştır.

Düzenli uçak bakımı, uçuşa elverişliliği sağlamak, uçağın güvenilirliğini korumak ve uçuş güvenliğini temin etmek için gereklidir. Havayolları genellikle uçak bakım görevlerini harf kontrollerine ayırır: A-, B-, C kontrolleri. Özellikle, A- ve B-kontrolleri hafif bakım kapsamına girerken, C kontrolleri ağır bakım olarak kabul edilir. Her harf kontrolü, farklı bir süre, sıklık ve görev seti ile ilişkilidir **[Gopalan, 1996]**. Harf kontrolleri sırasında uçak, bakım için hangarda kalır. Hafif bakım genellikle bir veya iki günde tamamlanabilirken, ağır bakım birkaç hafta sürebilir.

Harf kontrolünün sıklığı, bakım planlama dokümanında (MPD) belirtilen, iki kontrol arasındaki maksimum aralık ile belirlenir ve bu aralık takvim günleri (DY), uçuş saatleri (FH) ve uçuş döngüleri (FC) cinsinden ifade edilir. Bakım planlayıcıları, uçakları kullanım parametreleri (yani DY, FH ve FC) limitlere ulaşmadan önce belirli günlerde bakım yapmak üzere bakım slotlarına tahsis ederler. Bir bakım slotu, uçak bakımı yapmak için bir hangarın bir günlük kullanılabilirliğini ifade eder. Bir uçağın bakım kontrolü için son tarih, önceki bakım kontrolünün başlangıç tarihi, uçak kullanımı ve maksimum aralık gibi faktörlere bağlıdır. Genel olarak, uçak bakım

kontrol planlaması, bir planlama ufku göz önüne alındığında, bir uçakta ne zaman ve hangi tür bakım kontrolünün yapılması gerektiğini belirlemektir.

Uzun vadeli (genellikle 3-5 yıl) ağır uçak bakım kontrolü programı, havacılık endüstrisindeki bir havayolu için çok önemlidir. İlk olarak, ağır bakım kontrollerinin planlanması, A-/B- kontrolleri gibi hafif bakım kontrollerini etkilediğinden, kısa vadeli bakım planlarına istikrar sağlar [Witteman vd., 2021]. Bu nedenle, sağlam bir ağır bakım kontrol programı, hafif bakımın ve ilgili kaynakların (örneğin, bakım araçları, iş gücü ve uçak yedek parçaları, hangar kapasitesi) istikrarlı bir şekilde planlanmasına olanak tanıyabilir. İkinci olarak, düzenli olarak bakım planlarını yeniden değerlendirme zamanı ve çabasını azaltır. Üçüncü olarak, bakım planlarını sürekli gözden geçirme gerekliliğini ortadan kaldırarak, yılın ticari yoğun dönemlerinde (örneğin, yaz operasyonları, okul tatilleri, dini bayramlar ve özel günler) ağır bakım kontrollerinin planlanma riskini azaltır.

Havayolları, uçaklarının bakımının uçak üreticilerinin ve havacılık düzenleyicilerinin en iyi standartlarına göre yapılmasını sağlamak için bakım planlamasını kullanır. Planlama, tüm planlanmış hava aracı parçalarının ve sistemlerinin, onaylanmış hava aracı bakım programına göre değiştirilmesini, onarılmasını veya düzenli olarak bakımının yapılmasını sağlar. Bu, arızaların uçağın hizmet standartlarının altına düşmesine veya çalışmasının tehlikeli hale gelmesine neden olmasını önler. Diğer yandan, uçağın bakım için yerde kalması, hizmet verebildiği uçuş süresini sınırlar. Havayolları, bakım nedeniyle yerde kalan uçak sayısını azaltarak maliyet anlamında tasarruf etmeyi amaçlar. Bu ise, bakım geri dönüş süresini azaltmak için olası yolları araştırmak üzere uçak bakım planlamasında sürekli iyileştirmeyi gerekli kılmaktadır. Planlama, aynı zamanda uçakların seyahatin yoğun olduğu sezonlarda maksimum gelir elde etmeye hazır olmasını da sağlar. Bakımlı bir uçağa sahip olmak, havayollarının arıza sürelerini azaltmasına da olanak tanır, bu da kesinti süresini en aza indirirken geliri en üst düzeye çıkarır.

1.1. Problem Tanımı

Havacılık sektöründe uçakların periyodik bakımları, operasyonel güvenliğin ve sürdürülebilirliğin sağlanması açısından kritik bir öneme sahiptir. Uçak bakım süreçlerinde iş yükünü oluşturan rutin ve rutin dışı işlerin adam-saat miktarlarının doğru bir şekilde tahmin edilmesi ve kapasite planlamasının etkin bir biçimde yapılması, bakım süreçlerinin verimliliğini belirleyen temel unsurlardan biridir. Bu süreçlerde, uçakların bakıma giriş periyotları ve bu periyotlarda uygulanacak rutin kartlar büyük bir rol oynar. Ayrıca, uçuş esnasında ortaya çıkan arızaların giderilmesi, üretici firma tarafından talep edilen revizyonların uygulanması ve belirli bölgelerde yapılan muayene kartları kapsamında tespit edilen arızaların onarılması da bakımın önemli bileşenleri arasında yer alır.

Rutin kartlar, belirlenen işlerin planlı olarak belli bir döngü sistemiyle gerçekleştirilmesi üzerine kuruludur. Ancak, bu kartlar kapsamında yapılan muayenelerde de tespit edilen arızalar plansız işler olarak kaydedilen rutin dışı kartlara yol açar. Rutin dışı kartlar, teknisyenler tarafından arızanın karmaşıklığı ve süresi baz alınarak hesaplanan adam-saat gereksinimlerine dayanır. Bakımlardaki muayene kartları sebebiyle tespit edilen rutin dışı kartların adam saat toplamaları, uçağın gövde tipi, bakım süresinin uzunluğu ve uçağın yaşı gibi çeşitli değişkenlere bağlı olarak farklılık gösterir.

Bakım süreçlerinde planlanan adam-saat miktarları ile gerçek ihtiyaçlar arasındaki sapmalar, operatör firmalar açısından önemli bir zorluk teşkil eder. Bu sapmalar, özellikle bakım süresinde öngörülemeyen uzamalara yol açarak operasyonel maliyetleri artırabilir ve uçakların planlanan süre zarfında tekrar hizmete girememesine neden olabilir. Dolayısıyla, kapasitenin doğru kullanımı, verimliliğin artırılması ve bakım sürelerindeki sapmaların minimize edilmesi bu problemin çözümünde ana hedefler arasında yer alır.

Bu hedeflere ulaşmak amacıyla çeşitli tahmin modelleri kullanılmış ve bakım planlamasında planlanan sürelerden sapmanın en aza indirilmesine yönelik veri odaklı yaklaşımlar geliştirilmiştir. Tahmin modelleri, geçmiş bakım verileri, uçak özellikleri ve bakım türü gibi faktörleri göz önünde bulundurarak daha doğru kapasite planlamasına imkân verir. Bu sayede, işletmeler bakım süreçlerinde beklenmedik uzamalardan kaçınarak, bakım maliyetlerini kontrol altında tutabilir ve operasyonel

verimliliği artırabilirler. Bu yaklaşımda ana odak, tahmin modeli geliştirmek değil, planlanan sürelerden sapmaları en aza indiren bir planlama yapabilmektir.

1.2. Tez Çalışmasının Amacı ve Kapsamı

Uçaklar, sahip oldukları karmaşık mekanik, elektriksel ve elektronik sistemler nedeniyle sürekli aşınma ve yıpranmaya maruz kalan makinelerdir. Bu nedenle, uçakların güvenli ve kesintisiz bir şekilde çalışabilmesi için belirli periyotlarda bakıma alınmaları zorunludur. Havacılık endüstrisinde yapılan bu bakımlar, hem uçuş güvenliğini en üst seviyede tutmak hem de operasyonel verimliliği sağlamak açısından kritik bir öneme sahiptir. Uçak bakım süreçleri, her bir bileşenin detaylı bir şekilde incelenmesini ve bakım teknisyenlerinin planlanan zaman dilimlerinde her bir işi titizlikle tamamlamasını gerektirir. Ancak pratikte, bakım süreçlerinde büyük sapmalar yaşanmakta, öngörülen süreler ve iş gücü gereksinimleri ile gerçek uygulama arasında önemli farklar ortaya çıkmaktadır.

Özellikle uçak bakımı planlamalarında, tahmin modellerinin eksikliği nedeniyle planlanan bakım süreleri genellikle standart süreler üzerinden belirlenmekte, buna ek olarak rutin dışı işlerin adam-saat tahminleri toplu bir şekilde eklenmektedir. Fakat bu yaklaşımlar, özellikle rutin dışı işlerin belirsizliğinden dolayı, bakım için planlanan adam saatten yüksek sapmalara ve bakım sürelerinin öngörülemez bir şekilde uzamasına neden olmaktadır. Bu belirsizlikler, planlamanın doğruluğunu ve bakım sürelerinin efektif yönetimini zorlaştırmakta operatör firmalar açısından ciddi maliyet artışlarına yol açmaktadır.

Bu tez çalışmasının temel amacı, mevcut uçak bakım sistematığına alternatif bir yaklaşım önererek, bakım planlaması sürecindeki belirsizlikleri azaltmaktır. Bu bağlamda, makine öğrenmesi ve matematiksel optimizasyon tekniklerinin bir arada kullanıldığı bir metodoloji geliştirilmesi hedeflenmektedir. Önerilen yöntem, uçak bakım sürelerinin daha doğru bir şekilde tahmin edilmesine olanak sağlayacak, rutin ve rutin dışı bakım işlerinden kaynaklanan belirsizlikleri dikkate alarak projelerin tamamlanma sürelerini verilen tolerans sınırları içerisinde gerçekleştirecek şekilde optimize edilecektir. Böylece, bakım süreçlerinde daha iyi tahminler yapılabilecek ve bakım faaliyetleri planlanan süreler dahilinde tamamlanarak operasyonel verimlilik artırılabilir.

Endüstriyel bağlamda bu tez, bilimsel yöntemlere dayanan ve pratikte uygulanabilir bir çözüm sunmayı hedeflemektedir. Geliştirilecek metodoloji, uçak bakım süreçlerinde operasyonel etkinliği artırmak için kullanılabilecek bir araç olarak endüstri tarafından benimsenebilir. Aynı zamanda, bakım maliyetlerinin ve süresinin minimize edilmesi, uçakların hizmete geri dönüş sürelerinin kısaltılması ve bakım süreçlerinin daha öngörülebilir hale getirilmesi sayesinde, operatör firmaların rekabet gücünü artırmak için önemli bir adım olacaktır.

Bu tezde önerilen yaklaşım, uçak bakım süreçlerinde karşılaşılan belirsizlikleri ele almak için iki aşamalı bir model geliştirilmesine dayanmaktadır. İlk aşamada, makine öğrenmesi yöntemleri kullanılarak bakım sürelerini ve rutin dışı işlerden kaynaklanan adam-saat gereksinimlerini daha doğru bir şekilde tahmin etmeye yönelik bir tahmin modeli oluşturulacaktır. İkinci aşamada ise, bu tahminlerden elde edilen veriler, matematiksel optimizasyon teknikleri ile birleştirilerek bakım planlaması yapılacaktır. Bu optimizasyon modeli, bakım faaliyetlerini en uygun şekilde sıralayarak ve kaynak kullanımını optimize ederek, bakım sürelerinin belirlenen tolerans aralıklarında tamamlanmasını sağlayacaktır. Böylelikle, hem bakım süreçlerindeki belirsizliklerin etkisi en aza indirgenecek hem de operasyonel etkinlik artırılarak bakım maliyetleri ve süreleri üzerinde iyileştirmeler sağlanacaktır.

2. UÇAK BAKIM VE ONARIM SÜREÇLERİ

2.1. Uçak Bakım Süreçlerine İlişkin Temel Bilgiler

Bakım Planlama Dokümanı (Maintenance Planning Document / MPD), uçak üreticileri tarafından hazırlanan bir belge olup, bir uçağın güvenli ve etkin bir şekilde işletilebilmesi için gereken tüm bakım işlemlerini ve bu işlemlerin hangi aralıklarla yapılması gerektiğini detaylandırır. MPD, operatörlere (havayolu şirketlerine veya uçak sahiplerine) yönelik bir rehber niteliği taşır ve uçakların periyodik bakım ihtiyaçlarının planlanmasında temel bir referans dokümanı olarak kullanılır. Bu dokümandaki bilgiler, operatörlerin kendi bakım programlarını oluştururken esas aldıkları teknik gereksinimleri içerir. MPD'de yer alan başlangıç bakım programına göre, her bir operatörün kendi bakım programını geliştirme sorumluluğu vardır [Ahmadi, 2010]. Operatörler tarafından uygulanan yaygın bir yaklaşım, görevlerin büyük çoğunluğunun özelliklerine (gerekli prosedürler, koşullar) ve aralıklarına göre bir araya getirildiği "bloklama" olarak bilinen yaklaşımdır. Bloklama stratejisi, bakım kartlarının uygulanmasını gruplayarak uçağın bakım için hangara girmesi gereken zamanları en aza indirmeyi hedefler. Bu bloklar, rutin bakım kontrollerine, yaygın olarak bilinen harf kontrollerine (A-B-C) atanır.

Bakım, onarım ve revizyon kuruluşu, havayolunun sahip olduğu tüm filosu için bakım programının (AMP / Aircraft Maintenance Program) planlanmasında bloklama stratejisini kullanmıştır. MRO, hava yolunun filosunu A, B ve C kontrolleri olmak üzere üç harf kontrolüne ayırır. MRO'nun mühendislik departmanı tarafından yapılan çalışmalar, bu harf kontrollerinin ve bunların ilgili aralıklarının formüle edilmesine yol açmıştır. **Tablo 3**, MRO'nun tanımlamalarına göre her bir harf kontrolünün farklı aralık spesifikasyonlarının bir özetini sunmaktadır [EASA- AMP Aircraft Maintenance Programme, 2021].

Aralık Spesifikasyonu	A-Bakım	B-Bakım	C-Bakım
Uçuş Saatleri	1500	-	15000
Uçuş Döngüleri	200	-	2000
Takvim Süresi	105 gün	15 ay	3 yıl
Blok Sayısı	22	2	15

Tablo 2.1: MRO'nun tanımlamalarına göre hava yolunun geniş gövdeli filosunun harf kontrol aralıklarının spesifikasyonu [EASA- AMP Aircraft Maintenance Programme, 2021]

Bu metinde, harf kontrolleri, uçak bakımı için farklı seviyelerde yapılan düzenli bakım işlemlerini ifade eder. "A" ve "B" kontrolleri daha kısa ve daha az kapsamlı bakım işlemlerini kapsarken, "C" kontrolü daha uzun ve detaylı bakımları içerir.

Harf kontrollerine atanan MRI'ler (minimum gerekli muayene) gibi, harf kontrollerinin aralıkları da uçuş saatleri, uçuş döngüleri ve takvim süresi bazında tanımlanır ve hangi döngü daha önce gelir prensibine göre planlanır. A kontrollerinin daha küçük aralıklara sahip olması, daha sık planlanması gereken görev kartlarından oluşan blokların bu kontrollere tahsis edilmesindendir. **Tablo 2.1**'de belirtildiği gibi, MRO 22 benzersiz A-bloku tanımlamıştır. Çok daha büyük aralıklara sahip MRI'ler ise C kontrollerine tahsis edilir ve MRO, 15 benzersiz C kontrolü tanımlamıştır. B kontrolleri, diğer adıyla kabin kontrolleri, A ve C kontrollerinden farklı olarak herhangi bir MPD ögesi içermez ve bu nedenle katı bir aralığı yoktur. Kabin kontrolleri, operatörün talebi üzerine tanıtılmış olup, kabin kalitesini yüksek tutmak için yapılan kabin kontrol kartlarını içermektedir.

Uçak bakım süreçleri, güvenlik ve operasyonel devamlılık sağlamak amacıyla uçakların düzenli kontrol ve onarımını içerir. Bu süreçler, ulusal ve uluslararası havacılık otoriteleri tarafından belirlenen sıkı kurallar çerçevesinde yürütülür. Bakım süreçleri genel olarak hat bakımı (line maintenance) ve üs bakımı (base maintenance) olarak ikiye ayrılır. Üs bakımı, uçakların daha derinlemesine incelenmesini ve onarılmasını gerektiren uzun vadeli ve kapsamlı bakım işlemlerini kapsar. Üs bakımı

genellikle uçakların operasyon dışına alındığı uzun süreli periyotlarda uygulanır ve çeşitli bakım paketleri kapsamında gerçekleştirilir.

Base bakım, daha donanımlı bakım merkezlerinde ve uzman ekipler tarafından yapılır. EASA (European Union Aviation Safety Agency) ve FAA (Federal Aviation Administration) gibi havacılık otoriteleri tarafından düzenlenen kurallar çerçevesinde gerçekleştirilir. Bu süreçlerin yönetimi, EASA Part 145 ve FAA CFR 14 Part 43/145 gibi yasal düzenlemelere göre yapılır.

Base bakım süreçleri, kapsamlı planlama gerektiren, detaylı adımlarla yürütülen operasyonlardır. Bu süreçlerde bakım paketleri olarak adlandırılan prosedürler, belirli kriterlere ve uçuş döngülerine göre hazırlanır. Bakım paketleri, genellikle aşağıdaki faktörlere uygun planlanır.

- **Üretici Tavsiyeleri:** Uçak üreticileri, uçağın tipine, modeline ve kullanım süresine göre belirli aralıklarla yapılması gereken bakım tavsiyeleri sunar. Bu tavsiyeler, uçağın güvenliğini ve uzun ömürlülüğünü sağlamak amacıyla oluşturulmuş standartlardır. Üretici tarafından sağlanan MPD veya Aircraft Maintenance Manual (AMM) gibi dokümanlar, uçak bakım planlamasında temel alınır.
- **Yasal Düzenlemeler ve Otorite Talimatları:** Havacılık otoriteleri (EASA, FAA, ICAO vb.), uçak bakım süreçlerini yöneten çeşitli kurallar belirler. Bu kurallar, uluslararası uçuşlarda güvenlik standartlarının korunması ve uyumluluğun sağlanması için zorunludur. Yasal düzenlemeler doğrultusunda, bakım paketleri her uçağın modeline, operasyonel bölgesine ve kullanım koşullarına göre düzenlenir.
- **Kondisyon ve Performansa Dayalı Bakım:** Bakım paketleri, uçağın kullanım koşullarına ve sistem performansına göre optimize edilir. Uçağın günlük operasyonel verileri analiz edilerek, hangi parçaların daha sık değişmesi veya hangi sistemlerin daha sık kontrol edilmesi gerektiği belirlenir. Bu, daha akıllı bir bakım planlaması yaparak bakım maliyetlerini azaltır ve operasyon sürekliliğini artırır.
- **Takvimsel ve Uçuş Süresi Bazlı Planlama:** Uçak bakım süreçleri, genellikle uçuş döngüsü, uçuş saati veya belirli takvim aralıklarıyla ilişkilendirilir. Her uçak için belirlenen "uçuş döngüsü" veya "uçuş saati" sınırları, bakım paketinin

zamanlamasını ve içeriğini doğrudan etkiler. Örneğin, bir uçak her 18 ayda bir veya belirli bir uçuş saatine ulaştığında C bakımı almak zorundadır.

Bakım paketleri oluşturulurken, her bir iş kalemi için belirli bir zaman dilimi, insan kaynağı ve gerekli ekipman tanımlanır. İş paketleri, uçakların hangi bileşenlerinin bakım veya onarıma ihtiyaç duyduğunu ve hangi uzmanlık alanlarının sürece dahil edileceğini gösteren detaylı bir çalışma planıdır. İş paketleri ayrıca gerekli yedek parçaları, teknik dokümanları ve test gereksinimlerini de içerir. Bakım paketleri oluşturulduktan sonra, bunların uygulama aşamasında belirli adımlar izlenir:

- **Bakım Tesisleri ve Ekibin Hazırlığı:** Uygulama süreci başlamadan önce gerekli ekipman ve tesisler hazırlanır. Ayrıca, bakım teknisyenleri ve mühendisleri, ilgili bakım faaliyetlerini gerçekleştirmek üzere organize edilir.
- **Detaylı İnceleme ve Kontroller:** Belirlenen iş paketlerine göre uçakta yapılacak işlemler başlatılır. Bu süreçte her bileşen detaylı olarak kontrol edilir, arızalı parçalar değiştirilir ve gerekli testler yapılır.
- **Sistematik Testler:** Bakımın ardından, uçağın tüm sistemlerinin yeniden çalıştığından ve uçuşa uygun olduğundan emin olmak için kapsamlı testler yapılır. Özellikle hidrolik, elektrik ve yakıt sistemlerinin tam fonksiyonel olduğuna dair testler zorunludur.
- **Dokümantasyon ve Raporlama:** Tüm bakım işlemleri detaylı olarak dokümanite edilir. Bu dokümanlar hem havacılık otoritelerine sunulmak üzere arşivlenir hem de gelecekteki bakım işlemlerine referans sağlamak amacıyla kullanılır. Bu dokümantasyon süreci, uçuş güvenliği açısından büyük önem taşır.

Uçak bakım şirketleri, bakım süreçleri için gereken adam-saatleri tahminlemek amacıyla çeşitli yöntemler ve verilerden yararlanır. Bu tahminler hem bakım planlamasının doğru yapılması hem de iş gücü ve kaynakların verimli kullanılması için kritik öneme sahiptir. Geçmiş verileri inceleyen birimler, daha önce yapılan benzer bakım işlemleriyle ilgili verileri analiz ederek bir tahmin oluşturur. Bu tahmin daha önce aynı uçak modeli ve bakım türü için kullanılan toplam adam-saat miktarı dikkate alınır. Bakıma yüklü rutin kartlar üzerindeki adam saatler ve geçmiş bakımlardaki rutin dışı işler için harcanan sürelerin ortalamaları ile bakıma adam saat tahmininde bulunulur.

Uçak üreticilerinin sağladığı Bakım Planlama Dokümanı (MPD) analiz edilir. MPD'de listelenen görev kartları incelenerek, her bir görevin tamamlanması için gereken zaman tahmini yapılır. Özellikle, rutin bakım kartlarının standart adam-saat değerleri ve rutin dışı görevlerden doğan olası ilave işler göz önünde bulundurulur. Uçağın yaşı, toplam uçuş saatleri (FH), iniş-kalkış döngüleri (FC), ve uçak üzerindeki sistemlerin genel durumu gibi operasyonel bilgiler dikkate alınır. Bu yöntemlerin kombinasyonu, uçak bakım şirketlerinin bakım sürelerini ve adam-saat tahminlerini daha hassas bir şekilde yapmalarına olanak tanır. Böylece hem operasyonel kesintiler azaltılır hem de maliyet ve kaynak planlaması optimize edilir.

2.2. Bakım Kartları

Uçak bakım görev kartları, teknisyenleri belirli bakım görevleri boyunca yönlendirmek için havacılık sektöründe kullanılan temel araçlardır. Bu kartlar, bakım görevlerinin doğru ve güvenli bir şekilde gerçekleştirilmesini sağlamak için ayrıntılı talimatlar, güvenlik önlemleri ve diğer ilgili bilgileri içerir.

Görev kartlarının kullanımı, havacılık bakımında standart bir uygulamadır ve görevlerin tutarlı ve verimli bir şekilde tamamlanmasını sağlar. Bu kartlar, rutin bakım, denetimler ve planlanmamış onarımlar gibi geniş bir yelpazedeki görevler için kullanılır. Basit kontrollerden karmaşık onarımlara kadar her türlü işlemi kapsar. Görev kartları genellikle uçak üreticileri, bakım organizasyonları veya düzenleyici otoriteler tarafından geliştirilir. Bu kartlar, sektör gerekliliklerine uygun olarak görevlerin gerçekleştirilmesini sağlamak için belirlenmiş prosedürler, standartlar ve en iyi uygulamalara dayanır. Talimatların sağlanmasının yanı sıra görev kartları, bir uçakta gerçekleştirilen bakımın kaydı olarak da hizmet eder. Görevlerin tamamlanma tarihini, teknisyenin adını, ek notlar veya gözlemleri belgelemek için kullanılır.

Genel olarak, uçak bakım görev kartları, havacılık bakım operasyonlarının kritik bir bileşenidir ve uçakların güvenliği, güvenilirliği ve uçuşa elverişliliğini sağlar. Bu kartlar, teknisyenlere görevleri doğru ve güvenli bir şekilde yerine getirmeleri için gereken bilgileri sunarak, uçakların bütünlüğünü korumaya ve yolcular ile mürettebatın güvenliğini sağlamaya yardımcı olur.

Uçak bakım kartları genel olarak iki kısımda incelenebilir. Bunlardan ilki rutin bakım kartları, uçak üreticisi veya ilgili havacılık otoriteleri tarafından önceden belirlenen ve

belirli döngüler içerisinde tekrarlı olarak gerçekleştirilmesi gereken görevleri içerir. Bu kartlar, uçakların güvenilir bir şekilde işletilmesi için gerekli olan temel bakım faaliyetlerini kapsar.

Görevler, üreticinin bakım programlarına dayanır ve standartlaştırılmıştır. Genellikle öngörülebilir sürelerde tamamlanır. Çoğunlukla kontrol, temizlik, yağlama, değişim gibi faaliyetleri içerir. **Tablo 2.2'**de bu görevler detaylı olarak açıklanmıştır. Bu kartlarda sapmalar genellikle minimum düzeydedir, çünkü görevler açıkça tanımlanmıştır. Kartların süreleri genellikle yapılan iş etütleri ile belirlenmiştir.

Rutin olmayan bakım kartları ise, planlanmamış veya beklenmedik şekilde ortaya çıkan sorunları çözmek için kullanılan kartlardır. Bu kartlar genellikle, bakımlarda muayene ettiren rutin kartların uygulanması sırasında tespit edilen veya operasyon sırasında kokpit ve kabin ekipleri tarafından bildirilen arızaların düzeltilmesine yönelik görevleri içerir. Bakım şirketlerinin kullanmış olduğu uçak bakım sistemlerinde rutin olmayan işler için kayıtlar açılırken kaynak sebep girilmektedir. Bu sebepler arasında bakım kartı içerisindeki muayene adımları sonrası bulgular, uçuş sırasında kokpit ve kabin ekiplerinin sistemlere girmiş olduğu arızalar, bakım sırasında herhangi bir muayene kartı olmasa dahi teknisyen bulguları sayılabilir.

Rutin olmayan kartların tamamlanma süreleri ve iş yükü öngörülemez. Bakım sürelerinde ve adam-saat tahminlerinde bu belirsizlikler sapmalara neden olabilir. Çoğunlukla arıza tespiti, onarım, değişim ve test gibi görevleri içerir.

Tablo 2.2: En son Tanımlarla Görev Türlerinin listesi [Camo, 2023]

GÖREV TİPİ	TANIM	İÇERİK
LU/SV veya LUB/SVC	Yağlama/Bakım	İşsel tasarım yeteneklerinin korunması amacıyla yapılan herhangi bir yağlama veya bakım eylemi.
OP veya OPC	Operasyonel Kontrol	Operasyonel kontrol, bir öğenin amaçlanan amacını yerine getirdiğini belirleme görevidir. Nicel toleranslar gerektirmez. Bu bir arıza bulma görevidir.
VC veya VCK	Görsel Kontrol	Görsel kontrol, bir öğenin amaçlanan durumunda olduğunu belirlemek için yapılan bir gözlemdir. Nicel toleranslar gerektirmez. Bu, belirgin geçme/kalma kriterlerine sahip bir arıza bulma görevidir.
FC veya FNC	Fonksiyonel Kontrol	Bir öğenin bir veya daha fazla işlevinin belirtilen sınırlar içinde gerçekleşip gerçekleşmediğini belirlemek için yapılan nicel bir kontrol.
GV veya GVI	Genel Görsel Muayene	Açık hasar, arıza veya düzensizliği tespit etmek için bir iç veya dış alanın, kurulumun veya tertibatın görsel muayenesi. Aksi belirtilmediği sürece bu seviyedeki muayene, dokunma mesafesinden yapılır. Muayene alanındaki tüm açık yüzeylere görsel erişimi artırmak için bir ayna gerekebilir. Bu seviyedeki muayene, gün ışığı, hangar aydınlatması, el feneri veya sarkıt ışık gibi normalde mevcut aydınlatma koşulları altında yapılır ve erişim panellerinin veya kapılarının çıkarılmasını veya açılmasını gerektirebilir. Kontrol edilen alana yaklaşmak için stantlar, merdivenler veya platformlar gerekebilir. Uygun görünürlüğü sağlamak için temel temizlik gerekebilir.
DI veya DET	Detaylı Muayene	Belirli bir öğenin, kurulumun veya tertibatın hasar, arıza veya düzensizlik tespit etmek için yoğun bir şekilde incelenmesi. Bu, bir bileşenin veya tertibatın sıklık/güvenlik açısından kontrol edilebildiği dokunsal değerlendirmeyi içerebilir. Mevcut aydınlatma normalde uygun görülen bir yoğunlukta doğrudan iyi bir aydınlatma kaynağıyla desteklenir. Aynalar ve büyüteçler gibi inceleme yardımcıları gerekli olabilir. Yüzey temizliği ve ayrıntılı erişim prosedürleri gerekebilir.
SI veya SDI	Özel Detaylı Muayene	Hasar, arıza veya düzensizliği tespit etmek için Tahribatsız Muayene (NDT) ve/veya ekipman (örneğin baroskop, videoskop, musluk testi) gibi özel inceleme tekniklerinden yararlanılarak belirli bir öğenin, kurulumun veya tertibatın incelenmesi. Karmaşık temizlik ve önemli erişim veya sökme prosedürleri gerekebilir. Bir görevin SDI olarak sınıflandırılması, görevi gerçekleştiren kişi için gerekli nitelikleri tanımlamaz.
RS veya RST	Restorasyon	Öğeyi belirli bir standarda döndürmek için gerekli olan çalışma. Restorasyon, tek tek parçaların temizlenmesinden veya değiştirilmesinden komple bir revizyona kadar değişebilir.
DS or DIS	Iskarta	Belirli bir kullanım ömrü sonunda bir eşyanın hizmetten çıkarılması.

3. BELİRSİZLİK MODELLEME

3.1. Literatür

Literatür taramamızda erişilen önceki araştırmalarda, uçak bakımlarındaki rutin olmayan görev gereksinimlerini tahmin etme sorunu veri analitiği temelli bir zorluk olarak ele alınmıştır [Pelt vd., 2019]. Tahmin yaklaşımı, çalışmaların gerçekleştirildiği ilgili verilere erişmeyi gerektirir. Rutin olmayan görevlerin etkisini azaltmak amacıyla kaynak ve malzeme planlaması ile operasyonel zamanlama süreçlerini bir araya getirerek entegre etmek önerilmiştir [Samaranayake & Kiridena, 2012].

Mevcut durumda rutin olmayan adam-saat tahminlerinde yaşanan sapmaların en aza indirilmesi, kapasite planlarının doğruya yakın bir şekilde gerçekleştirilebilmesi ve verimliliğin artırabilmesi açısından büyük önem arz etmektedir [Kazan & Tavsamaz, 2014]. Bu öneme istinaden yapılan bir çalışmada kaba tahmin, kaba trendli tahmin, basit ortalama, basit hareketli ortalama, ağırlıklı hareketli ortalama, üstel düzeltme yöntemleri kullanılmıştır. Uygulama sonucuna bakıldığında, tahmin yöntemlerinin sürecin kontrol altında yürüdüğü dönemlerde gerçeğe yakın sonuçlar verdiğini göstermektedir. Özellikle α sabitinin 0.2 seçildiği üstel düzeltme yöntemiyle yakın sonuçlar elde edilmiştir. Ancak gerçekleşen değerlerin yüksek oranda saptığı ve sürecin kontrol dışı değerler ürettiği durumlarda tahminlerin geçerliliğini yitirmekte olduğu, bu sebeple tahminlerin doğru sonuçlar verebilmesi için bu sapmalara neden olan faktörlerin gözden geçirilmesi ve sapmaya sebep olan durumların ortadan kaldırılması gerektiği ifade edilmiştir [Kazan & Tavsamaz, 2014].

Literatür tarama çalışmalarının çoğunlukla Zorgdrager vd. örneğinde olduğu gibi, gelecekte öngörülmeyen görevler için malzeme ihtiyaçlarının tahmin edilmesine odaklandığını belirtmek önemlidir. Fakat rutin olmayan stokastik görevlerde işin gerektirdiği adam saatlerin tahmini daha yüksek bir değişkenlik ve hassasiyet ihtiyacı gerektiğinden çok daha karmaşıktır. Zorgdrager vd. (2014), rutin olmayan görev kartlarının iş yükü tahmini için geçmiş verilere dayalı olarak doğrusal regresyon ve denetimli öğrenme modellerine başvurmuştur. Ancak, verilerin sınırlı olması denetimli öğrenme modellerinde doğruluk sorunlarına ve aşırı öğrenmeye yol açmıştır. Beklenmedik bir sonuç olarak, doğrusal model en yüksek doğruluğu sağlamıştır.

Çalışmanın yazarları, doğrusal modellerin, stokastik görevlerin iş yükündeki değişkenlik ve karmaşıklığı kapsamlı bir şekilde yakalayamayacağı görüşündedir.

Rutin olmayan kartların adam saatlerini doğru bir şekilde tahmin etmek ve mevcut verilerden anlamlı sonuçlar çıkarmak amacıyla çeşitli denetimli öğrenme teknikleri değerlendirilmektedir. İyi tanımlanmış, ölçülebilir niteliklere sahip, kapsamlı veri setleri göz önüne alındığında, yerleşik bir makine öğrenimi yöntemi olan Rastgele Orman (Random Forest-RF) modellerinin tahmin ve sınıflandırma görevleri için uygulanması uygun bir seçenek olarak öne çıkmaktadır. Bu algoritma, büyük veri setlerini işleme konusunda oldukça yetkin olup, karar ağaçlarına dayalı yapısı sayesinde kolayca yorumlanabilir tahminler üretmeyi mümkün kılmaktadır.

Birçok dikkate değer çalışma, RF modellerinin farklı alanlardaki etkinliğini ve verimliliğini vurgulamıştır. RF modelinin bükülme polimer filmlerinin yorgunluk ömrünü tahmin etmede yüksek doğruluk ve verimlilik sağladığını göstermiştir **[Kishino vd., 2023]**. Havacılık araştırmaları alanında RF modellerinin kararlılık gösterdiği, aşırı öğrenmeye daha az duyarlı olduğu ve gelecekteki mekanik arızaları tahmin etmede etkili bir şekilde kullanıldığı ortaya konmuştur **[Zhu vd., 2024]**.

3.2. Arka Plan

3.2.1. Makine Öğrenmesi

Makine öğrenmesi bilgisayarların insanlara benzer şekilde öğrenmesini sağlamak amacıyla çeşitli algoritma ve tekniklerin geliştirilmesi için çalışılan bilim ve teknolojinin birlikte kullanıldığı bir çalışma alanıdır. Deneysel veriler, gözlemlenen değişkenler arasındaki ilişkileri gösteren örnekler biçimindedir. Makine öğrenimi araştırmasının temel odak noktası, örneklerdeki kalıpları otomatik olarak tanımayı öğrenmek ve akıllı kararlar almaktır **[Bousquet vd., 2004]**.

Makine öğrenimi (ML), bilgisayar sistemlerinin, deneyimlerden öğrenerek belirli görevlerdeki performanslarını geliştirme sürecini ifade eder. **[Mitchell, 1997]**.

Bir bilgisayar programı, bir görev sınıfı T , bir performans ölçütü P ve bir deneyim E ile ilgili olarak, eğer T 'deki görevlerde P ile ölçülen performansı E 'den öğrenerek artıyorsa, bu programın öğrenmiş olduğu söylenir." **[Mitchell, 1997]**.

Bu bağlamda, makine öğreniminin üç temel bileşeni şunlardır:

Görev (*T*): Sistem tarafından yerine getirilmesi istenen görevler. Örneğin, görüntü sınıflandırma, doğal dil işleme veya tahmin.

Performans Ölçütü (*P*): Sistemin başarısını ölçmek için kullanılan kriterler. Örneğin, doğruluk oranı veya hata oranı.

Deneyim (*E*): Sisteme sağlanan eğitim verileri veya etkileşimler.

Makine öğrenimi, temelde verilerden öğrenme sürecine dayanır ve bu nedenle günümüzde büyük veri, yapay zekâ ve karar destek sistemlerinin temel yapı taşlarından biri haline gelmiştir. Makine öğreniminin büyük bir bölümü olasılıksal terimlerle ifade edilebilir. Bu da olasılıksal düşünmeyi makine öğrenimi için temel bir beceri haline getirir [Murphy, 2022]. Makine öğreniminin önemli bir bölümü, öngörücü modeller oluşturma göreviyle ilgilidir. Bu modeller, bağımsız değişken olarak adlandırılan öngörücülerin değerlerine dayanarak, bağımlı değişkenin değerini tahmin eder. Öngörücü modelleme sorunları ise iki ana kategoriye ayrılmaktadır: sınıflandırma ve regresyon.

Sınıflandırma problemleri kategorik (nominal) bir çıktı değişkeninin değerlerini tahmin etmeyi içerir. Bir veya daha fazla sürekli veya kategorik girdi değişkeni tahmin edici olarak kullanılabilir. Basit sürekli tahmin edicileri, kategorik tahmin edicileri veya her ikisini içeren sınıflandırma problemlerini çözmek için bir dizi yöntem vardır.

Regresyon problemleri, bir veya daha fazla sürekli veya kategorik değişkenden bir sürekli değişkenin değerini tahmin etmeyi içerir. Örneğin, bir aracın yakıt tüketimini, motor hacmi, araç ağırlığı ve yakıt türü gibi çeşitli sürekli ve kategorik değişkenlere dayanarak tahmin etmek istenebilir. Bu tür bir problem için, diğer değişkenlerden yakıt tüketimini tahmin etmek amacıyla bir doğrusal denklem bulmak için çoklu regresyon uygulanabilir.

Makine öğrenimi içinde, birden fazla giriş değişkeni ve genellikle tek bir çıkış değişkeni ile regresyon & sınıflandırma görevlerini ele almak için bir dizi ileri düzey istatistiksel yöntem bulunmaktadır. Bu yöntemler arasında doğrusal regresyon, polinomsal regresyon, rastgele orman (random forest), gradyan artırma (gradient boosting) ve diğer yöntemler yer alır.

Bu çalışma kapsamında, belirsizliklerin modellenmesi ve bu belirsizliklerin etkilerinin öngörülmesi için çeşitli makine öğrenmesi teknikleri ve istatistiksel yöntemler kullanılmıştır. Rutin olmayan iş yükü ile ilgili tahminler yaparken polinomsal regresyon, rastgele orman regresyon ve gradyan arttırma regresyon gibi öne çıkan makine öğrenmesi algoritmaları kullanılmış, ayrıca medyan ve ortalama gibi temel özet istatistikler ile karşılaştırmalar yapılmıştır. Belirsizlik modellemesi sürecinde uçak bakımlarından üreyen rutin olmayan kartların adam-saat değerleri üzerinde durulmuş ve bu belirsizlikler için tahmin yöntemleri geliştirilmiştir.

Kullanılan makine öğrenmesi algoritmalarını değerlendirmek için aşağıda detayları verilen yöntemler kullanılmıştır.

- R^2 (R Kare) / Düzeltilmiş R^2
- Ortalama Kare Hatası (Mean Squared Error (MSE))
- Ortalama Mutlak Hata (Mean Absolute Error (MAE))

R Kare/Ayarlanmış R Kare, bağımlı değişkenin modeldeki bağımsız değişkenlere göre değişim oranını, yani bağımlı değişkendeki değişimin model tarafından açıklanabilen oranını ölçer. Korelasyon katsayısının karesidir. R-Kare aşırı uyum (overfitting) sorununu dikkate almaz. Bir regresyon modeli çok fazla bağımsız değişkene sahipse, model eğitim verilerine çok iyi uyabilir ancak test zamanında aynı performansı göstermeyebilir.

$$R^2 = 1 - \frac{SS_{Residual}}{SS_{Total}}$$

Ortalama kare hatası (MSE), modelin tahmin ettiği değerler ile gerçek değerler arasındaki farkların karesinin ortalamasını ifade etmektedir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Burada, y_i gerçek değerler, $\hat{y}_i$ modelin tahmin ettiği değerler ve n veri örneklerinin sayısını temsil etmektedir. MSE, tahmin edilen sonuçların gerçek sayıdan ne kadar farklı olduğuna dair mutlak bir sayı verir. Tek bir sonuçtan çok fazla içgörü yorumlanamaz, ancak diğer model sonuçlarıyla karşılaştırmak için gerçek bir sayı vermesi hangi regresyon modelinin iyi olduğunu seçmekte yardımcı olur. Kök ortalama kare hatası (RMSE), MSE'nin kareköküdür; MSE değeri kolayca

karşılaştırılmayacak kadar büyük olduğunda MSE hata karesi ile hesaplanır ve yorumlamayı kolaylaştırır.

3.2.2. Doğrusal Regresyon

Regresyon analizinin temelleri, matematiğin ilk dönemlerine kadar gitmektedir. 19. yüzyıl matematikçileri olan Gauss, Boole, Cayley ve Sylvester gibi isimlerin çalışmalarından gelişen cebirsel invariantlar teorisi, doğrusal regresyon modelinin mümkün olmasını sağlamıştır. Bu teori, kısa süre içinde doğrusal regresyon modeli ve korelasyon yöntemlerine de genişletilmiştir. Bu yöntemler, genel doğrusal modelin geliştirilmesinin temelini oluşturur. Doğrusal regresyon, denetimli öğrenme modellerinde, bağımsız değişkenler ile bağımlı değişken arasındaki en uyumlu hattı çizen bir regresyon modeli algoritmasıdır. Bir veya daha fazla girdi ile çıktı arasındaki istatistiksel ilişkiyi tanımlamak için bir doğrusal denklem oluşturur [Hill vd., 2007].

Doğrusal regresyon, tekli ve çoklu olmak üzere iki alt başlık altında incelenebilir. Tekli doğrusal regresyon tek bir x girdisi ile, y çıktısını modellemeye çalışan algoritmadır. Söz konusu model, matematiksel olarak

$$y = a_0 + a_1x$$


olarak ifade edilebilir. Burada, x girdi, y çıktı, a_0 sabit katsayı değeri (intercept) ve a_1 girdi katsayısıdır.

Çoklu regresyonun genel amacı ise, birden fazla girdi değişkeni ile bir çıktı değişkeni arasındaki ilişkiyi nicelleştirmektir. Çıktı (bağımlı) değişkeni y'nin, girdi (bağımsız, tahmin edici) değişkenleri $x_1, \dots, x_n$ ile doğrusal bir ilişkisi olduğu varsayılmaktadır. Buradaki model

$$y = a_0 + a_1x_1 + a_2x_2 + a_3x_3 \dots + a_nx_n$$

olarak yazılabilir; x_i girdisinin katsayısı a_i ile ifade edilmektedir.

Bir doğrusal regresyon modelinin amacı, gerçek çıktı ile tahmin edilen çıktı değeri arasındaki hatayı minimum yapacak, en uygun doğruyu hesaplamaktır.



Şekil 3.1: Doğrusal Regresyon Grafiği

Şekil 3.1’de, rastgele oluşturulan veri noktaları (mavi daireler) ile bunlara en iyi uyan doğrusal regresyon doğrusu (kırmızı çizgi) bir örnek olarak gösterilmektedir. Buradaki tekli regresyon örneğinde $a_0 = 5,29$, $a_1 = 2,43$ olarak hesaplanmıştır. Veri noktalarının doğrusal regresyon doğrusuna yakın olması, modelin genel olarak iyi bir uyum sağladığını gösterir.

3.2.3. Polinomsal Regresyon

Polinomsal regresyon, bağımsız değişkenler ile bağımlı değişken arasındaki doğrusal olmayan ilişkiyi modellemek için kullanılan bir regresyon tekniğidir. Polinomlar, doğrusal regresyon modelinin bir genellemesidir ve çoklu terimler içererek daha karmaşık ilişkileri temsil edebilirler. Temel doğrusal regresyon modelinin aksine, polinomsal regresyon, bağımsız değişkenin yüksek dereceli terimlerini kullanarak daha esnek ve doğrusal olmayan bir model oluşturur. Polinom regresyonuna aslında çoklu doğrusal regresyonun özelleştirilmiş hali denilebilir. [Ostertagová, 2012]. Bir polinom, tek bir değişken olduğu durumda şu şekilde yazılabilir:

$$y = \beta_0 + \beta_1 X_1 + \beta_2 X_1^2 + \beta_3 X_1^3 + \dots + \beta_n X_1^n.$$

Burada,

- y : Bağımlı değişken (tahmin edilen değer),
- X_i : Bağımsız değişkenler,
- $\beta_0, \beta_1, \dots, \beta_n$: Polinomun katsayıları (parametreler),
- n : Polinomun derecesi.

Buradaki problem yapısı, parametrelerin hesaplanması açısından n terimli çoklu doğrusal regresyonla tamamen aynıdır. Polinomsal regresyonun temel özelliklerinden biri, modelin doğrusal olmayıp, yüksek dereceli polinom terimleri ile esneklik kazanmasıdır. n değeri, polinomun derecesini belirtir ve polinomun karmaşıklığını belirler. Daha yüksek bir derece, daha karmaşık ve veri setine daha iyi uyum sağlayan bir model oluşturabilir, ancak aşırı uyum (overfitting) riski de taşır. Polinomsal regresyon, birden fazla girdi değişkeni bulunan duruma genelleştirilebilir.

Veri setlerinde doğrusal olmayan ilişkiler olduğunda ve doğrusal modellerin yeterli olmadığı durumlarda polinomsal regresyon kullanılır. Polinomlar, verilerin doğrusal olmayan eğilimlerini yakalamada esneklik sağlar. Diğer yandan, çok yüksek dereceli polinomlar, eğitim verilerine fazla uyum sağlayarak genel performansı olumsuz etkileyebilir. Ayrıca, yüksek dereceli polinomlar, modelin yorumlanmasını zorlaştırabilir.

3.2.4. Düzenleme

Düzenleme (regularization), modelin karmaşıklığını kontrol etmek için kullanılan bir tekniktir ve aşırı uyumu engellemeye yardımcı olur. İki ana düzenleme türü vardır:

- L1 Düzenlemesi (Lasso): Modelin parametrelerinin bazılarını sıfıra yakınlştırarak değişken seçimi yapar. Bu, gereksiz özelliklerin modelden çıkarılmasına yol açar. Lasso regresyonu, L1 normu kullanır ve parametrelerin mutlak değerlerinin toplamını cezalandırır.
- L2 Düzenlemesi (Ridge): Modelin parametrelerinin büyüklüğünü küçültür, ancak parametreleri sıfıra çekmez. L2 normu, parametrelerin karelerinin toplamını cezalandırır. Ridge regresyonu bu yöntemi kullanır.

Her iki düzenleme türü de modelin genellenebilirlik performansını iyileştirebilir.

Ridge regresyonu, doğrusal regresyon modelinin bir türüdür ve özellikle aşırı uyum sorununu önlemek amacıyla L2 düzenlemesi ekler. Ridge regresyonu, kayıp fonksiyonuna, modelin parametrelerinin karelerinin toplamını ekler. Bu, modelin karmaşıklığını cezalandırarak daha genellenebilir bir model elde edilmesini sağlar. Bu durumda, parametre hesaplama alt problemi aşağıdaki formu alır.

$$\min_a \sum_i \left| y^i - (a_0 + a_1 x_1^i \dots + a_n x_n^i) \right|^2 + \alpha \|a\|^2$$


Ridge regresyonunda α parametresi, düzenleme teriminin şiddetini kontrol eder. α değeri arttıkça, modelin karmaşıklığını cezalandırmak daha fazla olur ve modelin parametreleri sıfıra yakın değerler alır. Bu da modelin daha basitleşmesini sağlar.

- α küçük (yaklaşık 0): Model daha az düzenlenir ve veri setine daha yakın bir uyum sağlanır, ancak aşırı uyum riski artar.
- α büyük (çok yüksek): Model daha fazla düzenlenir ve genellenebilirlik artar, ancak modelin doğruluğu düşebilir çünkü veriye uyum sağlama zorluğu yaşanır.

3.2.5. Rastgele Orman Regresyon

Rastgele orman (random forest), L. Breiman (2001) tarafından 2000'lerin başında tanıtılan, sınıflandırma ve regresyon için kullanılan denetimli bir öğrenme tekniğidir. Bu yöntem, orijinal verinin alt kümeleri üzerinde büyütülen bir dizi karar ağacından oluşan bir sınıflandırıcı inşa etmeyi amaçlar. Makine öğrenmesinin temel kaygılarından biri olan genellenebilirlik ve aşırı öğrenme konularında farkındalık oluşturmak amacıyla, “rastgele” ifadesi bu yöntemde gözlemlere ve değişkenlere dayalı rastgele seçim sürecini vurgulamaktadır.

Rastgele orman yöntemi, birden fazla karar ağacının ürettiği tahminlerin bir araya getirilerek değerlendirilmesi prensibine dayanır. CART (Classification and Regression Trees) yöntemini geliştiren Breiman, CART'ın yüksek öğrenme kapasitesine sahip olmasına rağmen aşırı öğrenmeye yatkınlığını önlemek adına çeşitli yöntemler geliştirmiştir. Ancak bu sorun için daha etkili bir çözüm arayışı sonucunda, rastgele orman tekniğini ortaya koymuştur.



Şekil 3.2: Rastgele Orman Teknik Görseli

Yöntemin temel adımları aşağıda açıklanmıştır.

- **Veri Alt Kümesi Seçimi:** Eğitim veri setinden rastgele bir alt küme seçilir (her bir ağaç için farklı bir alt küme).
- **Karar Ağacı Eğitimi:** Her alt küme üzerinde bir karar ağacı eğitilir. Ağaç, veriyi sınıflandırma veya regresyon için kullanılır.
- **Tahmin Yapma:** Her ağaç, yeni veriye tahmin yapar.
- **Sonuçların Birleştirilmesi:** Tüm ağaçların tahminleri birleştirilir. Sınıflandırma ise çoğunluk oyu, regresyon ise ortalama alınarak yapılır.
- **Sonuç:** Birden fazla ağacın tahminlerinin birleşmesiyle daha doğru ve sağlam bir tahmin yapılır.

Rastgele orman yöntemi, hızlı bir şekilde eğitilebilir ve büyük veri setlerini işleme kapasitesine sahiptir. Bu yöntem, neredeyse hiç ön işleme gerektirmez ve ikili, kategorik ya da sayısal özellikleri ölçeklendirmeye ihtiyaç duymadan işleyebilir. Ayrıca, özelliklerin önemini etkili bir şekilde gösterebilir, bu da modelin hangi değişkenlere daha fazla ağırlık verdiğini anlamayı kolaylaştırır. Rastgele ormanlar, kullanılan spesifik hiperparametreler konusunda oldukça toleranslıdır, bu yüzden fazla ayar yapmaya da gerek yoktur. Bu özellikleri sayesinde çok çeşitli modelleme görevlerine uygulanabilir. Ayrıca, bu modelleri paralel olarak büyütmek mümkündür;

bu da modelin daha hızlı çalışmasına imkân tanır. Bu durum artırılmış modeller ya da sinir ağları için geçerli değildir.

Rastgele orman yönteminin bazı dezavantajları da bulunmaktadır. İlk olarak, modelin yorumlanabilirliği sınırlıdır. Rastgele orman, çok sayıda karar ağacının birleşiminden oluştuğu için, her bir ağacın nasıl çalıştığını anlamak ve sonuçları yorumlamak zordur [Liaw & Wiener, 2002]. Ayrıca, modelin eğitilmesi ve tahmin yapılması, büyük veri setlerinde zaman alıcı olabilir ve yüksek hesaplama gücü gerektirebilir [Breiman, 2001]. Bu durum, özellikle sınırlı kaynaklara sahip sistemlerde performans sorunlarına yol açabilir. Diğer bir dezavantaj ise, modelin aşırı uyum yapma riski taşımasıdır. Özellikle karar ağaçları çok derinleşirse, model fazla özelleşebilir ve genelleme gücü azalabilir [Hastie, Tibshirani, & Friedman, 2009]. Ayrıca, rastgele ormanlar büyük veri setlerinde çok sayıda ağaç oluşturduğundan, bellek kullanımının yüksek olması ve verinin hızlı işlenmesini engellemesi gibi performans sorunlarına neden olabilir [Liaw & Wiener, 2002].

3.2.6. Gradyan Arttırma Regresyon

Gradyan Arttırma, zayıf öğrencileri (weak learner) bir araya getirerek güçlü bir öğrenci (strong learner) oluşturmak için kullanılan bir makine öğrenme algoritmasıdır. Gradyan Arttırma, ardışık olarak basit tahmin modellerinin doğrusal kombinasyonları şeklinde model üreten bir tahmin tekniğidir. Kullanılan basit tahmin modelleri genellikle karar ağaçlarıdır [Biau & Cadre, 2017]

3.3. Uygulama

Bu bölümde, uçak bakımlarında kabin ve koltuğu detaylı muayene ettiren kartlara istinaden tespit edilen rutin dışı kartların adam saat tahminlemesine yönelik gerçekleştirilen çalışmalarla ilgili uygulama detayları ve sonuçlar verilmiştir.

3.3.1. Veriler

Bu çalışmada kullanılan veriler, belirli bir üreticinin belirli bir tipteki dar gövdeli uçaklarının bakım süreçlerine ilişkin bir uçak bakım firmasından elde edilmiştir. Veriler, belirli bakım periyotları sırasında kabini ve koltuklarının detaylı muayenesini

yaptıran iki bakım kartı üzerinden toplanmıştır. Kabini detaylı muayene ettiren kart için 225 bakım, koltuğu detaylı muayene ettiren kart için 244 bakım incelenmiştir.

Her uçak için, hangi bakım türüne dahil olduğu bu veri setinde belirtilmiştir. Uçak başına gerçekleştirilen bakım işlemlerinin toplam süresi kaydedilmiştir. Bu süre, uçağın hangarda kaldığı ve bakım ekipleri tarafından üzerinde çalışıldığı toplam zaman olarak ifade edilmiştir. Bu değişken, bakım operasyonlarının uzunluğunu ve karmaşıklığını değerlendirmek için kullanılmıştır. Bakım kartlarına bağlı olarak rutin bakım işlemleri dışında ortaya çıkan, genellikle sorun tespiti ve giderimi için gerekli olan ek işlerin adam-saat cinsinden toplam süresi ölçülmüştür. Rutin olmayan bu işler, uçağın bakım kartlarında belirtilmeyen ancak bakım süreci sırasında keşfedilen ve çözülmesi gereken sorunlara işaret etmektedir. Her iki bakım kartı için ayrı ayrı toplanan bu veriler, bakım süreçlerinin ne kadar ek iş yarattığını ve bunların iş yükü üzerindeki etkisini değerlendirmek amacıyla kullanılmaktadır.

3.3.2. Veri Önışleme

Bu çalışmada, verilerin analiz öncesi uygun hale getirilmesi amacıyla bire-bir kodlama (one-hot encoding) yöntemi kullanılmıştır. Verilerin bazı kategorik değişkenler içerdığı göz önünde bulundurularak, makine öğrenmesi ve istatistiksel modelleme süreçlerinde bu değişkenlerin modele dahil edilebilmesi için bu dönüşüm gerekli hale gelmiştir. Bakım türü gibi kategorik değişkenler, sayısal formatta ifade edilmesi zorunlu olan yapısal değişkenlerdir.

Kategorik veriler, makine öğrenmesi ve veri analizi süreçlerinde doğrudan kullanılamazlar çünkü birçok model, girdilerin sayısal olmasını gerektirir. Bire-bir kodlama, kategorik değişkenlerin her bir kategorisini ikili değişkenlere dönüştürerek bu sorunu çözer.

Kategorik değişkenler (örneğin, bakım türleri) doğrudan analiz edilemeyeceği için, bu değişkenlerin her bir kategorisi bağımsız birer ikili (0 veya 1) değişken haline getirilmiştir. Bu, modelin her kategoriye bağımsız olarak bakmasını sağlar ve kategoriler arasında sahte bir sıralama yaratmaz. Örneğin, “C1 Bakımı” ve “C2 Bakımı” kategorileri için her bir kategori ayrı birer sütun haline getirilmiştir; bir uçak “C4 Bakımı” sürecindeyse, bu sütundaki değer 1, diğerinde ise 0 olur.

Kategorik verilerin yanlış bir şekilde sayısal değerlerle temsil edilmesi, modelin kategoriler arasında olmayan ilişkiler kurmasına neden olabilir. Bire-bir kodlama ile bu problem ortadan kaldırılarak modelin her kategoriye bağımsız birer özellik olarak algılanması sağlanır. Bu da modelleme sonuçlarının doğruluğunu ve güvenilirliğini artırır.

Bire-bir kodlama, özellikle doğrusal regresyon gibi modellemelerde kategorik değişkenlerin etkisini ölçmek ve bağımsızlıklarını korumak açısından önemli bir dönüşümdür. Bu tezde kullanılan regresyon ve diğer istatistiksel yöntemler, sayısal verilerle çalışmayı gerektirdiği için, kategorik değişkenler bu şekilde dönüştürülmüştür.

Veri seti üzerinde analiz sürecine başlamadan önce çeşitli düzeltmeler yapılmıştır. Bu düzeltmeler şunları içermektedir:

- **Eksik Verilerin Tamamlanması:** Bazı uçaklar için eksik olan bakım süresi veya adam-saat verileri, bakım raporlarından veya operasyonel kayıtlar üzerinden tamamlanmıştır.
- **Aykırı Verilerin Düzeltilmesi:** Bazı bakım süresi ve adam-saat verilerinde, veri giriş hatalarından kaynaklanan aşırı yüksek veya düşük değerler tespit edilmiştir. Bu veriler, sektör standartları ve uzman görüşleri doğrultusunda düzeltilmiştir.
- **Veri Birleştirme:** Farklı kaynaklardan alınan veriler, her uçağa ait tüm verilerin tek bir tabloya entegre edilmesiyle düzenlenmiştir. Her uçak için belirlenen bakım kartları ve ilgili adam-saat verileri ayrı sütunlarda belirtilmiş ve analiz için uygun hale getirilmiştir.

Veri seti, her uçak için yukarıda belirtilen şekilde düzenlendikten sonra, analize uygun hale getirilmiştir. Analiz sürecinde kullanılan temel değişkenler aşağıda listelenmiştir.

1. Uçak ID: Her bir uçağın benzersiz kimliği, analizde takip edilmesi ve karşılaştırılması için kullanılmıştır.
2. Uçak tipi (AC_TYPE): Uçağın dar gövde (narrow-body) veya geniş gövde (wide-body) olması, bakım ihtiyaçlarını etkiler.
3. Uçak yaşı (AC_YEARS): Daha eski uçaklarda daha fazla rutin olmayan iş ortaya çıkabilir.

4. Bakım Türü (WO_DESCRIPTION): Uçağın dahil olduğu bakım kategorisi (C1-Check, C2-Check vb.).
5. Toplam Bakım Süresi (TAT): Bakım operasyonlarının tamamlanması için harcanan toplam süre.
6. Rutin Olmayan İşlerin Toplam Adam-Saati: İlgili bakım kartlarına bağlı olarak ortaya çıkan rutin dışı işlerin iş gücü yükü.

Bu değişkenler; uçağa, bakım süresine ve bakım türüne göre değişkenlik gösteren rutin olmayan işlerin tahminlemesini yapabilmek için kullanılmıştır.

3.3.3. Uygulama Detayları ve Deneysel Kurgu

İlk olarak veri setlerinin temel özelliklerini özetlemek ve analiz etmek için kullanılan istatistiksel ölçümlerden yararlanılmıştır. Ortalama (aritmetik ortalama) ve medyan, merkezi eğilimleri anlamak için yaygın olarak kullanılan iki temel ölçüttür. Veri setinde aynı bakım türünde oluşturulan rutin olmayan kartların adam saatlerinin ortalama ve medyan değerleri hesaplanmıştır. Hem kabin hem de koltuk muayene kartları kapsamında oluşan rutin olmayan kartlar için belirlenen değerler ileriki bölümlerde diğer tahmin yöntemleri ile karşılaştırılacaktır.

Tüm uygulamalar Python 3.9.13 versiyonu ile gerçekleştirilmiş, veri işleme ve analiz için pandas (1.5.3), modelleme için Scikit-Learn (1.2.2) ve veri görselleştirme için matplotlib (3.7.1) ve seaborn (0.12.2) kütüphaneleri kullanılmıştır. Betimleyici istatistik tahminleyicilerinden sonra doğrusal regresyon, polinomsal regresyon, rastgele orman ve gradyan arttırma gibi regresyon analizi ve makine öğrenmesi teknikleri kullanılarak modellemeye dayalı tahminler ve değerlendirilmeler yapılmıştır.

İlk adımda, Python pandas kütüphanesi kullanılarak, MS Excel dosyasından veri seti yüklenmiştir. Bu veri seti, çeşitli değişkenler içermektedir ve her bir değişkenin özellikleri incelenmiştir. Özellikle, AC_TYPE, AC_YEARS ve WO_DESCRIPTION gibi kategorik veriler üzerinde işlem yapılacağı için, bu değişkenlerin değerleri önce incelenmiştir.

Veri setindeki bazı kategorik değişkenler, makine öğrenimi modeline uygun hale getirilmek için sayısal verilere dönüştürülmüştür. Bunun için bire-bir kodlama (OHE) tekniği kullanılmıştır. Bu teknik, her kategoriye ikili bir vektör olarak temsil eder,

böylece model bu kategorileri işleyebilir. Bu adımda, AC_TYPE ve WO_DESCRIPTION değişkenlerine OHE uygulanmıştır. OHE'nin uygulanmasının ardından, orijinal kategorik sütunlar veri setinden çıkarılmış ve sayısal karşılıkları veri setine eklenmiştir.

Veri seti daha sonra sayısal verilere dönüştürülüp, tahmin edilmek istenen hedef değişken (Y) ile bağımsız değişkenler (X) oluşturulmuştur. Özellikler (X) ve hedef değişken (Y) belirli bir formatta ayrılmış ve veri matrisine dönüştürülmüştür. Bunun için, veri matrisinden belirli sütunlar seçilerek bağımsız ve bağımlı değişkenler elde edilmiştir.

Veri seti, model performansını değerlendirmek amacıyla eğitim ve test setleri olarak ikiye ayrılmıştır. Bu kapsamda, veri setinin %80'i eğitim seti ve %20'si test seti olarak kullanılmıştır. Eğitim seti, modellerin eğitilmesi için kullanılırken; test seti, modellerin genel performansını değerlendirmek için ayrılmıştır. Veri bölme işlemi Excel'de gerçekleştirilmiş ve sonuçlar uygun formatta kaydedilmiştir.

Doğrusal Regresyon

Bağımsız değişkenler (X) ve bağımlı değişken (Y) hazırlandıktan sonra, doğrusal regresyon modeli oluşturulmuş ve eğitilmiştir. Bu model, bağımsız değişkenlerle bağımlı değişken arasındaki doğrusal ilişkiyi öğrenmek için kullanılır. Modelin parametreleri (eğilim ve katsayılar) veri üzerinde eğitim yapılarak belirlenmiştir.

Doğrusal regresyon modelini oluşturmak ve eğitmek için Scikit-Learn kütüphanesindeki LinearRegression sınıfı kullanılmıştır. Model değerlendirme aşamasında, performans ölçütleri olarak R^2 (determinasyon katsayısı) ve ortalama karesel hata (Mean Squared Error- MSE) hesaplanmıştır. Bu işlemler için metrics modülündeki araçlardan yararlanılmıştır. Doğrusal regresyon için model eğitimi ve tahmin adımlarında ise fit ve predict metodları kullanılmıştır. Model eğitildikten sonra, modelin tahminleri alınmış ve gerçek değerlerle karşılaştırılmıştır. Modelin doğruluğu, Ortalama Kare Hatası (MSE) hata metriği kullanılarak değerlendirilmiştir. Bölüm 3.2.1'de açıklandığı gibi, MSE tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasını hesaplar ve modelin ne kadar iyi tahminler yaptığını gösterir. Daha düşük MSE değerleri, modelin yüksek doğrulukla tahminler yaptığını gösterirken, yüksek MSE değerleri modelin iyileştirilmesi gerektiğini işaret eder.

Sonuç olarak, modelin tahmin ettiği değerler ile gerçek değerler arasındaki farkların karelerinin ortalaması olan MSE değeri hesaplanmıştır. Model çözdürüldüğünde kabin kapsamında MSE değeri 51685.8, koltuk kapsamında ise 45283,4 olarak elde edilmiştir.

Polinomsal Regresyon


Polinomsal regresyon, doğrusal regresyonun bir uzantısıdır ve daha karmaşık, doğrusal olmayan ilişkileri modellemek için kullanılır. Bu model, bağımsız değişkenlerin polinom terimlerine dayalı olarak bağımlı değişkeni tahmin etmeye çalışır ve doğrusal regresyonun sınırlamalarını aşmak için kullanılan güçlü bir yöntemdir. Ancak, dereceyi ve diğer parametreleri dikkatlice optimize etmek, aşırı öğrenmeyi engellemek ve iyi bir genelleme sağlamak için önemlidir.

Bu çalışmada polinomsal regresyon L2-düzenleştirmesi ile uygulanmıştır. Düzenleştirme parametresi ve polinom derecesini optimize etmek, polinomsal regresyon modelinin doğruluğunu artırmak ve aşırı öğrenmeyi engellemek için kritik bir adımdır. Bu parametrelerin optimizasyonu için şu bilgiler dikkate alınmıştır.


- Derece (Degree). Polinomal regresyonun derecesi, kullanılan polinomun karmaşıklığını belirler. Yani, polinomal terimlerin sayısını ve modelin ne kadar eğik olacağını kontrol eder. Derece çok düşük tutulursa, modelin kapasitesi yeterli olmayabilir (underfitting), yani veri setini yeterince iyi modellemez. Eğer dereceyi çok yüksek tutulursa, model aşırı karmaşık hale gelir ve eğitim verisini mükemmel bir şekilde ezberleyebilir (overfitting).
- α (Regularization Parameter). α , modelin düzenleştirme parametresidir. α , modelin karmaşıklığını kontrol eder; küçük değerler aşırı uyuma neden olabilir, büyük değerler ise modelin fazla basitleştirilmesine neden olabilir.

Bu parametreleri optimize etmek için genellikle kılavuz arama (grid search) veya rastgele arama (random search) gibi yöntemler kullanılmaktadır. Bu yöntemlerle farklı α ve derece değerlerini deneyip en iyi performansı veren kombinasyon bulunmaya çalışılmıştır. Aşağıdaki Şekil 3.3 ve Şekil 3.4 grafiklerinde polinomsal model için en iyi MSE'nin elde edildiği ısı haritası paylaşılmıştır.

Alınan sonuçlarda kabin için en iyi model: Derece = 3, α = 50 ile Test MSE: 66104.7 ile, koltuk için en iyi model: Derece = 2, α = 10 için MSE: 65919.8 sonucunda ulaşılmıştır.



Şekil 3.3: Kabin ısı haritası



Şekil 3.4: Koltuk ısı haritası

Rastgele Orman Regresyon

Rastgele orman algoritması, bir (topluluk ensemble) öğrenme yöntemidir. Bu, birçok bağımsız karar ağacının birleştirilmesiyle çalışır ve her ağaç, veri setinin rastgele bir örneği üzerinde eğitilir. Bu yöntem, modelin genellenebilirliğini artırırken aşırı öğrenme riskini azaltır.

Bu çalışmada, hiperparametre optimizasyonu amacıyla, ağaç sayısı (n_estimators) ve ağaç derinliği (max_depth) parametreleri için çeşitli kombinasyonlar test edilmiştir. Hiperparametre optimizasyonu, modelin en uygun şekilde çalışmasını sağlamak ve en iyi sonuçları elde etmek için kritik bir adımdır. Modelin bu parametrelerle eğitilmesi, farklı veri setlerinde en düşük hata oranını ve yüksek doğruluk seviyesini yakalamak için önemlidir.

Modelin başarısını artırmak için hiperparametrelerin optimize edilmesi gerekmektedir. Ağaç sayısının artması, modelin doğruluğunu artırabilirken, çok yüksek ağaç derinliği değerleri aşırı öğrenmeye neden olabilir. Bu yüzden her iki parametreyi farklı kombinasyonlarda test etmek, en iyi genelleme yeteneğine sahip modelin seçilmesini sağlar.

Sonuç olarak, hiperparametre optimizasyonu yaparak en uygun model seçilmiş ve en düşük MSE değeri ve yüksek R^2 değeri ile en iyi performansa sahip model belirlenmiştir. Kabin kartları için alınan sonuç **Tablo 3.1**'de verilmiştir.

Tablo 3.1: Kabin Koltuk Rastgele Orman Analiz Sonuçları

En iyi model: Kabin	En iyi model: Koltuk
Ağaç sayısı: 200.0	Ağaç sayısı: 200.0
Ağaç derinliği: 10.0	Ağaç derinliği: 10.0
Eğitim MSE: 9635.982967710432	Eğitim MSE: 9811.968979576985
Eğitim R^2 : 0.9012413845872199	Eğitim R^2 : 0.9119444485610967
Test MSE: 92068.73151701337	Test MSE: 163403.7324202484
Test R^2 : -0.15140243583831947	Test R^2 : -0.453225219214720

Rastgele Orman modelinin performansını değerlendirirken daha fazla hiperparametreyi optimize etmek için genişletilmiş bir yapı kullanılmıştır. Modelin ayarlanabilir parametre sayısında eklemeler yapılmıştır. Bu tür bir hiperparametre optimizasyonu, modelin daha doğru ve genellenebilir tahminler yapmasını sağlamak amacıyla önemlidir.

Min_samples_split: Bu parametre, bir iç düğümdeki minimum örnek sayısını belirler. Yani, bir düğümün bölünmesi için gereken minimum örnek sayısını ayarlamak, modelin daha sağlam ve aşırı öğrenmeye daha dayanıklı olmasını sağlar.

Min_samples_leaf: Bu parametre, yaprak düğümdeki minimum örnek sayısını belirler. Bu da modelin daha az karmaşık hale gelmesini sağlar ve aşırı öğrenmeyi engelleyebilir.

n_estimators (ağaç sayısı), max_depth (ağaç derinliği), min_samples_split (iç düğümde minimum örnek sayısı) ve min_samples_leaf (yaprak düğümde minimum örnek sayısı) gibi parametrelerin farklı kombinasyonlarıyla modelin eğitilmesi sağlanmıştır. Bu sayede modelin daha geniş bir parametre aralığında test edilmesi ve en iyi performansı gösteren parametrelerin seçimi mümkün olmuştur.

Yeni sonuçlar aşağıdaki **Tablo 3.2**'de verilmiştir.

Tablo 3.2: Kabin Koltuk Rastgele Orman Hipermatre Ayarlaması Sonrası Analiz Sonuçları

En iyi model: Kabin	En iyi model: Koltuk
Ağaç sayısı: 50.0	Ağaç sayısı: 500.0
Ağaç derinliği: 10.0	Ağaç derinliği: nan
Min_samples_split: 10.0	Min_samples_split: 2.0
Min_samples_leaf: 1.0	Min_samples_leaf: 4.0
Eğitim MSE: 22153.844099685877	Eğitim MSE: 28991.26171481968
Eğitim R ² : 0.7729465715446964	Eğitim R ² : 0.7398237252358222
Test MSE: 89799.81127187899	Test MSE: 125211.32230260193
Test R ² : -0.12302754401646543	Test R ² : -0.11356239301432192

Tablo 3.1 ve **Tablo 3.2**'de kabin ve koltuk kartları için rastgele orman modeliyle yapılan analizleri ve hiperparametre ayarlamalarının etkisini göstermektedir. Eğitim ve test MSE ile R² değerleri dikkate alınarak model performansları değerlendirilmiştir.

Kabin Kartları

1. Eğitim MSE

- **Tablo 3.1**'de en düşük eğitim MSE değeri (9635.98) elde edilmiştir.
- **Tablo 3.2**'de hiperparametre optimizasyonu sonrası bu değer artarak 22153.84 olmuştur. Bu artış, aşırı öğrenmenin (overfitting) azaldığını ve modelin genelleştirme kapasitesinin artırıldığını göstermektedir.

2. Test MSE:

- En düşük test MSE değeri, **Tablo 3.2**'de (89799.81) görülmektedir. Hiperparametre optimizasyonu, test performansını bir miktar iyileştirmiştir (**Tablo 3.1**'deki test MSE: 92068.73).

3. Test R²:

- **Tablo 3.2'de** test R² değeri (-0.1230), **Tablo 3.1'e** göre (-0.1514) iyileşmiştir. Ancak her iki durumda da negatif olması, modelin test setindeki performansının yetersiz olduğunu göstermektedir.

Koltuk Kartları

1. Eğitim MSE:

- En düşük eğitim MSE değeri **Tablo 3.1'de** (9811.97) elde edilmiştir.
- **Tablo 3.2'de** bu değer artarak 28991.26 olmuştur. Bu, aşırı öğrenmenin azaltıldığına işaret eder.

2. Test MSE:

- En düşük test MSE değeri, **Tablo 3.2'de** (125211.32) elde edilmiştir. Bu, **Tablo 3.1'e** göre (163403.73) belirgin bir iyileşme olduğunu göstermektedir.

3. Test R²:

- **Tablo 3.2'de** test R² değeri (-0.1135), **Tablo 3.1'deki** (-0.4532) değere kıyasla daha iyi bir performans sergilemiştir. Ancak, negatif olması test performansının hâlâ yetersiz olduğunu göstermektedir.

Sonuç

1. Eğitim Performansı: **Tablo 3.1'de** her iki kart grubu için de daha düşük eğitim MSE değerleri elde edilmiş, ancak bu durum aşırı öğrenme kaynaklıdır.
2. Test Performansı: Hiperparametre optimizasyonu sonrası (**Tablo 3.2**), hem test MSE değerlerinde düşüş hem de test R² değerlerinde iyileşme görülmüştür. Bu, modelin test setindeki genelleştirme kabiliyetinin arttığını göstermektedir.
3. En İyi Test Performansı: **Tablo 3.2'de** her iki kart grubu için daha düşük test MSE ve daha yüksek test R² değerleri elde edilmiştir. Bu tablo, genelleştirme açısından daha iyi sonuçlar sunmuştur.

Gradyan Arttırma Regresyon

Gradyan arttırma, topluluk öğrenme yöntemlerinden bir diğeridir ve doğruluğu arttırmak için zayıf öğrencilerin (genellikle karar ağaçları) ardışık olarak birleştirildiği bir yöntemdir. Her yeni ağaç, önceki ağaçların hatalarını düzeltmeye çalışır. Modelin başarısı, ağaçların bir arada nasıl çalıştığına bağlıdır. Gradyan arttırma, yüksek

doğruluk sağlayabilir, ancak modelin aşırı öğrenme eğilimi gösterebileceği için doğru hiperparametre ayarlamaları burada da önemlidir.

Gradyan arttırma, modelin doğruluğunu artıran bir zayıf öğrenici kombinasyonudur. Her bir öğrenici (ağaç), önceki modelin hatalarını minimize etmek için eğitilir. Bu yöntem, her yeni modelin, hata yapmış olan veriler üzerine yoğunlaşarak tahminleri geliştirmeye çalıştığı için çok güçlüdür. Bu "gradyan" optimizasyonu ile modelin hatalarını sürekli olarak düzeltir.

Çalışmanın veri seti ile bir gradyan arttırma regresyon modeli de eğitilmiş ve modelin başarısı (MSE, R^2) hesaplanmıştır. Sonuçlar **Tablo 3.3**'te görülmektedir.

Tablo 3.3: Kabin Koltuk Gradyan Arttırma Regresyon Analiz Sonuçları

Kabin	Koltuk
Eğitim MSE: 7878.892311503059	Eğitim MSE: 6350.2741212703095
Eğitim R^2 : 0.9192497020513805	Eğitim R^2 : 0.9430107361019437
Test MSE: 90578.8825429901	Test MSE: 153614.6926948072
Test R^2 : -0.13277053215661616	Test R^2 : -0.3661667463744571

İkinci olarak GridSearchCV ile hiperparametreler optimize edilmiş ve en iyi model bulunmaya çalışılmıştır. GridSearchCV, Scikit-Learn kütüphanesinde yer alan bir araçtır ve makine öğrenmesi modellerinin hiperparametre optimizasyonunu gerçekleştirmek için kullanılır. Adı, bir ızgara arama (grid search) süreci ve çapraz doğrulama (cross-validation) tekniklerini birleştirdiğini ifade eder. GridSearchCV, model için belirtilen hiperparametrelerin tüm olası kombinasyonlarını sistematik bir şekilde dener ve en iyi performansı sağlayan hiperparametre setini seçer.

Tablo 3.4: Kabin Koltuk Gradyan Arttırma Regresyon GridSearchCV ile Hiperparametreler Optimizasyon Sonrası Analiz Sonuçları

Kabin	Koltuk
En iyi Parametreler	En iyi Parametreler
Learning_rate: 0.05	Learning_rate: 0.1
'max_depth': 2	'max_depth': 2
'n_estimators': 200	'n_estimators': 50
Eğitim MSE: 20712.94698784358	Eğitim MSE: 20952.323541901696
Eğitim R ² : 0.787714240208564	Eğitim R ² : 0.8119675666271817
Test MSE: 75417.52735446837	Test MSE: 134723.11753139383
Test R ² : 0.056835873916742385	Test R ² : -0.1981552018917634

Son olarak, daha detaylı hiperparametre araması yapılmış ve sonuçlar yeniden değerlendirilmiştir.

Tablo 3.5: Kabin Koltuk Gradyan Arttırma Regresyon GridSearchCV ile Daha Detaylı Hiperparametreler Optimizasyon Sonrası Analiz Sonuçları

Kabin	Koltuk
En iyi Parametreler	En iyi Parametreler
Learning_rate: 0.05	Learning_rate: 0.01
'max_depth': 2	'max_depth': 3
'min_samples_leaf': 2	'min_samples_leaf': 2
'min_samples_split': 2	'min_samples_split': 2
'n_estimators': 200	'n_estimators': 300
'subsample': 1.0	'subsample': 1.0
Eğitim MSE: 22752.412597736704	Eğitim MSE: 20986.43337455089
Eğitim R ² : 0.766811878665382	Eğitim R ² : 0.811661454762207
Test MSE: 86363.40578039175	Test MSE: 160809.9043280227
Test R ² : -0.0800521973571553	Test R ² : -0.4301571023357522

Tablo 3.3, Tablo 3.4, Tablo 3.5, kabin ve koltuk kartları için gradyan arttırma regresyon modeli kullanılarak yapılan analizlerde farklı hiperparametre kombinasyonlarının etkisini göstermektedir. Sonuçlar, eğitim ve test seti üzerindeki MSE ve R² değerleri temelinde değerlendirilmiştir.

Kabin Kartları

1. Eğitim MSE:

- **Tablo 3.3'te** en düşük eğitim MSE değeri (7878.89) elde edilmiştir.

- **Tablo 3.4** ve **Tablo 3.5'te** hiperparametre optimizasyonu sonrasında bu değerler artmış (20712.95 ve 22752.41), ancak bu durum aşırı öğrenmenin (overfitting) azaltıldığını göstermektedir.

2. Test MSE:

- En düşük test MSE değeri, **Tablo 3.4'te** (75417.53) görülmektedir. Bu, GridSearchCV ile yapılan hiperparametre optimizasyonunun test performansını iyileştirdiğini gösterir.
- **Tablo 3.5'te** test MSE değeri artmış (86363.41), bu da daha detaylı hiperparametre ayarlarının kabin kartları için ek bir fayda sağlamadığını göstermektedir.

3. Test R²:

- **Tablo 3.4'te** test R² değeri (0.0568) pozitif olup, modelin test setinde ortalama bir tahmin yapmaktan daha iyi performans gösterdiğini ifade eder.
- **Tablo 3.3** ve **Tablo 3.5'te** test R² değerleri negatif olup, modelin bu durumlarda test performansının yetersiz olduğunu göstermektedir.

Koltuk Kartları

1. Eğitim MSE:

- En düşük eğitim MSE değeri yine Tablo 3.3'te (6350.27) elde edilmiştir.
- **Tablo 3.4** ve **Tablo 3.5'te** bu değerler sırasıyla 20952.32 ve 20986.43 olarak artmıştır. Eğitim R² değerlerinin düşmesi, aşırı öğrenmenin önüne geçildiğini göstermektedir.

2. Test MSE:

- En düşük test MSE değeri Tablo 3.4'te (134723.12) elde edilmiştir.
- **Tablo 3.5'te** test MSE tekrar yükselerek (160809.90) modelin performansında bir düşüş olduğunu göstermektedir.

3. Test R²:

- **Tablo 3.4'te** test R² değeri (-0.1981) **Tablo 3.3'e** göre bir iyileşme göstermiştir, ancak pozitif değildir ve modelin performansı hâlâ zayıftır.
- **Tablo 3.5'te** test R² değeri (-0.4302) daha da düşmüş, bu da daha karmaşık hiperparametrelerin koltuk kartlarında model performansını kötüleştirdiğini göstermektedir.

Sonuç

Eğitim Performansı: **Tablo 3.3'te** en düşük eğitim MSE ve en yüksek eğitim R^2 değerleri görülmüştür, ancak bu durum aşırı öğrenmenin işareti.

Test Performansı: En düşük test MSE ve en iyi test R^2 değerleri **Tablo 3.4'te** elde edilmiştir. Bu, GridSearchCV ile yapılan temel hiperparametre optimizasyonunun modelin genelleştirme kabiliyetini iyileştirdiğini göstermektedir.

Detaylı Hiperparametre Optimizasyonu: **Tablo 3.5'te**, daha karmaşık hiperparametre kombinasyonları test performansını iyileştirmemiş, aksine düşürmüştür. Özellikle koltuk kartlarında model performansı olumsuz etkilenmiştir.

Tablo 3.4, test performansı açısından en iyi sonuçları sunmuştur ve modelin genelleştirme kabiliyeti bu tabloda daha iyidir.

3.3.4. Sonuçlar

Bu bölümde, uçak bakımlarındaki rutin olmayan işlerin belirsizlikleri, veri analitiği ve makine öğrenimi yöntemleriyle incelenmiştir. Uygulanan geçmiş bakımlardaki rutin olmayan işler kategorilendirilmiş ve bu veriler üzerinden ortalama ve medyan kullanılarak tahminler yapılmıştır. Devamında polinomsal regresyon, Rastgele Orman ve gradyan arttırma gibi modele dayalı teknikler kullanılarak, bakım süresini etkileyen belirsizlikler tahmin edilmiş ve bu tahminlerin doğrulukları karşılaştırılmıştır. Tüm bu teknikler kullanılarak test verisi için elde edilen tahmin değerleri **Tablo 3.6'da** verilmiştir.

Kabin bölümünde gradyan arttırma genellikle yüksek doğruluk sağlıyor gibi gözükmemekte, ancak bazı durumlarda (örneğin, C001 ve C009 için) tahminlerin gerçek değerlerden oldukça uzaklaştığı görülmektedir. Rastgele Orman modelinin bazı tahminleri (örneğin C003 ve C004 için) çok düşük değerler tahmin ederek gerçek değerlerden sapma göstermiştir. Polinomsal regresyonun genellikle düşük değerler tahmin ettiği, dolayısıyla gerçek değerlere göre sistematik bir sapma (underfitting) gösterdiği söylenebilir. Rastgele Orman ve Gradyan Arttırma modellerinin daha dengeli tahminler ürettiği gözlenebilir. Medyan ve ortalama değerler, genellikle daha sabit

tahminler sunmaktadır. Ancak bu tahminler gerçek veriye göre belirgin bir genel sapma göstermektedir.

Koltuk bölümünde polinomsal regresyon tahminleri, genel olarak gerçek değerlere yakın görünmekle birlikte yüksek varyansa sahiptir. Yüksek sapma gösterdiği durumlar (örneğin, bakım ID'leri C007 ve C009) modelin daha karmaşık veri ilişkilerini anlamakta zorlandığını göstermektedir. Rastgele Orman genelde stabil ve gerçek değerlere daha yakın tahminler üretmiş olup bazı durumlarda (örneğin bakım ID'si C007 için 1554,31 tahmini) ciddi sapmalar görülebilmektedir. Gradyan artırma modeli bazı durumlarda aşırı yüksek tahminler üretmiştir. (Örneğin, C009 için 1903 ve 2087,94). Bu durum, modelin uç örneklerle (outlier) duyarlı olduğunu veya aşırı öğrenme yaşadığını gösterebilir. Medyan ve ortalama tahmin değerleri gerçek değerlere göre oldukça uzak kalmıştır.

Elde edilen sonuçlar, özellikle gradyan artırma ve polinomsal regresyon modellerinin yüksek tahmin başarısı ile belirsizliğin modellenmesinde etkili olduğunu göstermektedir. Rastgele orman regresyon ise belirli senaryolarda uygun bir performans sergilemekle birlikte, doğrusal olmayan ilişkilerin tam anlamıyla yakalanmasında diğer modeller kadar başarılı olamamıştır.

Sonuç olarak, deterministik bir planlama sürecinde kullanılabilecek şekilde güvenli tahminler yapabilen bir tahmin modeli bulunamamıştır. Bu durum tahmin modellerini gürbüz optimizasyon ile entegre bir şekilde kullanma yaklaşımına bizi yöneltmiş ve dördüncü bölümdeki gürbüz planlama çalışmasının temelini oluşturmuştur. Gürbüz optimizasyon, bakım sürecindeki belirsizliklerin yönetimi için daha sağlam bir planlama modeli geliştirilmesine olanak tanımıştır.

Tablo 3.6: Kabin Rutin Olmayan Kartlar için Regresyon Analiz Tablosu

	BAKIM	Gerçek Değerler	Polinomal Regresyon Tahmin Değerler	Random Forest Regresyon Tahmin Değerler	Gradient Boosting Regressor	Median Tahmin Değerler	Ortalama Tahmin Değerler
1	C001	249,5165	211,334488	382,835396	456,003657	67,855	74,95250714
2	C001	397,4167	211,425732	382,835396	456,003657	67,855	74,95250714
3	C001	315,0666	190,91133	348,011423	320,236048	67,855	74,95250714
4	C001	39,0001	162,556006	300,536156	321,312819	67,855	74,95250714
5	C002	345,0666	365,554223	367,321388	407,260471	308,8166	282,601475
6	C002	238,25	318,141213	331,932012	331,624762	308,8166	282,601475
7	C002	309,9499	416,716992	410,516581	241,830162	308,8166	282,601475
8	C002	36,68	363,165179	326,467509	398,343745	308,8166	282,601475
9	C002	372,0467	345,615049	348,338736	503,303764	308,8166	282,601475
10	C003	362	465,406711	210,352987	407,861985	430,5084	433,411675
11	C003	154,5	539,892701	573,275055	110,762984	430,5084	433,411675
12	C003	574,8835	446,690049	87,719634	177,284271	430,5084	433,411675
13	C004	493,9667	303,913445	188,251588	338,442892	252,1433	271,8419704
14	C004	91,3299	336,109665	358,062861	450,452303	252,1433	271,8419704
15	C005	261,7667	366,37193	400,948301	99,782261	267,1169	338,5209174
16	C005	229,8667	350,712002	133,155687	219,411127	267,1169	338,5209174
17	C005	554,2834	488,147794	427,371683	269,14308	267,1169	338,5209174
18	C005	308	277,660342	185,016707	363,857675	267,1169	338,5209174
19	C005	696,75	366,94114	173,080513	345,131238	267,1169	338,5209174
20	C006	338,8334	436,239007	405,845668	422,314521	444,8066	529,5521833
21	C006	348,55	454,227026	346,394083	386,068991	444,8066	529,5521833
22	C006	668	448,418358	624,701154	236,570763	444,8066	529,5521833
23	C006	398,0667	502,106892	627,763404	349,280759	444,8066	529,5521833
24	C006	709,0667	456,539917	668,418278	561,42844	444,8066	529,5521833
25	C006	1457	453,369942	693,701749	389,291983	444,8066	529,5521833
26	C007	205,8667	754,227411	485,390826	370,565546	907,89995	882,4526071
27	C007	761	700,495646	381,528724	156,44302	907,89995	882,4526071
28	C007	1344	651,23163	255,734917	469,629622	907,89995	882,4526071
29	C007	877	651,854597	255,245691	173,238681	907,89995	882,4526071
30	C008	415,6	290,470508	127,331164	456,996184	352,3418	413,348715
31	C008	345,3333	409,620049	206,776341	495,380256	352,3418	413,348715
32	C008	362,2167	336,627782	284,228349	487,210035	352,3418	413,348715
33	C008	501,1001	361,085801	343,702445	363,857675	352,3418	413,348715
34	C008	414,3266	342,277604	327,045065	99,782261	352,3418	413,348715
35	C008	792,4498	353,759189	396,779808	240,453858	352,3418	413,348715
36	C008	338,2499	347,782643	533,864306	393,175077	352,3418	413,348715
37	C008	244,7667	272,832244	98,932197	383,264094	352,3418	413,348715
38	C009	441,6266	480,333527	405,808163	187,045238	547,26655	563,5412
39	C009	338,1833	496,860729	426,758343	335,241847	547,26655	563,5412
40	C009	239,3833	362,312674	103,196717	465,909987	547,26655	563,5412
41	C009	628,6999	537,931655	630,587432	466,986758	547,26655	563,5412
42	C009	571,3333	520,718256	614,093509	395,083395	547,26655	563,5412
43	C009	396,2499	393,439095	350,259638	395,083395	547,26655	563,5412
44	C009	607,5834	439,672868	588,015551	585,69196	547,26655	563,5412

Tablo 3.7: Koltuk Rutin Olmayan Kartlar için Regresyon Analiz Tablosu

	BAKIM	Gerçek Değerler	Polinomal Regresyon Tahmin Değerler	Random Forest Regresyon Tahmin Değerler	Gradient Boosting Regressor	Median Tahmin Değerler	Ortalama Tahmin Değerler
1	C001	153,23	224,215193	165,99	209,02	200,9166	195,689076
2	C001	188,66	228,154118	246,29	264,54	200,9166	195,689076
3	C001	332,4501	232,894499	250,34	264,54	200,9166	195,689076
4	C001	159,5001	233,57776	191,30	189,34	200,9166	195,689076
5	C001	380,1667	233,806196	199,48	189,34	200,9166	195,689076
6	C002	310,6167	358,53423	306,33	345,41	228,8133	277,229113
7	C002	162,1966	259,888547	263,76	259,65	228,8133	277,229113
8	C002	350,75	362,06971	315,67	360,33	228,8133	277,229113
9	C001	236,3333	244,108435	245,86	306,99	200,9166	195,689076
10	C004	333,9434	356,159411	377,09	548,89	404,1166	409,064033
11	C002	152,7501	270,328762	295,56	314,49	228,8133	277,229113
12	C004	409,4333	453,19268	372,12	513,61	404,1166	409,064033
13	C003	100,9167	451,591195	314,35	363,13	319,75	399,06911
14	C007	234,5734	581,592682	326,50	650,68	866,3495	842,157512
15	C004	246,5	457,131992	420,13	495,08	404,1166	409,064033
16	C001	115,98	210,04111	187,72	259,65	200,9166	195,689076
17	C007	211,2	581,342102	354,20	684,33	866,3495	842,157512
18	C008	159,4135	558,820662	613,81	869,79	336,065	492,095427
19	C005	326,3	484,13834	531,33	661,93	401,7499	430,903624
20	C005	134,51	422,670638	525,76	640,84	401,7499	430,903624
21	C008	333,6667	586,093774	687,28	647,35	336,065	492,095427
22	C005	793,1799	503,496554	649,78	535,00	401,7499	430,903624
23	C008	632,6963	418,301493	585,36	455,02	336,065	492,095427
24	C005	1161,843	501,642096	555,33	546,76	401,7499	430,903624
25	C008	605,5499	598,957641	687,25	651,38	336,065	492,095427
26	C008	209,2501	432,671406	584,35	484,25	336,065	492,095427
27	C002	411,7001	406,096987	390,79	339,47	228,8133	277,229113
28	C009	821,3996	499,690502	573,75	1903,00	466,5667	501,146619
29	C009	383,9935	570,264749	661,13	1730,07	466,5667	501,146619
30	C008	229,35	454,61034	640,35	1092,30	336,065	492,095427
31	C005	381,7467	447,281826	537,17	661,93	401,7499	430,903624
32	C006	520,7669	515,037318	660,47	508,83	417,6334	491,995322
33	C007	423,4998	591,729664	694,63	522,99	866,3495	842,157512
34	C006	196,25	555,686671	731,37	550,19	417,6334	491,995322
35	C009	324,2601	528,029995	660,37	1730,07	466,5667	501,146619
36	C007	934,2299	893,579249	894,52	652,08	866,3495	842,157512
37	C009	879,8164	559,852649	681,81	2087,94	466,5667	501,146619
38	C003	679,9299	545,650475	488,76	125,05	319,75	399,06911
39	C007	901,1833	854,996182	736,61	700,09	866,3495	842,157512
40	C003	1147,884	576,303119	568,09	342,26	319,75	399,06911
41	C007	500,8167	971,009111	1554,31	649,37	866,3495	842,157512
42	C005	1514,414	736,844788	1520,98	535,00	401,7499	430,903624
43	C001	481,5933	465,476111	1494,05	306,99	200,9166	195,689076
44	C001	334,5	482,51745	1494,05	250,93	200,9166	195,689076
45	C007	1236	1206,84559	1554,31	645,16	866,3495	842,157512

4. GÜRBÜZ (ROBUST) PLANLAMA

4.1.Literatür

Gürbüz(robust) planlama, belirsizliklere karşı hassasiyeti düşük çözümler sunmayı amaçlayan bir yaklaşımdır. Planlama sürecinde, girdi verilerindeki belirsizliklerin planın çıktıları üzerindeki etkisini minimize etmeyi hedefler. Bu, karar vericilere daha esnek ve dayanıklı bir planlama yapısı sunar. Belirsizlik, özellikle operasyonel sistemlerde kaçınılmaz bir faktör olduğundan, gürbüz planlama yaklaşımı, bu belirsizliklerin etkisini dikkate alan daha gerçekçi bir çözüm olarak öne çıkar. Gelecekteki belirsizliği ve buna bağlı maliyetleri proaktif bir şekilde dikkate almayı öngörür [Mulvey vd., 1995]. Uçak bakımı gibi karmaşık ve kritik bir alanda, belirsizlikler hem planlama hem de operasyonel süreçlerde önemli etkiler yaratabilir. Bu belirsizlikler genellikle rutin olmayan işlerin adam-saat ihtiyaçlarındaki öngörülemeyen dalgalanmalardan kaynaklanır. Bu nedenle, gürbüz planlama yaklaşımları uçak bakım süreçleri için oldukça uygundur.

Deterministik optimizasyon problemlerinde, model parametrelerinin bilindiği varsayılmasına rağmen gerçek uygulamalarda birçok gerçekçi parametre belirsizliğe maruz kalmaktadır. Bu durumlarda, belirsiz parametreler için deterministik değerler varsaymak, pratik uygulama için uygulanamaz veya optimal olmayan kararlarla sonuçlanacaktır. Bu nedenle, birçok pratik optimizasyon probleminde parametre belirsizliğinin göz önünde bulundurulması önem arz etmektedir. Geçmişte, optimizasyon problemlerindeki belirsizlikleri ele almak için çeşitli yaklaşımlar önerilmiştir; bunlar arasında gürbüz optimizasyon, geri dönüşümlü stokastik programlama ve şans kısıtları bulunmaktadır. Çeşitli yöntemler arasında, gürbüz optimizasyon, belirsizlik alanının bir kısmını veya tamamını kapsayan bir belirsizlik setine dayalı olarak parametre belirsizliğini ele almaktadır. Gürbüz optimizasyonun hedefi, belirsizlik setindeki parametrelerin herhangi bir gerçekleşmesi için geçerli kalan en iyi çözümü seçmektir. Optimizasyon problemlerindeki belirsizlikleri ele almak için diğer yöntemlerle karşılaştırıldığında, gürbüz optimizasyonun önemli avantajlarından biri hesaplanabilirliğidir. [Nemirovski, 2012] veri belirsizliğinin,

kısıtların yüksek olasılıkla karşılanması gerektiği durumlarda nasıl güvenilir ve hesaplanabilir yaklaşımlarla ele alınabileceğini açıklamaktadır.

Gürbüz optimizasyonun geniş bir dalı, en kötü durum optimizasyonuna odaklanır. Bu yaklaşımda, parametrelerin nominal değerlerinden maksimum sapmasını sınırlayan bir konveks belirsizlik kümesi üzerinde kısıtların alabileceği uç değerler hesaplanır. Amaç, optimal çözüm hakkında içgörüler sağlayan ve kısıt ihlalleri için olasılıksal garantiler sunan hesaplanabilir yeniden formülasyonlar geliştirmektir **[Gabrel vd., 2014]**. Gürbüz optimizasyona dair en erken çalışmalardan biri, verilerdeki basit sapmaları ele alarak ve çözümün tüm olası sapmalar altında geçerli olmasını sağlamak amacıyla orijinal doğrusal programlama problemini yeniden formüle **etmiştir [Soyster, 1973]**. Ancak, bu yaklaşım oldukça muhafazakâr olup, belirsizliğin tüm potansiyel gerçekleştirmeleri için geçerlilik sağlamaktadır.

[Ahuja vd., 2009] belirsizliği modellemek için sezgisel bir yöntem sunmuş ve bu yöntem, “hafif sağlamlık” (light robustness) olarak adlandırılan bir modelleme çerçevesine yol açmıştır. Bu çerçeve, gürbüz optimizasyonu, daha az koruyucu bir yaklaşım olan basitleştirilmiş stokastik programlama ile birleştirir ve yüksek esneklik ve kullanım kolaylığı sunar.

Bu çalışma kapsamında doğrusal tamsayılı bir gürbüz optimizasyon modeli formüle edilmiş ve çözülmüştür. Bununla beraber, belirtmemiz gerekir ki gürbüz optimizasyon doğrusal modellerle sınırlı değildir. Bu konuda yapılan çalışmalardan örnekler mevcut durumla ilgili fikir verecektir. **[Zhang, 2004]** nominal parametrelerin çevresinde geçerli ve birinci dereceye kadar sağlam olan doğrusal olmayan programlama problemleri için formülasyonlar sunmuştur. **[Teo, 2007]** konveks olmayan gürbüz optimizasyon problemleri için bir yöntem geliştirmiştir. Bu yöntem, iteratif olarak azalma yönleri boyunca ilerler ve gürbüz yerel çözüm ile sonlanır.

[Boni vd., 2008] belirsiz konik kuadratik kısıtlar içeren problemleri analiz ederek yaklaşık bir gürbüz karşılık formüle etmiştir. **[Hsiung vd., 2008]** doğrusal olmayan her bir kısıt için parça parça doğrusal konveks yaklaşımlar kullanarak, gürbüz geometrik programlama için hesaplanabilir yaklaşımlar sunmuştur. **[Ben-Tal vd. 1998]** Fenchel eşizlik (duality) kullanarak gürbüz doğrusal olmayan optimizasyon üzerine kapsamlı ve yapısal bir inceleme sunmuştur.





Gürbüz optimizasyon, yöneylem araştırması komünitesi dışında, süreç sistemleri mühendisliği araştırmacıları tarafından da çalışılmıştır. [Li & Ierapetrinou, 2008], belirsizlik altında süreç çizelgeleme problemine çeşitli gürbüz optimizasyon formülasyonlarının uygulanmasını incelemiştir. [Lin vd., 2004] ve [Janak vd., 2007] belirsizlik altındaki hem sınırlı hem de bilinen çeşitli olasılık dağılımlarıyla karışık tamsayılı doğrusal optimizasyon problemleri için gürbüz optimizasyonu çalışmıştır. [Verderame & Floudas, 2009], gürbüz optimizasyon çerçevesini operasyonel planlama problemlerine uygulamıştır. [Li vd., 2011], hem doğrusal optimizasyon hem de karışık tamsayılı doğrusal optimizasyon problemleri için küme tabanlı sağlam karşılık optimizasyonuna dair sistematik bir çalışma sunmuştur.

Belirsizlik kümesi tabanlı gürbüz optimizasyonda, belirsiz parametrelerin bir belirsizlik kümesi içinde değerler aldığı varsayılır. Amaç, bu belirsizliklere karşı “bağışık” olan, yani belirsiz verilerin tüm gerçekleştirmelerinde uygulanabilirliğini koruyan en iyi çözümü seçmektir. Belirsizlik kümeleri, problemdeki belirsizlik türüne uygun olarak farklı şekillerde tanımlanabilir.

Tablo 4.1'de, farklı belirsizlik kümeleri ve bunlara bağlı ayarlanabilir parametreler açıklanmıştır. Kutu (box) belirsizlik kümesi, belirsizlik vektörünün sonsuz normuyla sınırlıdır ve ayarlanabilir parametresi Ψ ile kontrol edilir. Elipsoidal belirsizlik kümesi, belirsizlik vektörünün l_2 -normunu kullanır ve Ω parametresi ile tanımlanır. Polihedral belirsizlik kümesi ise belirsizlik vektörünün l_1 -normuna dayanır ve Γ parametresi ile ifade edilir. Bu temel kümeler, çeşitli kombinasyonlarla birleştirilebilir. Örneğin, kutu+elipsoidal belirsizlik kümesi Ψ ve Ω parametreleriyle kutu ve elipsoid arasındaki kesişimi temsil ederken, kutu+polihedral belirsizlik kümesi Ψ ve Γ parametreleri ile tanımlanır. Kutu+elipsoidal+polihedral belirsizlik kümesi, üç kümenin kesişimi olarak tanımlanır ve Ψ , Ω ve Γ parametrelerini kullanır. Bu belirsizlik kümeleri, özellikle sınırlı ve sınırsız belirsizlik durumlarını modellemek için kullanılır ve her biri farklı uygulama alanlarına hitap eder.

Bu çalışmada, uçak bakım süreçlerinde belirsizliğin etkilerini analiz etmek ve karar destek mekanizmalarını güçlendirmek amacıyla gürbüz optimizasyon yaklaşımı uygulanmıştır. Özellikle, rutin olmayan bakım kartlarının adam-saat gereksinimlerindeki belirsizlikler, kutu belirsizlik seti çerçevesinde modellenmiştir. Bu yöntem, belirsizlikleri dikkate alarak optimize edilmiş bakım planlarının güvenilirliğini artırmayı hedeflemiştir.

Tablo 4.1: Belirsizlik Setinin Özeti [Li vd., 2011]

İllüstrasyon	Tür	Ayarlanabilir Parametre	Sınırlı Belirsizlik için Önerilen Aralık	Sınırsız Belirsizlik için Önerilen Aralık
	Box	Ψ	$\Psi \leq 1$	$\Psi < \infty$
	Ellipsoidal	Ω	$\Omega \leq \sqrt{ J_i }$	$\Omega < \infty$
	Polyhedral	Γ	$\Gamma \leq J_i $	$\Gamma < \infty$
	Interval+Ellipsoidal	Ω	$\Omega \leq \sqrt{ J_i }$	
	Box+Ellipsoidal	Ψ, Ω	$\Psi \leq 1, \Psi \leq \Omega \leq \Psi \sqrt{ J_i }$	
	Interval+Polyhedral	Γ	$\Gamma \leq J_i $	
	Box+Polyhedral	Ψ, Γ	$\Psi \leq 1, \Psi \leq \Gamma \leq \Psi J_i $	
	Interval+Ellipsoidal+Polyhedral	Ω, Γ	$\Omega \leq \sqrt{ J_i }, \Omega \leq \Gamma \leq \Omega \sqrt{ J_i }$	
	Box+Ellipsoidal+Polyhedral	Ψ, Ω, Γ	$\Psi \leq 1, \Psi \leq \Omega \leq \Psi \sqrt{ J_i }$ $\Omega \leq \Gamma \leq \Omega \sqrt{ J_i }$	

4.2. Model

Bu çalışmada, uçak bakım operasyonlarının planlanmasında toplam maliyeti minimize etmeyi hedefleyen bir matematiksel model geliştirilmiştir. Havacılık sektöründe bakım operasyonları, operasyonel süreklilik ve güvenlik açısından kritik bir role sahiptir. Ancak bu süreçler, karmaşık yapısı, belirsizlikler ve yüksek maliyetler nedeniyle etkili bir planlama gerektirir. Özellikle, bakım süreleri ve işgücü kullanımı gibi parametrelerdeki sapmalar, operasyonel verimliliği düşürmekte ve maliyetleri artırmaktadır. Bu nedenle, sistematik bir yaklaşımla karar süreçlerini desteklemek, zaman ve kaynak kaybını önlemek açısından büyük bir önem taşır.

Matematiksel modelleme, bu karmaşık sistemlerin yapısal olarak analiz edilmesi ve optimize edilmesi için güçlü bir araçtır. Bu çalışmada geliştirilen model, bakım

operasyonlarının hem zaman hem de maliyet boyutunu dikkate alarak kapsamlı bir çözüm sunmayı amaçlamaktadır.

4.2.1. Parametreler

Geliştirilen matematiksel model aşağıdaki parametrelere sahiptir.

- N: Uçak Sayısı
- M: Teknisyen Sayısı
- C_{hangar} : Günlük hangar maliyeti
- H: Hangar kapasitesi
- $C_{overtime}$: Fazla mesai birim maliyeti
- P: Bakım süresi geçince oluşan operatör ceza maliyeti
- T_{plan}^i : i. uçağın planlanan teslim zamanı
- S_i : i. uçağın bakım geliş zamanı
- CardCount: Bakım kartı sayısı
- Cards = {1, 2,...,CardCount}
- R_{ij} : i uçağındaki j. kart için gerekli çalışma süresi (adam-saat)
- T_{max} : Planlama periyodunun maksimum süresi
- Time = {0, ... , T_{max} } (Ayrıklaştırılmış zaman aralıkları kümesi)
- Aircraft = {1,...,N} (Bakımı planlanan uçakların kümesi)
- J = {(j,k) : j.kart k'nın öncülü} (Öncüllük ilişkileri kümesi)

4.2.2. Değişkenler

- $X_{ijt} = \begin{cases} 1, & \text{eğer } i. \text{ bakımın } j. \text{ kartı } t \text{ zamanında başlamışsa} \\ 0, & \text{aksi takdirde} \end{cases}$
- T_{actual}_i : Uçağın gerçekleşen bakım süresi
- $Penalty_i$: Ceza maliyeti ($t_{actual} > T_{plan}$ olursa ceza oluşur.)
- $Overtime_t$: t periyodundaki fazla mesai saati
- $Card_{start}_{ij}$: i. bakımın j. kartına başlama zamanı
- $Card_{end}_{ij}$: i. bakımın j. kartının bitiş zamanı
- $Maintenance_{start}_i$: i. bakıma başlama zamanı
- $Maintenance_{end}_i$: i. bakımdan çıkış zamanı

- Z_{ijt} : i. uçak için j. karta t anında atanan iş gücü
- Y_{ijt} : Hangar kapasitesini kontrol için ikili değişken

4.2.3. Matematiksel Model

Matematiksel modelin amaç fonksiyonu aşağıdaki gibi formüle edilmiştir.

$$\text{Minimize } z = \sum_{i \in \text{Aircraft}} [P * \text{Penalty}_i + C_{\text{hangar}} * (\text{Maintenance_end}_i - \text{Maintenance_start}_i)] + C_{\text{overtime}} * \sum_{t \in \text{Time}} \text{Overtime}_t$$

Amaç fonksiyonu, bakım operasyonlarının ekonomik verimliliğini sağlamak amacıyla üç temel maliyet unsurunu optimize etmektedir. Bakım işlemlerinin planlanan süreyi aşması durumunda, operasyonel aksaklıkları ve müşteri memnuniyetsizliğini yansıtan bir ceza maliyeti devreye girmektedir. Her bir uçak için ceza maliyeti, gerçekleşen bakım süresinin (T_{actual_i}) planlanan teslim süresini (T_{plan}^i) aşan kısmı ile ceza katsayısının (P) çarpılması ile hesaplanır. Bu terim, bakım süresinin etkin yönetimini teşvik eder.

$$\text{Ceza Maliyeti: } \sum_{i \in \text{Aircraft}} P * \text{Penalty}_i$$

Hangar maliyetleri, her bir uçak için bakım işlemleri boyunca hangarın kullanımına bağlı olarak hesaplanır. Her bir uçak için hangar kullanımı, bakımın başlangıç ve bitiş zamanları arasındaki süre farkına dayalıdır. Bu terim, hangar kapasitesinin etkin kullanımını sağlamak amacıyla modele dahil edilmiştir.

$$\text{Hangar Maliyeti: } \sum_{i \in \text{Aircraft}} C_{\text{hangar}} * (\text{Maintenance_end}_i - \text{Maintenance_start}_i)$$

Son olarak, fazla mesai maliyeti, iş gücünün planlanan çalışma süresinin ötesinde fazla mesai yapması durumunda oluşan maliyeti ifade eder. Zaman periyotları boyunca gerçekleşen toplam fazla mesai, iş gücünün sınırlı kapasitesini ve operasyonun verimliliğini modellemek için dikkate alınmıştır.

$$\text{Fazla Mesai Maliyeti: } C_{\text{overtime}} * \sum_{t \in \text{Time}} \text{Overtime}_t$$

Amaç fonksiyonu, yukarıdaki üç maliyet terimini bir araya getirerek toplam maliyeti minimize etmeyi hedeflemektedir. Model, ceza maliyetlerini azaltırken hangar kapasitesinin etkin kullanımını ve iş gücü planlamasını dengelemeyi amaçlamaktadır.

4.2.4. Kısıtlar

Modelin kısıtları, aşağıda verilerek açıklanmıştır.

- $\sum_{t \in Time} X_{ijt} = 1 \quad \forall i \in Aircraft, j \in Cards$

Her bir bakım kartının belirli bir zaman diliminde başlatılması gerekmektedir. Bu amaçla, her uçak (i) ve bakım kartı (j) kombinasyonu için toplamda yalnızca bir zaman diliminde başlama durumu sağlanmalıdır.

- $Card_start_{ij} = \sum_{t \in Time} t * X_{ijt} \quad \forall i \in Aircraft, j \in Cards$

Her bakım kartının başlangıç ve bitiş zamanları tanımlanmalıdır. Bu amaçla j kartının başlangıç zamanı, t zamanında kartın aktif olmasına göre belirlenir.

- $Card_end_{ij} = Card_start_{ij} + \sum_{t \in Time} Y_{ijt} \quad \forall i \in Aircraft, j \in Cards$

Kartın bitiş zamanı kartın başlangıç zamanı ile işlem süresinin toplamı olarak ifade edilmiştir.

- $\sum_{t \in Time} Z_{ijt} \geq R_{ij} \quad \forall i \in Aircraft, j \in Cards$

Her bakım kartı için belirlenen adam-saat gereksinimlerinin karşılanması kritik bir önceliktir. Her uçak (i) ve bakım kartı(j) için, toplam iş gücü ihtiyacının belirlenen asgari düzeyi sağlaması gerektiği anlamına gelir. Burada Z_{ijt} , i uçağı için j. bakım kartına, t zamanında gerçekleştirilen adam saat miktarını temsil eder. R_{ij} ise j. kart için gerekli minimum adam saat değerini ifade eder. Bu kısıt her bakım kartının operasyonel gereksinimlerini karşılayacak şekilde yeterli iş gücüyle desteklenmesini garanti eder.

- $Maintenance_end_i = \max_{j \in Cards} (Card_end_{ij})$
- $Maintenance_start_i = \min_{j \in Cards} (Card_start_{ij})$

Her uçak için bakım sürecinin bitiş zamanı, ilgili bakım kartlarının tamamlanma zamanlarının en büyük değeri ile temsil edilirken, başlangıç zamanı ise kartların en erken başlama zamanına eşit olacak şekilde belirlenmiştir.

- $T_{actual_i} \geq Maintenance_end_i - Maintenance_start_i, \forall i \in Aircraft$

Her uçağın (i) gerçekleşen bakım süresi (T_{actual}) başlangıç ve bitiş zamanları arasındaki farkı karşılamalıdır.

- $Maintenance_start_i \geq S_i \quad \forall i \in Aircraft$

Bakım başlangıç süresinin planlanan başlangıç zamanı ile uyumlu olması gerekmektedir.

- $Card_start_{ij} - t \leq T_{max} * (1 - Y_{ijt}) \quad \forall i \in Aircraft, j \in Cards$
- $t - Card_end_{ij} \leq T_{max} * (1 - Y_{ijt})$

Her bakım kartının işlem görmesi gereken süreler arasında uygun zamanlama yapılması gerekmektedir. Bu koşul belirli bir zaman diliminde (t), kartın başlangıç ve bitiş zamanları ile ilişkilendirilerek belirlenir. Y_{ijt} Değişkeni 1 olduğunda, t zamanının kartın başlama ve bitiş süreleri arasında kalacağını belirtir. Böylece belirli bir zaman diliminde kartın aktif olup olmadığına bağlı olarak zamanlama kontrol edilir.

- $Card_start_{i[j]} \geq Card_end_{i[k]} + 1 \quad \forall (j, k) \in J$

Modeldeki öncelik ilişkileri sayesinde, bakım kartlarının belirli bir sıralama düzenine uygun olarak gerçekleştirilmesi sağlanır. Böylece her kartın gerektirdiği öncelik sırasına göre başlatılması garanti edilir.

- $Penalty_i \geq Maintenance_end_i - T_{plan}^i$
- $Penalty_i \geq 0$

Planlanan bakım süresinin aşılması durumunda ceza maliyeti devreye girmektedir. Her bir uçak için (i) bakım süresinin aşıldığı durumda bir ceza uygulanacağını belirtir.

- $Y_{ijt} \geq X_{ijt} \quad \forall i \in Aircraft, j \in Cards, t \in Time$

Eğer i numaralı uçak için j kartı t zamanında başlatılmışsa ($X_{ijt} = 1$), aynı bakım kartının devam ediyor olması gerekmektedir.

- $Z_{ijt} \leq m \cdot 10 \cdot Y_{ijt} \quad \forall i \in Aircraft, j \in Cards, t \in Time$

Z_{ijt} , i numaralı uçak için j . bakım kartına t zamanında atanan toplam iş gücünü ifade eder. Y_{ijt} , ilgili bakım kartının t zamanında aktif olup olmadığını belirten ikili değişkendir. ($Y_{ijt} = 1$ ise aktif, $Y_{ijt} = 0$ ise aktif değil). Fazla mesai de dahil olmak üzere bir işçi en çok 10 saat çalışabileceğinden, $m \cdot 10$ maksimum iş gücü kapasitesini temsil eder. Eğer bakım kartı aktif değilse ($Y_{ijt} = 0$), iş gücü atanamaz ($Z_{ijt} = 0$). İş gücü atanmışsa ($Z_{ijt} \geq 0$), bu yalnızca bakım kartının aktif olduğu durumlarda ($Y_{ijt} = 1$) mümkündür.

- $\sum_{i \in Aircraft, j \in Cards} Y_{ijt} \leq H \quad \forall t \in Time$

Aktif bakımda olacak uçak sayısı hangar kapasitesinden daha yüksek olamaz.

- $\sum_{i \in Aircraft, j \in Cards} Z_{ijt} - m \cdot 7 \leq Overtime_t$

Belirli bir zamanda (t) iş gücü arzı ile fazla mesai toplamı, düzenli iş gücü kapasitesini aşabilir. Ancak bu artış, fazla mesai ile sınırlandırılmıştır. Z_{ijt} , t zamanında i numaralı uçak ve j . bakım kartına atanan toplam iş gücünü ifade eder. M , toplam çalışan sayısı olduğu ve bir işçi 7 saat normal mesai yaptığı için, $m \cdot 7$, bir vardiyada toplamda sağlanabilen düzenli iş gücü kapasitesi ifade eder.

- $Overtime_t \leq 3 \cdot m$

Fazla mesai, mümkün en büyük değerini aşamaz.

4.3. Gürbüz Formülasyon

Bu çalışmada, uçak bakımlarının gürbüz (robust) planlanması için kutu (box) belirsizlik yaklaşımı tercih edilmiştir. Bunun temel nedeni, bu yaklaşımın belirsizlikleri basit ve sezgisel bir şekilde modelleme yeteneğidir. Kutu yaklaşımı, belirsizliklerin her bir parametrede bağımsız olarak belirli bir aralıkta değişebileceğini


varsayar. Bu, uçak bakım süreçlerinde sıklıkla karşılaşılan ve öngörülmesi zor olan adam-saat sapmaları ve işgücü gereksinimi gibi belirsizliklerin modellenmesi için oldukça uygundur. Bu şekilde, bakım kartları üzerinden gelen rutin olmayan (non-routine) iş yüklerinin belirsizliklerini aralık olarak tanımlamak mümkün olmuştur.

Kutu belirsizlik kümesi, çözüm yönteminde fazla bir karmaşıklık yaratmadan belirsizlikleri kontrol etmeyi sağlaması ve uçak bakım planlamasında, hızlı ve pratik hesaplamaların önemli olması nedeniyle tercih edilmiştir. Bu yaklaşım, tüm belirsizlik aralığında geçerli bir çözüm sağlayarak, operasyonel risklerin minimize edilmesine yardımcı olmuştur.

4.4. Testler

4.4.1. Deney tasarımı

Deneyde uçak bakımlarındaki tüm süreç ele alınmayıp, gürbüz optimizasyon yaklaşımını test etmek için küçük bir örnek üzerinde çalışma yapılmıştır. Deney tasarımı içerisinde, üç dar gövdeli uçak ele alınarak tüm bakım toplam sekiz kart üzerinden değerlendirilmiştir. Bu kartlardan 6 tanesi rutin bakım kartlarından oluşurken, 2 kart ise kabini ve koltuğu detaylı muayene ettiren kartlar sonucu oluşan rutin olmayan bakım kartlarıdır. Söz konusu bakım kartları ve öncüllük ilişkileri Şekil 4.1’de verilmiştir. Deney senaryosunda belirlenen üç uçak, test verisinde uç değerlere sahip uçaklar olarak seçilmiştir. Bu üç uçak için uçağın tescil bilgisi, hangi bakım için tahmin yapılacağı, kaç günlük bir bakım olacağı bilgileri de modelde verilmiştir.



Şekil 4.1: Bakım kartlarının öncelik ilişkisi

Gürbüz formülasyonda hangi değerlerin kullanılacağı, farklı girdilerle elde edilen çözümler karşılaştırılarak değerlendirilmiştir. Hesaplamalar sırasında öncelikle uçakların gerçekleşen verileri kullanılmıştır. Test veri setinden seçilen üç uçağın gerçekleşmiş olan bakım süreçlerinde, en büyük rutin olmayan kartlara ait adam-saat değerleri incelenmiştir. 0.5 persentil, verinin alt yüzde 0,5'lik kısmını temsil eder. Eğitim veri setindeki ortalama veya buna çok yakın bir değer anlamına gelir. 0.9 Persentil Eğitim veri setindeki değerlerin alt yüzde 0,9'luk kısmını temsil eden, sınır değer anlamına gelen başka bir deyişle, veri setindeki en büyük değerlerden biridir. Ancak 0.5 persentile kıyasla biraz daha yukarıda bir değeri ifade eder. Üçüncü bir alternatif olarak, **Tablo 3.6** ve **Tablo 3.7'de** hesaplanan tahmin modellerinin verdiği çıktılarından seçilen bakımın en büyük değerleri alınarak gürbüz formülasyonda kullanılmıştır.

Oluşturulan gürbüz uçak bakım planlaması modeli, IBM ILOG CPLEX Optimization Studio 20.1.0 yardımıyla çözülmüştür.

4.4.2 Sonuçlar

Tablo 4.2, Tablo 4.3 ve Tablo 4.4'de test edilen üç senaryo için detaylar ve sonuçlar verilmiştir. Senaryo 1'de uçaklar normalden biraz daha fazla adam saate sahip uç bir örnek olarak seçilmiştir. 50 teknisyen ile $S = [2,3,6]$ ile bakıma gelmesi planlanan, $[11,9,20]$ TAT ile bakımda kalacaklarının tahmin edildiği $T_{max}=20$ planlama periyodunda hesaplamalar yapılmıştır. Senaryo 2'de Senaryo 1'deki uçaklar kullanılmış ama $T_{max}=25$ planlama periyodunda hesaplama yapılmıştır. Senaryo 3'de uçaklar beklenenden biraz daha az adam saate sahip uç bir örnek olarak seçilmiştir. 50 teknisyen ile $S = [2,3,6]$ ile bakıma gelmesi planlanan, $[8,10,15]$ TAT ile bakımda kalacaklarının tahmin edildiği $T_{max}=20$ planlama periyodunda hesaplanmıştır.

0.5 persentil ve 0.9 persentil değerleri, bakım kartlarındaki belirsizliklerin etkisini değerlendirmek için referans noktaları olarak kullanılmıştır. 0.5 persentil, daha büyük risk alma durumunu temsil ederken, 0.9 persentil daha muhafazakâr bir yaklaşımı ifade etmektedir. Gürbüz optimizasyon sonucunda farklı bakım başlangıç ve bitiş zamanlarıyla elde edilen çözümler, ceza maliyetleri (penalty) açısından karşılaştırılmıştır. Optimizasyon çözümlerinde ceza maliyetleri, bakım süresini aşan

durumlarda ($T_{actual_i} > T_{plan_i}$) ortaya çıkmış ve muhafazakâr çözümlerle minimize edilmiştir. Belirsizlikleri dikkate alarak optimize edilen çözümler, fazla mesai sürelerinde önemli farklılıklar yaratmıştır. Daha muhafazakâr çözüm yaklaşımı (ör. 0.9 persentil) genellikle daha yüksek fazla mesai süreleri ile sonuçlanırken, iyimser (ör. 0.5 persentil) yaklaşım gecikme maliyetine yol açabilmiştir.

Tablolardaki bulguları şu şekilde özetlemek mümkündür. Senaryo 1 sonuçlarına göre 0.5 persentil ile yapılan tahminlerde fazla mesai yapılmadığı, uçağın gerçekleşen verisine göre TAT olarak sapmanın olmadığı gözlenmiştir. 0.9 persentil ile yapılan tahminlerde teknisyenlerin yapmış olduğu fazla mesai artmakta, bakım bitişindeki sapmalardan sıfırlanmaktadır. Senaryo 1 için uçak bakımının gerçekleşen verisine en yakın tahmini hem bakım bitişi, hem ceza maliyeti hem de fazla mesai açısından, tezin ilk bölümünde hesapladığımız tahmin modellerinin en büyüğünü kullandığımız tahmin vermiştir. En büyük rutin olmayan kartlara ait adam-saat değerlerinde çözüm bulunamamıştır.

Senaryo 2 sonuçlarına göre Senaryo 1'in aksine 0.5 persentil ile yapılan tahminlerde çözüm bulunamamıştır. 0.9 persentil ile yapılan tahminlerle tezin ilk bölümünde hesapladığımız tahmin modellerinin en büyüğünü kullandığımız tahmin birbirine yakın sonuçlar vermiş ve gerçekleşene yakın sonuçlar elde edilmiştir. En büyük rutin olmayan kartlara ait adam-saat değerlerinde gerçekleşen durumla karşılaştırdığımızda bakım bitişlerinde sapma yaşanmazken, fazla mesai konusunda yüksek maliyetler oluşmuştur.

Senaryo 3 için en büyük rutin olmayan kartlara ait adam-saat değerlerinde çözüm bulunmamıştır. 0.5 persentil ile yapılan tahminler gerçekleşene en yakın durum olmuştur. 0.9 persentil ve tezin ilk bölümünde hesapladığımız tahmin modellerinin en büyüğü kullanılarak yapılan hesaplamalar yakın sonuçlar vermiş, 0.9 persentil kullanıldığında bakım sapmasız gerçekleşmiştir.

Gülbüz optimizasyonun farklı senaryolar için hesapladığı amaç fonksiyonu değerleri, belirsizliklere rağmen maliyet etkin bir planlama yapılabildiğini göstermektedir. En uygun çözümlerde, bakım başlangıç ve bitiş zamanları ile fazla mesai arasındaki denge optimize edilmiştir.

4.4.3. Değerlendirme

Gürbüz optimizasyon, bakım süreçlerinde belirsizliklerin etkisini dikkate alarak daha güvenilir ve etkin bir planlama sağlamıştır. Bu yöntem sayesinde, bakım süreçleri için daha gerçekçi ve uygulamaya uygun çözümler elde edilmiş, belirsizliklerin operasyonel maliyetler üzerindeki etkisi minimize edilmiştir. Belirsizlik kümesinin sınırlarını belirlemekle ilgili test edilen farklı yaklaşımlar (kötümser- muhafazakâr, iyimser, tahmin modellerine dayalı), belirsizliğin operasyonel sonuçlara etkisini inceleme fırsatı sunmuştur. İncelenen örnek planlama probleminde, tahmin modellerine dayalı gürbüz optimizasyon sonuçlarının belirsiz parametrelerin farklı gerçekleştirmelerini ifade eden üç test senaryosu için de uygun sonuçlar verdiği görülmüştür.

Tablo 4.2: 1. Senaryo Gürbüz Optimizasyon Deney Çıktısı

Uçak	Bakım Tipi	Bakım süresi	CAB	Gerçekleşen	En büyük	0.5 persentil	0.9 persentil	En büyük tahmin
TC-AAD	C3	9	1.UÇAK	575	1064	430	891	573
TC-AAE	C5	6	2.UÇAK	697	1019	267	614	488
TC-AAF	C6	14	3.UÇAK	1457	1182	445	917	693
			SEAT	Gerçekleşen	En büyük	0.5 persentil	0.9 persentil	En büyük tahmin
TC-AAD	C3	9	1.UÇAK	529	814	319	728	576
TC-AAE	C5	6	2.UÇAK	587	971	402	636	1520
TC-AAF	C6	14	3.UÇAK	735	1042	417	841	731
M=50 S=[2,3,6] T_plan=[11,9,20] T_max=20			Maintenance_start	[2 12 6]	Çözüm Bulunamadı	[2 6 10]	[2 12 7]	[2 6 11]
			Maintenance_end	[11 21 20]		[11 15 20]	[12 21 20]	[11 20 21]
			Objective	4,15E+05		1,41E+05	4,22E+05	4,18E+05
			Penalty	[0 12 0]		[0 6 0]	[1 12 0]	[0 5 0]
			Gerçekleşene göre penalty			[0 6 0]	[0 0 0]	[0 1 0]
			T_actual	[9 9 14]		[9 9 10]	[10 9 13]	[9 14 10]
			Card_start	[[2 2 5 4 6 4 8 10]		[2 2 4 4 5 4 8 10]	[2 2 4 5 5 9 11]	[2 2 4 4 5 8 10]
				[12 12 14 15 16 15 18 20]		[7 6 9 8 9 8 12 14]	[12 12 14 15 14 14 18 20]	[10 6 12 8 13 8 16 19]
				[6 8 8 10 9 12 16 19]]		[10 10 12 14 13 13 17 19]]	[7 7 9 10 11 11 15 19]]	[12 11 14 14 14 13 18 20]
			Card_ends	[[4 3 7 7 7 5 9 11]		[3 3 6 7 7 7 9 11]	[3 3 8 7 8 8 10 12]	[3 3 7 7 7 9 11]
				[13 13 17 17 17 17 19 21]		[8 7 11 11 11 9 13 15]	[13 13 17 17 17 17 19 21]	[11 7 15 13 14 11 18 20]
				[7 9 15 14 10 14 18 20]]		[11 12 16 16 15 16 18 20]]	[8 9 13 14 14 13 18 20]]	[13 12 17 16 17 17 19 21]
			Overtime	1682		0	1729	1683

Tablo 4.3: 2. Senaryo Gürbüz Optimizasyon Deney Çıktısı

Uçak	Bakım Tipi	Bakım Süresi	CAB	Gerçekleşen	En büyük	0.5 persentil	0.9 persentil	En büyük tahmin
TC-AAD	C3	9	1.UÇAK	575	1064	430	891	573
TC-AAE	C5	6	2.UÇAK	697	1019	267	614	488
TC-AAF	C6	14	3.UÇAK	1457	1182	445	917	693
			SEAT	Gerçekleşen	En büyük	0.5 persentil	0.9 persentil	En büyük tahmin
TC-AAD	C3	9	1.UÇAK	529	814	319	728	576
TC-AAE	C5	6	2.UÇAK	587	971	402	636	1520
TC-AAF	C6	14	3.UÇAK	735	1042	417	841	731
M=50 S=[2,3,6] T_plan=11,9,20] T_max=25			Maintenance_start	[2 7 12]	[2 7 13]	Çözüm Bulunamadı	[2 8 14]	[2 7 15]
			Maintenance_end	[12 18 26]	[12 18 26]		[14 19 26]	[12 20 26]
			Objective	1,87E+05	4,08E+05		1,94E+05	1,82E+05
			Penalty	[1 9 6]	[1 9 6]		[3 10 6]	[1 11 6]
			Gerçekleşene göre penalty		[0 0 0]		[0 0 0]	[0 0 0]
			T_actual	[10 11 14]	[10 11 13]		[12 11 12]	[10 13 11]
			Card_start	[2 2 6 4 4 4 9 11]	[2 2 5 4 4 4 9 11]		[[2 2 4 4 4 4 11 13]	[2 2 4 4 5 4 9 11]
				[8 7 10 9 10 9 15 17]	[7 9 10 11 9 12 15 17]		[8 9 10 13 10 11 16 18]	[7 8 9 11 10 12 17 19]
				[12 14 15 16 14 16 23 25]]	[14 13 17 15 18 18 23 25]]		[14 14 19 16 16 16 23 25]]	[15 15 18 17 19 20 23 25]]
			Card_ends	[3 3 8 8 7 7 10 12]	[3 3 8 7 8 8 10 12]		[[3 3 10 7 8 7 12 14]	[3 3 8 7 8 8 10 12]
				[9 8 14 11 14 13 16 18]	[8 10 14 14 13 14 16 18]		[9 10 15 15 13 15 17 19]	[8 10 16 16 14 16 18 20]
				[13 15 22 22 22 22 24 26]]	[16 14 20 21 22 22 24 26]]		[15 15 22 19 22 22 24 26]]	[17 16 22 22 22 22 24 26]]
			Overtime	57	1564		99	53

Tablo 4.4: 3. Senaryo Gürbüz Optimizasyon Deney Çıktısı

Uçak	Bakım Tipi	Bakım Süresi	CAB	Gerçekleşen	En büyük	0.5 persentil	0.9 persentil	En büyük tahmin
TC-AAA	C3	6	1.UÇAK	362	1064	430	891	573
TC-AAB	C5	7	2.UÇAK	230	1019	267	614	488
TC-AAC	C6	9	3.UÇAK	338	1182	445	917	693
			SEAT	Gerçekleşen	En büyük	0.5 persentil	0.9 persentil	En büyük tahmin
TC-AAA	C3	6	1.UÇAK	248	814	319	728	576
TC-AAB	C5	7	2.UÇAK	315	971	402	636	1520
TC-AAC	C6	9	3.UÇAK	250	1042	417	841	731
M=50 S=[2,3,6] T_plan=[8,10,15] T_max20			Maintenance_start	[2 10 6]	Çözüm Bulunamadı	[2 6 10]	[2 12 7]	[2 6 11]
			Maintenance_end	[11 19 15]		[11 15 20]	[12 21 20]	[11 20 21]
			Objective	1,37E+05		1,43E+05	4,23E+05	4,21E+05
			Penalty	[3 9 0]		[3 5 5]	[4 11 5]	[3 10 6]
			Gerçekleşene göre penalty			[0 4 0]	[0 0 0]	[0 0 0]
			T_actual	[9 9 9]		[9 9 10]	[10 9 13]	[9 14 10]
			Card_start	[2 2 4 4 4 4 8 10]		[3 2 5 4 5 4 8 10]	[2 2 4 4 4 4 9 11]	[2 2 5 4 4 4 8 10]
				[10 10 14 13 12 13 16 18]		[6 6 9 9 8 10 12 14]	[12 12 14 14 14 14 18 20]	[6 8 9 10 8 12 16 19]
				[7 6 9 8 9 8 12 14]]		[10 12 12 14 14 14 17 19]	[7 7 9 9 11 10 16 19]	[11 11 13 14 13 15 18 20]
			Card_ends	[3 3 6 7 7 7 9 11]		[4 3 7 6 7 7 9 11]	[3 3 8 8 8 6 10 12]	[3 3 7 6 6 7 9 11]
				[11 12 15 15 15 15 17 19]		[7 8 11 11 10 11 13 15]	[13 13 17 16 16 17 19 21]	[7 9 11 14 11 13 18 20]
				[8 7 11 11 11 9 13 15]]		[11 13 15 16 16 16 18 20]]	[8 8 15 12 13 11 18 20]	[12 12 17 17 17 17 19 21]
			Overtime	0	0	0	1729	1683

5. SONUÇ VE DEĞERLENDİRMELER

Havacılık sektörü, hızlı teknolojik gelişimlere ayak uydurmak, ulusal ve uluslararası ölçekte geniş hizmet ağı oluşturmak ve yüksek performans gerektiren bir çalışma sistemi geliştirmek zorundadır. Bu kapsamda, uçak bakım süreçlerinin etkin ve verimli bir şekilde planlanması, operasyonel etkinliği artırmak ve maliyetleri optimize etmek açısından kritik bir öneme sahiptir.

Bu tez çalışmasında, uçak bakım süreçlerinin mevcut sistematiğine alternatif ve matematiksel tekniklere dayalı yeni bir yaklaşım sunulmuş; uçak bakım süreçlerinde karşılaşılan belirsizlikleri ele almak için iki aşamalı bir model önerilmiştir.

1. Tahmin Modeli: Bakım sürelerindeki belirsizliğin kaynağı olan, rutin olmayan işlerden kaynaklanan adam-saat gereksinimlerini tahmin etmek üzere makine öğrenmesi tekniklerine dayalı modeller oluşturulmuştur. Bu yolla, daha başarılı tahminlerin elde edilmesi amaçlanmıştır.
2. Gürbüz Optimizasyon: Belirsizlik içeren bakım planlama problemi, gürbüz matematiksel optimizasyon problemi olarak modellenerek bakım planlaması yapılmıştır. Bu optimizasyon modeli, bakım faaliyetlerinin çizelgelemesi ve kaynak kullanımını belirsizlik içeren bakım sürelerinin verilen bir belirsizlik kümesi içerisindeki tüm değerleri için optimize etmektedir. Belirsizlik kümesinin belirlenmesinde tahmin modellerinden elde edilen verilerin kullanılması fikri de denenmiştir.

Bu bağlamda, çalışmanın ilk bölümünde, bakım kartlarından türeyen rutin olmayan işlerin adam-saat gereksinimlerini tahmin etmeye yönelik modeller oluşturan çeşitli yöntemler test edilmiş ve bu tahminlerin gerçekleşen değerlerle karşılaştırması sunulmuştur. Bu bölümde, test verisi üzerinde güvenilir tahminler veren bir tahmin modeli elde edilememiştir. Bunun bir sebebi, problemin doğası itibarıyla tahmin modelinin tespit edilebilir ve sayısallaştırılabilir faktörlerinin yetersiz oluşu olabilir. Diğer bir sebebi ise, çalışmada kullanılan verilerle ilgili aşağıda açıklanan problemlerdir.

- **Hatalı AdamxSaat Girişleri:** Verilerin doğru kaydedilmemesi sonucunda tahminlerde ciddi sapmalar meydana gelmektedir.

- **Rutin Olmayan İşlemlerde Çeşitlilik:** Aynı kart için farklı uygulamalar yapılması, tahminlerde standart bir eğilim oluşturmayı zorlaştırmaktadır.
- **Rutin İşlemlere Yanlış Atıflar:** Rutin olmayan işlem sürelerinin rutin kartlara kaydedilmesi veya kaydedilmemesi veri hatalarına neden olmaktadır.
- **Kirli Veriler:** Geçmiş verilere dayalı yapılan tahminlerde, kart bazında değil paket bazında veri olması, doğruluğu düşürmektedir. Uçak bakım firmalarının kullanmış oldukları uçak bakım sistemlerinde yapılan değişiklikler geçmiş verilerde bozulmalara sebep olabildiği gözlenmiştir.
- **Kartların Çakışması:** Aynı bölgede işlem yaptıran farklı kartların etkisiyle süreç karmaşıklaşmaktadır. Bu çakışma kartların zamanında uygulanamaması, bazı durumlarda zaman baskısı oluşması ve hatalı işlemlere, veri kayıtlarına sebep olabilmektedir.
- **Üçüncü Taraf Etkileri:** Uçak bakım operatörünün sahip olduğu uçak bakım firmasının bakım yaptığı uçaklarda kendi filosu dışındaki müşterilere ait uçakların farklı yaş, bakım sıklığı ve çevresel koşulları nedeniyle ortaya çıkan çeşitlilik, planlama doğruluğunu zorlaştırmaktadır.

Geliştirilen gürbüz planlama yaklaşımı, hem belirsizliklerin etkisini en aza indirmiş hem de operasyonel etkinliği artırarak bakım maliyetleri ve sürelerinde iyileştirmeler sağlamıştır. Örneğin, bakım kartlarının başlangıç ve bitiş zamanlarının optimize edilmesi, hangar ve iş gücü kullanımında verimlilik artışı sağlamıştır. Teslimat gecikmeleri ve toplam maliyetlerin minimize edildiği gözlemlenmiştir.

Bu bulgular, uçak bakım süreçlerinde veri kalitesinin artırılması ile tahmin doğruluğunun artacağını, maliyetleri ve kaynakları daha etkin planlamanın mümkün olacağını göstermiştir. Diğer yandan, gürbüz planlama yaklaşımının, belirsizlik altında etkin planlama yapabilmek için güçlü bir araç olduğu gösterilmiştir.

Gelecekteki çalışmalar için, bu tezde önerilen modelin geliştirilmesi ve genişletilmesi adına birkaç potansiyel araştırma alanı bulunmaktadır. İlk olarak, veri kalitesinin artırılmasına yönelik çalışmalara odaklanılabilir. Daha temiz ve doğru bir veri seti oluşturulması, tahmin modellerinin doğruluğunu artırabilir. Teknisyenlerin adam saat açma süreçlerinde yapılacak iyileşmeler bu sürecin yönetiminde yardımcı olabilir. İkinci olarak, tahmin modellerine daha karmaşık makine öğrenmesi algoritmaları, derin öğrenme yöntemleri veya hibrit modeller dahil edilerek, tahmin performansı iyileştirilmesi denenebilir. Ayrıca, belirsizlik setlerinin daha esnek ve dinamik bir

şekilde tanımlanması için veri odaklı yaklaşımlar kullanılabilir. Bunun yanı sıra, geliştirilen gürbüz optimizasyon modeli farklı bakım senaryolarında ve daha geniş bir bakım ağı için test edilebilir ve modelin uygulanabilirliği artırılabilir. Önerilen yaklaşımın genişletilmesi üzerine yapılacak çalışmalar hem endüstriyel hem de akademik anlamda uçak bakım süreçlerinin verimliliğini artırmak için önemli katkılar sunacaktır.



KAYNAKLAR

- Ahmadi, A. (2010), "Aircraft scheduled maintenance programme development: Decision support methodologies and tools" Division of Operation and Maintenance Engineering, Luleå University of Technology.
- Ahuja, R. K., Möhring, R. H., & Zaroliagis, C. D. (Ed.). (2009), "Robust and Online Large-Scale Optimization: Models and Techniques for Transportation Systems" (C. 5868). Springer Berlin Heidelberg.
- Akinsola, F. A., & Odhiambo, N. M. (2017), "Inflation and Economic Growth" A Review of The International Literature. Comparative Economic Research. Central and Eastern Europe, 20(3), 41-56.
- Ben-Tal, A., Melenberg, B., & Rennen, G. (2011), "Robust Solutions Of Optimization Problems Affected By Uncertain Probabilities".
- Biau, G., & Cadre, B. (2017), "Optimization by gradient boosting" (No. arXiv:1707.05023). arXiv.
- Boni, O., Ben-Tal, A., & Nemirovski, A. (2008), "Robust solutions to conic quadratic problems and their applications" Optimization and Engineering, 9(1), 1-18.
- Bousquet, O., Luxburg, U. von, & Rätsch, G. (2004) "Advanced Lectures on Machine Learning", ML Summer Schools 2003, Canberra, Australia, February 2-14, 2003, Tübingen, Germany, August 4-16, 2003, Revised Lectures. Springer Berlin Heidelberg.
- Breiman, L. (2001), "Random forests, Machine learning", 45(1), 5-32
- Camo, U. (2023), "User Guide for Aircraft Maintenance Programmes (AMP) approvals".
- Cros, G. (2022), "Airline Maintenance Cost Executive Commentary".
- EASA. (2021), "AMP2 Aircraft Maintenance Programme".
- Gabrel, V., Murat, C., & Thiele, A. (2014), "Recent advances in robust optimization: An overview". European Journal of Operational Research, 235(3), 471-483.
- Gopalan, R. (1996), "The Aircraft Maintenance Routing Problem".
- Hastie, T., Tibshirani, R., & Friedman, J. (2009), "The elements of statistical learning: data mining, inference, and prediction", Springer Science & Business Media.
- Hill, T.; Lewicki, (2007), "Methods and Applications" (StatSoft, Inc., Tulsa,).
- Hsiung, K.-L., Kim, S.-J., & Boyd, S. (2008), "Tractable approximate robust geometric programming. Optimization and Engineering", 9(2), 95-118.

Janak, S. L., Lin, X., & Floudas, C. A. (2007), “A new robust optimization approach for scheduling under uncertainty”, *Computers & Chemical Engineering*, 31(3), 171-195.

Kazan, H., & Tavsamaz, A. (2014), “Havacılıkta üreyen rutin olmayan (non- routine) işlerin adam x saat tahmini: gerçek zamanlı bakım kartlarında uygulama”, *Alphanumeric Journal*.

Kishino, M., Matsumoto, K., Kobayashi, Y., Taguchi, R., Akamatsu, N., & Shishido, A. (2023), “Fatigue life prediction of bending polymer films using random forest”. *International Journal of Fatigue*, 166, 107230.

Küçükyavuz, S., & Noyan, N. (2010), “Stochastic Programming and Robust Optimization Approaches for Aircraft Maintenance Scheduling”, *Computers & Industrial Engineering*, 60(1), 126-134.

Liaw, A., & Wiener, M. (2002), “Classification and regression by randomForest”, *R news*, 2(3), 18-22.

Li, Z., Ding, R., & Floudas, C. A. (2011), “A Comparative Theoretical and Computational Study on Robust Counterpart Optimization”: I. Robust Linear Optimization and Robust Mixed Integer Linear Optimization. *Industrial & Engineering Chemistry Research*, 50(18), 10567-10603.

Li, Z., & Ierapetritou, M. G. (2008), “Robust Optimization for Process Scheduling Under Uncertainty”, *Industrial & Engineering Chemistry Research*, 47(12), 4148-4157.

Lin, X., Janak, S. L., & Floudas, C. A. (2004), “A new robust optimization approach for scheduling under uncertainty”, *Computers & Chemical Engineering*, 28(6-7), 1069-1085.

Mitchell, T. M., & Mitchell, T. M. (1997), “Machine learning”, (Vol. 1, No. 9). New York: McGraw-hill.

Mulvey, J. M., Vanderbei, R. J., & Zenios, S. A. (1995), “Robust Optimization of Large-Scale Systems”, *Operations Research*, 43(2), 264-281.

Murphy, K. P. (2022), “Probabilistic Machine Learning: An Introduction”, MIT Press.

Nemirovski, A. (2012), “On safe tractable approximations of chance constraints”, *European Journal of Operational Research*, 219(3), 707-718.

Pelt, M., Stamoulis, K., & Apostolidis, A. (2019), “Data analytics case studies in the maintenance, repair and overhaul (MRO) industry”, *MATEC Web of Conferences*, 304, 04005.

Pintelon, L., & Parodi-Herz, A. (2008), *Maintenance: An Evolutionary Perspective. İçinde Complex System Maintenance Handbook* (ss. 21-48). Springer London.

Samaranayake, P., & Kiridena, S. (2012), "Aircraft maintenance planning and scheduling", An integrated framework. *Journal of Quality in Maintenance Engineering*, 18(4), 432-453.

Soyster, A. L. (1973), "Technical Note—Convex Programming with Set-Inclusive Constraints and Applications to Inexact Linear Programming", *Operations Research*, 21(5), 1154-1157.

Teo, K. M. (2007), "Nonconvex Robust Optimization".

Xia, W., Zhang, Z., & Yang, X. (2017), "Machine Learning in Aircraft Maintenance Planning: Predictive and Prescriptive Approaches", *Computers & Industrial Engineering*, 112, 97-107.

Verderame, P. M., & Floudas, C. A. (2009), "Operational Planning of Large-Scale Industrial Batch Plants under Demand Due Date and Amount Uncertainty", I. Robust Optimization Framework. *Industrial & Engineering Chemistry Research*, 48(15), 7214-7231.

Wittelman, M., Deng, Q., & Santos, B. F. (2021), "A bin packing approach to solve the aircraft maintenance task allocation problem", *European Journal of Operational Research*, 294(1), 365-376.

Zhang, Y. (2005), "A General Robust-Optimization Formulation for Nonlinear Programming".

Zhu, T., Ran, Y., Zhou, X., & Wen, Y. (2024), "A Survey of Predictive Maintenance: Systems, Purposes and Approaches" (No. arXiv:1912.07383).

Zorgdrager, M., Verhagen, W. J. C., & Curran, R. (2014), "An evaluation of forecasting methods for aircraft non-routine maintenance material demand", *International Journal of Agile Systems and Management*, 7(3/4), 383.

ÖZGEÇMİŞ

Mehmet İkbâl KARACA, lise eğitimini Sivas Cumhuriyet Anadolu Lisesi'nde tamamladı. (2010-2014). Yıldız Teknik Üniversitesi'nde Endüstri Mühendisliği bölümünde lisans eğitimini bitirdi (2015-2020). Şu anda Gebze Teknik Üniversitesi'nde Endüstri Mühendisliği alanında yüksek lisans yapmaktadır. (2022-2025).

2019 yılında Baykar Makine bünyesinde Üretim Planlama ve Kontrol biriminde staj yaptıktan sonra, yine aynı yıl Türk Hava Yolları Teknik AŞ'de Part time öğrenci olarak kariyerine başlamıştır. 2019 yılından itibaren Türk Hava Yolları Teknik AŞ'de Kabin içi Bakım Planlama Müdürlüğü'nde planlama ve iş geliştirme mühendisi olarak görevini yürütmektedir



TEZ METNİNDEN TÜRETİLEN YAYINLAR/SUNUMLAR

Karaca M., (2024), “Uçak Bakımlarında Rutin Olmayan İş Yükünün Tahmini Üzerine DeneySEL bir Çalışma”, 6. Uluslararası Veri Bilimi ve Uygulamaları Konferansı (ICONDATA’24), 78-80, Priştina, Kosova, 2-6 Eylül

