

**T.C.
MANİSA CELAL BAYAR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**YÜKSEK LİSANS TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI
ENDÜSTRİ MÜHENDİSLİĞİ PROGRAMI**

**HAVACILIK SEKTÖRÜNDE BİR TALEP TAHMİNİ VE
FİLO ATAMA ÇALIŞMASI**

Gizem KAYRAN

**Danışman
Dr. Öğr. Üyesi Özlem UZUN ARAZ**

MANİSA-2024

**GİZEM
KAYRAN**

**HAVACILIK SEKTÖRÜNDE BİR TALEP TAHMİNİ
VE FİLO ATAMA ÇALIŞMASI**

2024

TAAHHÜTNAME

Bu tezin Manisa Celal Bayar Üniversitesi Lisansüstü Eğitim Enstitüsü Endüstri Mühendisliği Ana Bilim Dalında akademik ve etik kurallara uygun olarak yazıldığını ve kullanılan tüm literatür bilgilerinin referans gösterilerek tezde yer aldığını, tamamen kendi çalışmam olduğunu, her alıntıya kaynak gösterdiğimi, tezin yazımında akademik ve etik kurallara aykırı herhangi bir yapay zekâ ve program kullanmadığımı beyan ederim.

Gizem KAYRAN



ÖZET

Yüksek Lisans Tezi

Havacılık Sektöründe Bir Talep Tahmini ve Filo Atama Çalışması

Gizem KAYRAN

Manisa Celal Bayar Üniversitesi
Lisansüstü Eğitim Enstitüsü
Endüstri Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Özlem UZUN ARAZ

Küresel hava yolu endüstrisinin dünya ekonomisinde büyük bir önemi bulunmakta, her yıl milyonlarca insanın hayatında belirleyici bir rol oynamaktadır. Havacılık sektörü turizm ve sanayi sektörleriyle yoğun olarak iş birliği içinde olması sebebiyle diğer sektörlerle kıyasla ekonomik değişimlerden ve uluslararası gelişmelerden daha kolay etkilenmektedir. 2020 yılında küresel salgın olarak ilan edilen Koronavirüs Hastalığı, önceki krizleri ardında bırakarak havacılık endüstrisine büyük bir şok yaşatmıştır. Ülke bazında uygulanan seyahat kısıtlamaları ve yolcu talebindeki benzeri görülmemiş düşüş, çoğu hava yolu şirketinin faaliyetlerini durdurmaya yol açmış, bazı hava yolu şirketlerini ise iflas noktasına sürüklemiştir. Sektör hızla toparlanmaktadır ancak henüz 2019 yılı seviyelerine dönülemediği. Böyle hassas bir endüstride olası bir kriz dönemi ve kriz dönemi sonrası toparlanma sürecinin iyi bir planlama süreci ile yürütülmesi gerektiği ortadadır.

Bu tez çalışması ile kriz dönemi ve kriz dönemi sonrası hava yolu operasyonlarının planlanması için hava yolu yöneticilerine yardımcı olacak bir karar destek sisteminin oluşturulması amaçlanmıştır. Önerilen karar destek sisteminde hava yolu planlama süreçlerinin tüm adımlarında yer alan ve süreci belirleyen yolcu sayılarının tahmin edilmesi ve tahminlenen döneme göre filo atama probleminin çözülmesi amaçlanmıştır. Bu doğrultuda Uzun Kısa Süreli Bellek (LSTM) ve Box-Jenkins yöntemi olan SARIMA modeli ile yolcu sayıları tahmin edilmiştir. Kullanılan veri setinde daha iyi performans gösteren Box-Jenkins yöntemi ile örneklem dışı öngörü yapılmıştır. Ardından, elde edilen öngörüler girdi olarak kullanılarak günlük hava yolu kazancını enbüyükleyen filo ataması matematiksel modeli geliştirilmiştir. Modelleme sonucunda haftalık uçuş-filo çizelgeleri ve hava yolu kazancı elde edilmiştir. İncelenen uçuş firmasının analiz periyodu boyunca yaptığı gerçek filo atama sonuçları ile önerilen karar destek sisteminden elde edilen filo atama sonuçları kazanç kriteri açısından karşılaştırılmıştır. Yapılan analizler sonucunda, önerilen karar destek sisteminin yolcu sayısı tahminlemede ve filo ataması problemini çözümünde etkin olduğu ortaya konulmuştur.

Anahtar Kelimeler: Yapay Sinir Ağları, Box-Jenkins Yöntemi, Zaman Serisi Analizi, Talep Tahmini, Filo Atama, Matematiksel Modelleme, Karar Destek Sistemi

2024, 171 sayfa

ABSTRACT

M.Sc. Thesis

A Demand Forecasting and Fleet Assignment Study in the Aviation Industry

Gizem KAYRAN

**Manisa Celal Bayar University
Graduate School of Education
Department of Industrial Engineering**

Supervisor: Assist. Prof. Dr. Özlem UZUN ARAZ

The global airline industry has a great significance in the world economy and plays a crucial role in the lives of millions of people every year. The aviation industry is more easily affected by economic changes and international developments compared to other sectors due to its intense cooperation with the tourism and industrial industries. Announced in 2020 as a global pandemic, the Coronavirus Disease has left the previous crisis behind and caused a great shock to the aviation industry. The travel restrictions applied on a country basis and the unprecedented decline in passenger demand have caused many airlines to stop their operations and forced some airlines to the bankruptcy level. The industry is recovering rapidly but has not yet returned to 2019 levels. In such a sensitive industry, it is obvious that a potential crisis period and the post-crisis recovery period should be carried with a good planning process.

The aim of this thesis is to create a decision support system to assist airline managers in planning airline operations during and after the crisis period. In the proposed decision support system, it is aimed to forecast the number of passengers, which is involved in all steps of airline planning processes and determines the process, and to solve the fleet assignment problem according to the forecasted period. In this regard, Long Short-Term Memory (LSTM) and Box-Jenkins method of SARIMA model were used to forecast the number of passengers. Out-of-sample forecasting was performed with the Box-Jenkins method, which performs better in the data set used. Then, a fleet assignment mathematical model that maximizes the daily airline profit was developed by using the obtained predictions as input. As a result of the modelling, weekly flight-fleet schedules and airline earnings were obtained. The actual fleet assignment results of the flight company during the analysis period and the fleet assignment results obtained from the proposed decision support system are compared in terms of the profit criterion. The analyses revealed that the proposed decision support system is efficient in forecasting the number of passengers and solving the fleet assignment problem.

Keywords: Artificial Neural Networks, Box-Jenkins Method, Time Series Analysis, Demand Forecasting, Fleet Assignment, Mathematical Modelling, Decision Support System

2024, 171 pages

TEŞEKKÜR

Lisansüstü eğitimim boyunca değerli bilgilerini benden esirgemeyen, yol gösteren ve her konuda yardımcı olan kıymetli danışmanım Dr. Öğr. Üyesi Özlem UZUN ARAZ'a sonsuz teşekkür ederim.

Ayrıca tezimin gelişmesinde maddi destek sağlayan Bilim İnsanı Destek Programları Başkanlığı'na (BİDEB) ve 2210-A Genel Yurt İçi Yüksek Lisans Burs Programı'na, başta bölüm başkanımız Doç. Dr. Mehmet Ali ILGIN olmak üzere bölümdeki tüm hocalarıma, her daim yanımda olan sevgili eşime ve aileme destekleri için teşekkürlerimi sunarım.

Gizem KAYRAN
Manisa, 2024



SİMGELER VE KISALTMALAR DİZİNİ

AIC	Akaike Bilgi Kriteri
AKK	Arz Edilen Koltuk Kilometre
AKKBG	Arz Edilen Koltuk Kilometre Başına Gider
AR	Otoregresif
ARIMA	Otoregresif Entegre Hareketli Ortalama
ARMA	Otoregresif Hareketli Ortalamalar
COVID-19	Koronavirüs Hastalığı
GSYİH	Gayrisafi Yurt İçi Hasıla
HEE	Haftalık Ekonomik Endeks
IATA	Uluslararası Hava Taşımacılığı Birliği
LSTM	Uzun Kısa Süreli Bellek
MA	Hareketli Ortalamalar
MAE	Ortalama Mutlak Hata
MAPE	Ortalama Mutlak Yüzde Hata
RMSE	Kök Ortalama Hata Kare
SARS	Şiddetli Akut Solunum Sendromu
SGP	Satın Alma Gücü Paritesi
ÜYK	Ücretli Yolcu Kilometre
ÜYKBG	Ücretli Yolcu Kilometre Birim Gelir

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1. 2015-2023 yılları arası yolcu ve kargo gelirleri [5].....	2
Şekil 1.2. 2000-2023 yılları arası faaliyet marjı ve net kar [5].....	3
Şekil 2.1. Yıllara göre hava yolu gelir payı dağılımı [8].....	7
Şekil 2.2 2008-2007 yılları kıtalara göre net kar miktarları [22].....	14
Şekil 2.3 1945-2020 yılları arası taşınan yolcu sayısı [25].....	16
Şekil 2.4. Hava yollarında operasyonel planlama ve çizelgeleme süreci [26].....	17
Şekil 4.1 Kantitatif tahmin yöntemlerinin sınıflandırılması [55].....	37
Şekil 4.2. Zaman serisi bileşenleri [69]	39
Şekil 4.3. Box-Jenkins metodunun akış şeması [74]	44
Şekil 4.4. Durağan olmayan zaman serisi grafiği	45
Şekil 4.5. Yapay nöronun yapısı [75]	51
Şekil 4.6. Basamak fonksiyonunun grafiği [77]	52
Şekil 4.7. Doğrusal fonksiyonunun grafiği [77]	53
Şekil 4.8. Sigmoid fonksiyonunun grafiği [77]	54
Şekil 4.9. Tanh fonksiyonunun grafiği [77].....	54
Şekil 4.10. ReLU fonksiyonunun grafiği [77]	55
Şekil 4.11. Sızıntı ReLU fonksiyonunun grafiği [77].....	56
Şekil 4.12. Tek katmanlı ileri beslemeli yapay sinir ağı modeli [75].....	58
Şekil 4.13. Çok katmanlı ileri beslemeli yapay sinir ağı modeli [75]	59
Şekil 4.14. Geri beslemeli yapay sinir ağı modeli [75].....	60
Şekil 4.15. Yinelenebilir sinir ağı modeli [80]	61
Şekil 4.16. LSTM ağının hücre yapısı ve genişleme diyagramı [79]	62
Şekil 5.1. Uygulamanın kavramsal çerçevesi	66
Şekil 5.2. 01.07.2020 - 31.05.2023 tarihleri arası günlük yolcu sayıları	72
Şekil 5.3. Veri setinin kutu grafiği ve histogram grafiği	73
Şekil 5.4. LSTM Pseudocode	75
Şekil 5.5. Birinci analizin LSTM tahmin grafiği	79
Şekil 5.6. İkinci analizin LSTM tahmin grafiği.....	84
Şekil 5.7. Üçüncü veri setinin LSTM tahmin grafiği	88
Şekil 5.8. Box-Jenkins Pseudocode	89
Şekil 5.9. Zaman serisinin ACF grafiği	90
Şekil 5.10. Zaman serisinin PACF grafiği.....	91
Şekil 5.11. Birinci derece farkı alınan zaman serisinin ACF grafiği.....	92
Şekil 5.12. Birinci derece farkı alınan zaman serisinin PACF grafiği.....	92
Şekil 5.13. Mevsimsel birinci derece farkı alınan zaman serisinin ACF grafiği.....	93
Şekil 5.14. Mevsimsel birinci derece farkı alınan zaman serisinin PACF grafiği.....	94
Şekil 5.15. SARIMA(2,1,2)(0,1,1) ₇ modelinin teşhis grafikleri.....	96
Şekil 5.16. Birinci veri setinin SARIMA tahmin grafiği.....	97
Şekil 5.17. İkinci veri setinin SARIMA tahmin grafiği.....	98
Şekil 5.18. Üçüncü veri setinin SARIMA tahmin grafiği.....	99
Şekil 5.19. Sabiha Gökçen Havalimanı uçuş noktaları.....	101
Şekil 5.20. 01.06.2023 ve 07.06.2023 tarih aralığındaki yolcu sayısı tahminleri....	105
Şekil 5.21. PC 2212 uçuş koduna ait geçmiş filo atamaları	112
Şekil 5.22. Günlük kazanç değerlerinin karşılaştırması.....	113

TABLÖLAR DİZİNİ

	Sayfa
Tablo 3.1. Havacılık sektöründe talep tahmini literatür taraması	25
Tablo 3.2. COVID-19 ve havacılık literatür taraması	30
Tablo 3.3. Filo atama problemi literatür taraması	33
Tablo 4.1. AR, MA ve ARMA sürecine ilişkin otokorelasyon yapısı [70].....	47
Tablo 4.2. Aktivasyon fonksiyonu formül ve değer aralıkları	56
Tablo 4.3. Performans metrikleri [79].....	64
Tablo 5.1. Günlük uçuş sayıları.....	70
Tablo 5.2. Aylık trafik verileri	71
Tablo 5.3. Veri setinin istatistiksel bilgileri	72
Tablo 5.4. Birinci analizin LSTM ağı araştırması	75
Tablo 5.5. Birinci veri setinin LSTM ağı mimarisi	78
Tablo 5.6. İkinci analizin LSTM ağı araştırması.....	80
Tablo 5.7. İkinci analizin LSTM ağı mimarisi	83
Tablo 5.8. Üçüncü analizin LSTM ağı araştırması.....	84
Tablo 5.9. Üçüncü analizin LSTM ağı mimarisi	87
Tablo 5.10. SARIMA modelleri ve modellerin Akaike Bilgi Kriteri değerleri	95
Tablo 5.11. Birinci analizin LSTM ve SARIMA model sonuçlarının karşılaştırması	100
Tablo 5.12. İkinci analizin LSTM ve SARIMA model sonuçlarının karşılaştırması	100
Tablo 5.13. Üçüncü analizin LSTM ve SARIMA model sonuçlarının karşılaştırması	100
Tablo 5.14. Günlük uçuş planı	102
Tablo 5.15. Hava yolu filo bilgileri	104
Tablo 5.16. Örneklem dışı öngörü ile gerçek değerlerin karşılaştırılması	105
Tablo 5.17. 01.06.2023 tarihli uçak çizelgesi.....	108
Tablo 5.18. 01.06.2023 tarihli uçak çizelgesinin net kâr değerleri	109
Tablo 5.19. Günlük kazanç değerlerinin karşılaştırması	113

İÇİNDEKİLER

	Sayfa
ÖZET.....	I
ABSTRACT.....	II
TEŞEKKÜR.....	III
İÇİNDEKİLER	IV
SİMGELER VE KISALTMALAR DİZİNİ	IV
ŞEKİLLER DİZİNİ.....	V
TABLolar DİZİNİ	VI
1. GİRİŞ.....	1
2. HAVA TAŞIMACILIĞI.....	6
2.1. Hava Taşımacılığının Önemi	8
2.1.1. Hava Taşımacılığının Ekonomik Açıdan Önemi	8
2.1.2. Hava Taşımacılığının Sosyal ve Kültürel Açıdan Önemi.....	9
2.2. Hava Yolu Taşımacılığında Talep	10
2.2.1. Hava Taşımacılığı Talebine Etki Eden Faktörler.....	12
2.2.1.1. Yakıt Fiyatları	12
2.2.1.2. Terör Saldırıları.....	13
2.2.1.3. Ekonomik Krizler	13
2.2.1.4. Salgın Hastalıklar.....	14
2.3. Hava Yolu İşletmelerinde Operasyonel Planlama ve Çizelgeleme.....	16
2.3.1. Filo Atama Problemi	18
3. LİTERATÜRDE YAPILAN ÇALIŞMALAR	20
3.1. Havacılık Sektörü Talep Tahmini Konusunda Yapılan Çalışmalar.....	20
3.2. COVID-19 ve Havacılık Sektörü Konusunda Yapılan Çalışmalar.....	26
3.3. Filo Atama Konusunda Yapılan Çalışmalar	31
4. TALEP TAHMİN YÖNTEMLERİ.....	36
4.1. Kalitatif (Nitel) Tahmin Yöntemleri	36
4.2. Kantitatif (Nicel) Tahmin Yöntemleri	37
4.2.1. Zaman Serileri Analizi	38
4.2.1.1. Zaman Serilerinde Durağanlık.....	40
4.2.1.2. Box-Jenkins Yöntemi	41
4.2.1.2.1. Box-Jenkins Modelinin Kurulması	43
4.2.2. Yapay Sinir Ağları	50
4.2.2.1. Yapay Sinir Ağı Yapısı.....	50

4.2.2.2.	Aktivasyon Fonksiyonları.....	52
4.2.2.2.1.	Basamak (Step) Fonksiyonu.....	52
4.2.2.2.2.	Doğrusal (Lineer) Fonksiyon	53
4.2.2.2.3.	Sigmoid Fonksiyonu.....	53
4.2.2.2.4.	Hiperbolik Tanjant (Tanh) Fonksiyonu.....	54
4.2.2.2.5.	ReLU (Rectified Linear Unit) Fonksiyonu.....	55
4.2.2.2.6.	Sızıntı (Leaky) ReLU Fonksiyonu	55
4.2.2.3.	Yapay Sinir Ağı Mimarileri.....	57
4.2.2.3.1.	İleri Beslemeli Yapay Sinir Ağları	57
4.2.2.3.2.	Geri Beslemeli Yapay Sinir Ağları	59
4.2.2.4.	Yinelenen Sinir Ağları (Recurrent Neural Networks)	60
4.2.2.4.1.	Uzun Kısa Süreli Bellek (Long Short Term Memory).....	62
4.2.3.	Tahmin Yöntemlerinin Performans Kriterleri.....	63
5.	KARAR DESTEK SİSTEMİNİN OLUŞTURULMASI.....	65
5.1.	Verilerin Toplanması	67
5.2.	Çalışmada Kullanılan Yazılımlar	68
5.3.	Veri Ön İşleme	70
5.4.	Tahmin Yöntemi Seçimi	73
5.4.1.	Uzun Kısa Süreli Bellek (LSTM) İle Talep Tahmini	74
5.4.2.	Box-Jenkins Yöntemi.....	89
5.4.3.	Modellerin Performans Ölçütlerinin İncelenmesi.....	100
5.5.	Filo Çizelgesinin Oluşturulması.....	101
5.5.1.	Uçak ve Uçuş Bilgilerinin Çekilmesi.....	101
5.5.2.	Örneklem Dışı Öngörü.....	104
5.5.3.	Matematiksel Modelin Geliştirilmesi.....	106
5.5.4.	Filo Atama Probleminin Çözümü	108
6.	SONUÇLAR VE TARTIŞMA	114
6.1.	Gelecek Çalışmalar	116
	KAYNAKLAR	117
	EKLER.....	124
EK 5.1.	Uzun Kısa Süreli Bellek Python Kodu	124
EK 5.2.	Box-Jenkins Python Kodu	126
EK 5.3.	Filo Atama Matematiksel Modeli	128
EK 5.4.	01.06.2023 Tarihli Filo Atamaları	129


EK 5.5. 01.06.2023 Tarihli Modelin Filo Atamalarının Kazanç Değerleri.....	131
EK 5.6. 02.06.2023 Tarihli Filo Atamaları	133
EK 5.7. 02.06.2023 Tarihli Modelin Filo Atamalarının Kazanç Değerleri.....	135
EK 5.8. 03.06.2023 Tarihli Filo Atamaları	137
EK 5.9. 03.06.2023 Tarihli Modelin Filo Atamalarının Kazanç Değerleri.....	139
EK 5.10. 04.06.2023 Tarihli Filo Atamaları	141
EK 5.11. 04.06.2023 Tarihli Modelin Filo Atamalarının Kazanç Değerleri.....	143
EK 5.12. 05.06.2023 Tarihli Filo Atamaları	145
EK 5.13. 05.06.2023 Tarihli Modelin Filo Atamalarının Kazanç Değerleri.....	147
EK 5.14. 06.06.2023 Tarihli Filo Atamaları	149
EK 5.15. 06.06.2023 Tarihli Modelin Filo Atamalarının Kazanç Değerleri.....	151
EK 5.16. 07.06.2023 Tarihli Filo Atamaları	153
EK 5.17. 07.06.2023 Tarihli Modelin Filo Atamalarının Kazanç Değerleri.....	155
EK 5.18. Havayolu Filo Atamaları.....	157
EK 5.19. 01.06.2023 Tarihli Havayolunun Filo Atamalarının Kazanç Değerleri	158
EK 5.20. 02.06.2023 Tarihli Havayolunun Filo Atamalarının Kazanç Değerleri	160
EK 5.21. 03.06.2023 Tarihli Havayolunun Filo Atamalarının Kazanç Değerleri	162
EK 5.22. 04.06.2023 Tarihli Havayolunun Filo Atamalarının Kazanç Değerleri	164
EK 5.23. 05.06.2023 Tarihli Havayolunun Filo Atamalarının Kazanç Değerleri	166
EK 5.24. 06.06.2023 Tarihli Havayolunun Filo Atamalarının Kazanç Değerleri	168
EK 5.25. 07.06.2023 Tarihli Havayolunun Filo Atamalarının Kazanç Değerleri	170

1. GİRİŞ

Küresel hava yolu endüstrisinin hem taşımacılık faaliyetleri hem de sanayi, turizm gibi endüstriler üzerindeki etkisi sebebiyle dünya ekonomisinde büyük bir önemi bulunmaktadır [1]. Hava taşımacılığı global olarak 3,5 trilyon dolarlık ekonomik faaliyeti desteklemektedir ki bu değer küresel Gayrisafi Yurt İçi Hasıla'nın (GSYİH) %4,1'ini oluşturmaktadır [2].

Hava hizmetlerine olan talep, hava taşımacılığının küresel ekonomi üzerindeki etkisini artırmakta, milyonlarca insanın ve milyarlarca dolar değerindeki malın dünyanın dört bir yanındaki pazarlara hızlı bir şekilde taşınmasını mümkün kılmakta ve milyonlarca insanın hayatlarında önemli bir rol oynamaktadır [3]. Ne var ki son derece önemli bu sektörün aynı zamanda çok hassas bir yapısı bulunmaktadır. Havacılık endüstrisi, 2019 yılında ortaya çıkan ve 2020 yılında küresel salgın ilan edilen Koronavirüs Hastalığı (COVID-19) tarafından en çok etkilenen endüstrilerden olmuştur. Ülke bazında uygulanan seyahat kısıtlamaları ve yolcu talebindeki benzeri görülmemiş düşüş çoğu hava yolu şirketinin faaliyetlerini durdurmaya yol açmış, bazı hava yolu şirketlerini ise iflas noktasına sürüklemiştir [4]. Aradan geçen üç yıl sonunda küresel salgın etkisini hafifletmiş, seyahat kısıtlamaları kalkmış ve hava yolu sektörü faaliyetleri 2019 seviyelerine yaklaşmıştır.


Şekil 1.1'de Uluslararası Hava Taşımacılığı Birliği (IATA) tarafından 2023 yılında yayımlanan yıllık rapordan alınan 2015 ve 2023 yılları arası küresel hava yolları gelirlerinin grafiği verilmiştir.



Şekil 1.1. 2015-2023 yılları arası yolcu ve kargo gelirleri [5]

IATA'nın raporuna göre; 2019 yılında yıllık 800 milyar dolar seviyelerine çıkan yolcu ve kargo gelirleri 2020 yılında ani bir düşüşle yıllık 400 milyar doların altına gerilemiştir. 2021 yılında 2019 yılının ancak %60'ı oranında yolcu ve kargo geliri elde edilebilmişken bu oran 2022 yılında %87'ye, 2023 yılında ise %93 seviyesine çıkabilmiş, ancak henüz 2019 seviyesine dönülememiştir.

Şekil 2.1'de IATA'nın aynı yıllık raporundan alınan, hava yolu endüstrisinin 2000 ve 2023 yılları arası net kar ve faaliyet marjı grafiği yer almaktadır.



Şekil 1.2. 2000-2023 yılları arası faaliyet marjı ve net kar [5]

IATA'nın raporuna göre, hava yolu endüstrisi 2020 yılında net 140 milyar dolarlık kayıp yaşamıştır. 2021 yılında kayıp miktarı azalarak 40 milyar dolara, 2022 yılında ise 7 milyar dolara gerilemiştir. Geçen üç yılın ardından ilk kez 2023 yılında kar grafiği tersine dönmüştür. Aynı grafikte, 2001 yılındaki 11 Eylül terör saldırısı ve 2008 yılındaki küresel ekonomik krizin hava yollarına etkisi de görülebilmektedir.

Şekil 1.1 ve Şekil 1.2'de yer alan grafiklerden anlaşılacağı üzere hava yolu endüstrisi 2020 yılında gelmiş geçmiş en zor zamanlarından birini yaşamıştır. Sektör hızla toparlanmaktadır ancak henüz 2019 yılı seviyelerine dönülememiştir. Böyle hassas bir endüstride olası bir kriz dönemi ve kriz dönemi sonrası toparlanma sürecinin iyi bir planlama süreci ile yürütülmesi gerektiği ortadadır.

Bu tez çalışması ile kriz dönemi ve kriz dönemi sonrası hava yolu operasyonlarının planlanması için hava yolu yöneticilerine yardımcı olacak ve hava yolu operasyonel planlama uzmanlarının kullanımına sunulacak bir karar destek sisteminin oluşturulması amaçlanmıştır. COVID-19 dönemi, yolcu taleplerinin ne kadar hızlı değişebileceğini ve insanların güvensiz hissettiklerinde zorunlu seyahatlerini bile erteleyebildiklerini, dolayısıyla yolcu taleplerini öngörmenin zorluğunu göstermiştir. Bu nedenle bu tez çalışması özellikle yolcu taleplerini tahminleme problemi üzerine yoğunlaşmıştır. Tez çalışması kapsamında önerilen karar destek sisteminde yolcu sayısı tahminleme ve tahminlenen döneme göre filo ataması yapma probleminin çözümü amaçlanmıştır.

Bu tez çalışmasında önerilen karar destek sistemini oluşturabilmek için Pegasus Hava Yolları'nın günlük yolcu sayıları verileri kullanılmıştır. İlk olarak 01.07.2020 ve 31.05.2023 tarihleri arasındaki hava yolunun günlük uçuş verilerine ulaşılarak analiz edilmiş ve yolcu sayılarının zaman serisi hazırlanmıştır. Farklı periyotlardaki operasyonel planlama süreçlerinde kullanmak ve tahmin performanslarını görmek amacıyla, tahmin dönemlerinin değiştirildiği üç farklı analiz için zaman serisi tekrar hazırlanmıştır.

Tez çalışması kapsamında oluşturulan karar destek sisteminde kullanılmak üzere literatürde sıklıkla tercih edilen ve zaman serilerinde başarılı performans gösteren geleneksel zaman serisi tahmin yöntemi Box-Jenkins ile uzun vadeli bilgilerin hatırlanması için tasarlanan yapay sinir ağı mimarilerinden Uzun-Kısa Süreli Bellek (LSTM) yöntemleri tercih edilmiştir. Seçilen tahmin modelleri ile hazırlanan zaman serisi modellenmiştir. Modelleme sonucunda tahmin değerlerinin Ortalama Mutlak Hata (MAE), Ortalama Mutlak Yüzde Hata (MAPE) ve Kök Ortalama Hata Kare (RMSE) performans metrikleri hesaplanmıştır. Hesaplanan performans metrikleri karşılaştırılarak veri setinde daha yüksek performans gösteren yöntem seçilmiştir. Hava yolu kazancını enbüyükleyen günlük filo atama çizelgesini oluşturmak amacıyla geliştirilecek matematiksel modelde kullanılmak üzere, seçilen tahmin yöntemi ile belirlenen periyotta örneklem dışı öngörü yapılmıştır.

Matematiksel modelin hazırlanması için seçilen hava yoluna ait filo ve uçuş bilgileri çekilmiştir. Bu doğrultuda matematiksel modelin amaç fonksiyonu, parametreleri, karar değişkenleri ve kısıtları belirlenmiştir. Geliştirilen matematiksel model tahmin edilen yolcu sayıları ile çalıştırılmıştır. Model sonucunda hava yolunun günlük kazancını enbüyükleyen uçuş-filo çizelgesi oluşturulmuş, hava yolunun günlük ve haftalık kazançları hesaplanmıştır. Model performansını görmek amacıyla hava yolunun ilgili uçuş kodlarına atadığı geçmiş filo bilgileri çekilmiş ve hava yolunun günlük kazançları tekrar hesaplanmıştır. Geliştirilen model ile hava yolu kazancında %4 oranında iyileşme gerçekleştirildiği tespit edilmiştir.

Tez çalışmasının akışı ise şu şekildedir: İkinci bölümde hava taşımacılığı hakkında genel bilgiler verilmiştir. Hava taşımacılığının tanımı, sınıflandırılması, önemi, hava yolu taşımacılığında talep, talebe ekte eden faktörlerin ayrıntılı analizi ve hava yolu işletmelerinde operasyonel planlama ve çizelgeleme süreçleri ikinci bölümde yer almaktadır. Üçüncü bölümde havacılık sektöründe talep tahmini ve filo atama problemi üzerine yapılan çalışmalar incelenmiştir. Dördüncü bölümde tahmin yöntemleri sınıflandırılmış, Box-Jenkins ve yapay sinir ağları yöntemleri tanıtılmıştır. Beşinci bölümde filo atama problemine yönelik karar destek sistemi oluşturulmuştur. Karar destek sistemi oluşturulurken verilerin toplanması, tahmin yönteminin seçilmesi, matematiksel modelin kurulması adımları ayrıntılı olarak beşinci bölümde verilmiştir. Altıncı bölümde ise tez çalışması kapsamında yapılan uygulamanın sonuçları tartışılmış, gelecek çalışmalar için önerilerde bulunulmuştur.

2. HAVA TAŞIMACILIĞI

Hava taşımacılığı; çeşitli amaçları gerçekleştirmek amacıyla oluşturulan, girdisi insan, hava araçları, havalimanları ve kargo olan, sonucunda ise yolcu ve kargo taşıma, hizmet sunumu gibi çıktılara dönüşen bir sistemdir [6]. Hava taşımacılığı dünyanın en önemli endüstrilerinden birisidir. Her yıl milyonlarca insanın iş ve eğlence hayatında belirleyici bir rol oynayan hava taşımacılığı, daha iyi bir yaşam kalitesini teşvik etmekte ve yaşam standartlarının iyileştirilmesine yardımcı olmaktadır [3].


Hava taşımacılığı, hava yolu taşımacılığı ve genel havacılık adı altında iki sınıfa ayrılmaktadır. Hava yolu taşımacılığının genel havacılıktan ayrılan temel özelliği; hava yolu taşımacılığının ticari bir amaçla ücret karşılığında yapılmasıdır [6]. Genel havacılık ise şahsi amaçlarla ve daha küçük boyutlu hava araçlarıyla yapılmaktadır.

Hava yolu taşımacılığı, insanların, kargonun ve postanın zaman ve yer faydası sağlayacak şekilde bir noktadan başa bir noktaya bir hava aracı ile gitmesi olarak tanımlanabilir [7]. Hava yolu taşımacılığı yapan işletmeler çeşitli kategorilere ayrılmakla birlikte bu işletmelerin filo büyüklükleri ve sefer sıklıkları geniş bir yelpazede yer almaktadır [7].

Hava yolu taşımacılığının özellikleri şu şekilde sıralanabilir [6].

- Ürünü stoklanamaz, hizmet anında üretilir ve tüketilir.
- Hizmet sunumu birçok değişkene bağlı olduğu için kesin değildir. Teknik şartlar ya da dış bir sebep nedeniyle gerçekleşmeyebilir.
- Genellikle toplu olarak sunulur.
- Hizmet tüketim anında üretildiği için önceden deneme ve test etme imkânı bulunmaz.
- Hizmet kalitesi nesnel olarak ifade edilemez, kişilerin beklentilerine göre değişmektedir.

Uluslararası Hava Taşımacılığı Birliği'nin (IATA) 2022 yılı raporunda yayınlanan ve 137 hava yolu şirketi incelenerek oluşturulan 2016-2022 yılları arasındaki hava yolu gelir dağılımı grafiği Şekil 2.1'de verilmiştir.



Şekil 2.1. Yıllara göre hava yolu gelir payı dağılımı [8]

Şekil 2.1'e bakıldığında, örneklemdaki hava yolu şirketlerinin toplam gelirleri içinde yolcu gelirlerinin payı 2019 yılında %72,5 iken 2020 yılında bu oranın %49,4'e düştüğü görülmektedir. Yolcu gelirlerinin payındaki bu azalış hava yolu şirketlerine yansıyan COVID-19 pandemisinin etkisini göstermektedir. Yolcu seyahatlerinin azalması ve e-ticaretin yükselişe geçmesiyle birlikte gelir dağılımı içinde kargonun payı 2020 yılında bir önceki yıla göre %24,2 artmıştır. Bununla birlikte, 2022 yılına gelindiğinde pandeminin etkisinin ve insanlarda yarattığı seyahat korkusunun azalması sebebiyle yolcu seyahatleri artışa geçerek %60,3'lük paya ulaşmıştır.

Hızlı ve güvenli olması sebebiyle sıklıkla tercih edilen hava yolu taşımacılığı 2021 yılında 24,2 milyon sefer yaparak 2,3 milyar yolcu ve 56,5 milyon ton yük taşımıştır [9].

2.1. Hava Taşımacılığının Önemi

Wright Kardeşler olarak tanınan Orville ve Wilbur Wright'ın ilk uçuşundan bu zamana kadar olan yüzyıl boyunca hızla gelişen hava taşımacılığı endüstrisi, günümüzde halkların hatta ülkelerin ve kıtaların kültürel ve ekonomik bağlarının gelişmesi ve sürdürülmesi için elzem olan bir endüstri haline gelmiştir [10].

Hava taşımacılığının insanlığa ve ülkeler arasındaki ilişkilere dair birçok faydası bulunmaktadır. Bu faydalar genel olarak ekonomik, sosyal ve kültürel olarak sınıflandırılabilir.

2.1.1. Hava Taşımacılığının Ekonomik Açıdan Önemi

Havacılık uluslararası ticaretin ve ekonomik kalkınmanın merkezinde yer almaktadır [11]. Birçok sektörün küresel tedarik zincirleri için hayati önem taşıyan hava taşımacılığı, uzak mesafelere taşıma konusunda hızlı ve güvenli olması sebebiyle tercih edilmektedir. Hava taşımacılığı çoğunlukla hafif, kompakt, çabuk bozulabilen ve birim değeri yüksek malların teslimatı için kullanılmaktadır. Ticaret hacmi olarak hava taşımacılığı ile taşınan mallar dünya çapında taşınanların %1'ine denk gelmesine rağmen bu miktar tüm ticaret değerinin üçte birine denk gelmektedir [11]. Bununla birlikte gelişmekte olan ülkelerin iç pazarlara dahil olması ve gıda ve çiçek gibi çabuk bozulabilen malların ihraç edilebilmesi için de hava taşımacılığı gerekmektedir. İlaç endüstrisi de başta aşilar olmak üzere zamana duyarlı tıbbi malzemelerin teslimatı için hava taşımacılığına güvenmektedir [11].

Hava taşımacılığının dünyanın en büyük endüstrilerinden olan turizm endüstrisine de büyük bir katkısı bulunmaktadır. Uluslararası turistlerin %58'inden fazlası seyahat aracı olarak hava yolu ulaşımını tercih etmektedir, dolayısıyla havacılık ve turizm endüstrileri sürdürülebilir kalkınma ve büyüme için birbirlerine bağımlıdır [12]. Turizm, düzenli turist akışına ihtiyaç duyan, gelişmekte olan ülkeler için büyük önem arz etmektedir. Gelen turistlerin azalması durumunda bu ülkelerin ekonomileri de bundan etkilenecektir.

Hava taşımacılığı endüstrisi aynı zamanda büyük bir istihdam kaynağıdır. Dünya çapında yaklaşık 11,3 milyon kişi doğrudan iş imkanlarından; havaalanı operatörü, perakende, araç kiralama, gümrük, göçmenlik, catering, uçuş ve kabin ekibi üyesi, yer hizmetleri, eğitim ve bakım personeli, motor ve bileşen mühendisi ve tasarımcısı, hava trafik kontrolörü ve havaalanı yöneticisi olarak görev almaktadır [13]. Dünya genelinde 18,1 milyon kişi ise mal ve hizmet alımları yoluyla dolaylı olarak havacılık tarafından desteklenmektedir. Bunlar arasında uçak parçaları tedarikçileri, yakıt tedarikçileri, inşaat şirketleri, havalimanlarında satılan malların üreticileri, çağrı merkezleri gibi çeşitli hava taşımacılığı destek rolleri yer almaktadır [13]. Aynı zamanda hava taşımacılığı, 44,8 milyon kişinin istihdam edildiği dünyanın en büyük endüstrisi haline gelmekte olan turizm sektöründe de hayati bir rol oynamaktadır.

Ekonomik büyüme ve hava taşımacılığı arasında pozitif yönlü bir ilişki söz konusudur. Ekonomik büyüme hava taşımacılığı talebini arttırmakta, artan hava taşımacılığı faaliyetleri ise doğrudan ve dolaylı olarak ekonomiye katkı sağlamaktadır.

2.1.2. Hava Taşımacılığının Sosyal ve Kültürel Açıdan Önemi

Hava yolculuğunun ekonomik öneminin yanı sıra sosyal ve kültürel ilişkilere ve hayati ihtiyaçlara da büyük bir katkısı bulunmaktadır. Dünyada kara yolu bağlantısı zayıf olan pek çok toplum hava yolu ile dünyanın geri kalanı ile bağlantılarını devam ettirebilmektedir. Rusya, Kanada ve İskandinavya'nın en kuzey bölgeleri ve diğer pek çok ücra topluluk için eğitim ve sağlık hizmetleri gibi temel ihtiyaçlara erişim yalnızca hava yolu ile mümkündür [14].

Dünyanın dört bir yanındaki küçük ada ülkeleri ticaret yapmak, eğitim ve sağlık hizmetlerine ulaşmak ve aksi takdirde dünya ile tek bağlantılarını sağlayacak olan düzensiz ve seyrek tekne seferlerinin ötesine erişim sağlamak için hava taşımacılığına güvenmektedir [14].

Hava hizmetleri afet, kıtlık ve savaş zamanlarında da insanlara yardım etmede önemli bir rol oynamaktadır. Özellikle diğer erişim yollarının engellendiği durumlarda gıda, tıbbi yardım, insan gücü ve arama kurtarma hizmetlerinin ulaştırılmasında yardımcı olmaktadır [15]. Bununla birlikte yılda yaklaşık 400.000 hasta evleriyle hastaneler arasında tarifeli uçuşlarla taşınmaktadır [14].

Aynı zamanda hava taşımacılığı ile yapılan tatiller ve kültürel seyahatler insanların kişisel gelişimlerine ve hayat kalitelerinin artmasına yardımcı olmaktadır. Ayrıca hava taşımacılığı uzak mesafelerdeki arkadaş ve aile ziyaretleri için de hızlı ve güvenli bir seyahat alternatifi sunmaktadır.

2.2. Hava Yolu Taşımacılığında Talep

Talep, tüketicilerin bir zaman diliminde farklı fiyat seviyelerinden farklı miktarlardaki mal veya hizmetleri satın alma istekleri olarak tanımlanmaktadır [6][7]. Tüketiciler bir beyaz eşya üreticisinden üretilen ürün ile birlikte garanti, teknik servis ve yedek parça temini, bir seyahat acentasından ise yurtiçi ya da yurtdışı turu, uçak bileti, yemek, konaklama, rehberlik hizmeti ve güvenilirlik talep edebilmektedir. Hava yolu taşımacılığında ise talep edilen ürün; bilet, bagaj, yer ve kabin hizmetleri, emniyet, dakiklik, uygunluk ve işletmenin imajı da dahil olmak üzere müşterilerin ihtiyaç duydukları hizmet sunumlarının tamamına denmektedir [7]. Bu tez çalışmasında ise hava yolu yolcularının yolculuk talebi, yani satılan ya da satılacak koltuk sayılarından bahsedilecektir.

Hava yolu taşımacılığının ürünü olan hizmetler daha sonra sunulmak üzere depolanamamaktadır. Bu nedenle satılamayan boş koltuklar işletme için bir kayıptır. Bir uçuşta boş kalan koltuklar daha sonra satılamayacağı için bozulabilen ve çöpe atılan bir ürün olarak değerlendirilmektedir [16].

Hava yolu işletmesinin karlılığı için arz ve talebi birbirine yakın tutması gereklidir. Düşük talebin olduğu bir uçuş için yüksek kapasiteli bir uçağın atanması sonucunda koltukların büyük bir kısmı boş kalacak ve sonucunda işletmenin yüksek maliyetlere katlanması gerekecektir. Aynı şekilde yüksek talebin olduğu bir uçuşa düşük kapasiteli bir uçak atanması durumunda da kullanılmayan talep stoklanamayacağı için potansiyel gelir kazancı kaybedilecektir. Hava yolu işletmelerinin stratejisi, doğru sayıda koltuğu doğru fiyattan sunmak olmalıdır [16].

Hava yolu trafiği ölçümleri fiilen kullanılan ya da satılan hava yolu çıktısının miktarını ölçmektedir [1]. Hava yolları tarafından taşınan trafik; yolcu, kargo ve postalardan oluşmaktadır. Yalnızca kargo taşıyan hava yolları öncelikli olarak kargo taşıırken, yolcu ya da karma hava yolları ise tüm trafik türlerini birden taşıyabilmektedir [1]. Talebin ölçülmesinde her sektör farklı kavramları kullanmakla birlikte hava yolu taşımacılığında talebin ölçülmesinde kullanılan ölçüm araçları:

- Ücretli yolcu,
- Ücretli yolcu-kilometre,
- Ücretli ton-kilometre
- Yolcu yük faktörüdür [17].

Ücretli yolcu; ücret karşılığı hava yolu ürününü yani koltuğu satın alan müşterilere denilmektedir. Ücretli yolcu-kilometre satın alınan koltuk ve iki uçuş noktası arasındaki mesafenin çarpılması ile, ücretli ton-kilometre ise taşınan yük ve mesafenin çarpılması ile elde edilmektedir. Yolcu yük faktörü ise uçağın koltuklarının doluluk oranını vermektedir.

Bir hava yolu işletmesinde yolcu talebi tahmini operasyon yöneticilerinin uygun planlar oluşturabilmesi için kritik bir unsurdur. Havaalanı inşaatı, filo ve rota planlaması gibi uzun vadeli operasyonel faaliyetlerinin gerçekleştirilebilmesi için uzun vadeli tahminler gerekmektedir. Bununla birlikte uçuş ve uçak çizelgeleme, ekip çizelgeleme ve bakım ve denetim gibi kısa vadeli planlar için de yüksek doğruluklu kısa vadeli talep tahminlerine ihtiyaç duyulmaktadır [18].

Hava taşımacılığında talep genel olarak büyüme eğilimindedir. Ancak ekonomik krizler, terör saldırıları, dünya geneline yayılan bulaşıcı hastalıklar ya da salgınlar bu büyümeyi sekteye uğratmaktadır.

2.2.1. Hava Taşımacılığı Talebine Etki Eden Faktörler

Hava taşımacılığına talep her zaman beklenen düzeyde olmayabilir. Yolcuların talepleri çeşitli nedenlerle dalgalanma gösterebilmektedir. Bu nedenlerin ve yolcuların karşı tepkilerinin önceden farkına vararak işletmelerin olası bir talep dalgalanmasına karşı hazırda bulunmaları gerekmektedir. Yolcu talebinin belirleyicileri şu şekilde sıralanabilir:

- Yakıt fiyatları
- Yolcuların ekonomik durumları ve gelir seviyeleri
- Rakip firmaların ve diğer ulaşım araçlarının fiyatları
- Yolcu tercihleri ve müşteri sadakati
- Uçuş sıklığı,
- Sıra dışı gelişen ekonomik krizler ve salgınlar [6].

2.2.1.1. Yakıt Fiyatları

Yakıt maliyetleri bilet fiyatlarını ve dolayısıyla karlılığı önemli ölçüde etkileyen bir değişkendir. Dünya'daki gelişmelere bağlı olarak yakıt fiyatlarında dalgalanmalar yaşanmaktadır. Hava yolu firmaları ise yakıt fiyatlarındaki bu artışları bilet fiyatlarına yansıtmak durumundadır. Bilet fiyatlarının artmasıyla birlikte hava yolu talebinde azalma meydana gelmektedir.

Yakıt maliyetleri hava yolu işletmeleri için sabit olan ve kontrol edemedikleri bir maliyet özelliğindedir. Yakıt maliyetleri ürün farklılaşması yoluyla rekabet avantajı elde edemeyen hava yolu işletmelerinin bilet fiyatları üzerinden avantaj elde etmesini zorlaştırmaktadır [6].

2.2.1.2. Terör Saldırıları

Hava taşımacılığına olan talebin yakıt fiyatlarında ya da GSYH'deki değişimlerin etkisiyle dolaylı olarak etkilenmesinin yanı sıra gerçekleşen terör saldırıları nedeniyle doğrudan da etkilenebilmektedir. Bu etkileşime yakın tarihteki en büyük örnek elbette ki 11 Eylül terör saldırısıdır.

11 Eylül 2001'de kaçırılan yolcu uçakları ile Dünya Ticaret Merkezi ve Pentagon'a gerçekleştirilen terör saldırısı sonrası 2000 yılında 328,5 milyar dolar olan küresel ölçekte hava yolu işletme gelirleri 2001'de 307,5 milyar dolara; 2002'de ise 378,8 milyar dolara gerilemiştir [19].


Terör saldırısından yolcular psikolojik olarak da etkilenmiş, korku ve güvenlik kaygısı duymuşlardır. Havaalanları ve hava yolları ise olası tehditlerden korunmak için güvenlik önlemlerini sıkılaştırmak durumunda kalmışlardır. Yolcuların kaygısı ve sıkılaştırılmış havaalanı güvenlik önlemleri de uçuşlardaki yolcu sayısını etkilemiştir. Bunlarla birlikte küresel yolcu trafiği 2001 yılında 2000 yılına göre %2.9 oranında azalmış, 2001-2005 yılları arasında hava yolları toplam 41,5 milyar dolar kaybetmiştir [19].

2.2.1.3. Ekonomik Krizler

Ekonomik krizler; enflasyon, döviz kuru politikaları, aşırı borçlanma gibi nedenlerle meydana gelebilen, önceden tahmin edilemeyen ve bu nedenle önlem alınamayan, ülke ekonomisinde olağandışı gelişmeler yaşatan kriz durumlarıdır [20]. Ekonomik krizler fiyatların artmasına, insanların işsiz kalmasına ve yoksullaşmasına, dolayısıyla alım gücünün düşmesine sebep olmaktadır. Ekonomik krizlerin yarattığı bu ekonomik yıkımın büyüklüğü elbette sektörden sektöre değişiklik göstermektedir. Bununla birlikte, havacılık sektörü krizden en çok etkilenen sektörler arasında yer almaktadır.

Havacılık sektörünün diğer sektörlerle kıyasla ekonomik değişimlerden ve uluslararası gelişmelerden daha kolay etkilendiği görülmektedir [6]. Bunun en önemli nedeni havacılık sektörünün turizm ve sanayi sektörleriyle yoğun olarak iş birliği içinde olmasıdır.

Havacılık sektörüne 11 Eylül saldırılarından sonra en büyük darbe 2008 ekonomik krizi ile vurulmuştur. Ekonomik kriz ile yakıt fiyatları artmış, yolcu talepleri düşmüş, dolayısıyla uçuş sıklıkları azalmış ve hava yolları büyük gelir kayıpları yaşamıştır [21]. Şekil 2.2’de Uluslararası Hava Taşımacılığı Birliği’nin (IATA) 2009 yılının yıllık raporunda yer alan hava yollarının kıta bazında net kar grafiği yer almaktadır.



Şekil 2.2 2008-2007 yılları kıtalara göre net kar miktarları [22]

Şekilde görüldüğü üzere, Kuzey Amerika kıtası net kar miktarları 2007 yılında 5,3 milyar dolar iken 2008 yılında -5.1 milyar dolara gerilemiştir. Asya Pasifik’teki, yıllık 2,1 milyar dolar kar miktarı ekonomik krizin olduğu yıl -3.9 milyar dolara, tüm dünyada ise yıllık 12.9 milyar dolardan -10.4 milyar dolara düşmüştür.

2.2.1.4. Salgın Hastalıklar


Terör saldırıları gibi salgın hastalıkların da havacılığa doğrudan etkisi bulunmaktadır. Hava yolculuğuna etki eden salgınların başında 2003 yılında ortaya çıkan SARS, 2009 yılında ortaya çıkan H1N1 ve 2019 yılında ortaya çıkan COVID-19 salgınları yer almaktadır.

21. yüzyılın ilk salgın hastalığı olan SARS (Şiddetli Akut Solunum Sendromu), bir koronavirüsün neden olduğu, soğuk algınlığı ve gribe benzer şekilde tükürük damlacıkları yoluyla yayılabilen viral bir solunum yolu hastalığıdır [23]. Uluslararası hava yolculukları ile taşınarak beş kıtaya ve 29 ülkeye yayılmıştır. 2003 yılının Şubat ayında tespit edilen virüs, aynı yılın Nisan ayında dünya genelinde Ücretli Yolcu-Kilometre miktarının 2002 yılına kıyasla %18,5 oranında düşmesine sebep olmuştur. Salgının en yoğun etkilendiği Asya-Pasifik bölgesinde ise bu oran %44,8'e ulaşmıştır [24].

SARS salgınının ardından 2009 yılında ortaya çıkan H1N1 grip salgınında 216 ülke enfekte olmuş, ancak hızlı müdahale ile ölüm oranı yalnızca %0.001-%0.007 arasında kalmıştır [24]. Buna rağmen dünya genelinde yolcu talebi önceli yılın aynı dönemine göre %9,3 oranında düşerken, yük talebi de %17,4 oranında azalmıştır [24].

2019 yılında ortaya çıkan ve 2020 yılının Mart ayında Dünya Sağlık Örgütü tarafından küresel salgın olarak nitelendirilen COVID-19 pandemisi önceki krizleri ardında bırakarak havacılık endüstrisine büyük bir şok yaşatmıştır. İnsanların yaşadığı sosyal kargaşa ve karantina nedeniyle sınırların kapatılması binlerce uçuşun iptal edilmesine ve milyonlarca kişinin işsiz kalmasına yol açmıştır. IATA 2020 Mart ayı raporunda, dünya genelinde Ücretli Yolcu-Kilometrenin Şubat ayında %10,3 oranında düştüğünü ve Mayıs ayında bu oranın %55,8'e ulaştığını belirtmiştir [24]. Asya-Pasifik bölgesinde ise bu oran %65,5'e kadar yükselmiştir ki bu şimdiye kadar kaydedilen en büyük düşüştür [24].

ICAO tarafından 2020 yılında yayımlanan 1945-2020 yılları arasındaki taşınan yolcu sayısı grafiği Şekil 2.3'te yer almaktadır.




Şekil 2.3 1945-2020 yılları arası taşınan yolcu sayısı [25]

Yolcu sayısı grafiğinde görüldüğü üzere 1972-2019 yılları arasında meydana gelen krizler taşınan yolcu sayısını etkilemekte, hava yollarında kısmi durgunluk yaratmaktadır. Ancak kısa sürede toparlanan sektör hız kesmeden artan trend eğrisine geri dönmektedir. Bununla birlikte, 2019-2020 yıllarında COVID-19 salgını uçuşları durma noktasına yaklaştırmıştır.

2.3. Hava Yolu İşletmelerinde Operasyonel Planlama ve Çizelgeleme

Hava yolu işletmelerinde operasyonel planlama ve çizelgeleme süreci uçuştan 12 ay önce başlamakta ve uçuş anına dek devam etmektedir. Hava yolu işletmelerinin operasyonel planlama ve çizelgeleme süreci Şekil 2.4'te yer almaktadır.



Şekil 2.4. Hava yollarında operasyonel planlama ve çizelgeleme süreci [26]

Hava yolu işletmelerinin operasyonel planlama sürecinin ilk adımı uçuş çizelgeleme sürecidir. Uçuş çizelgeleme süreci uçuştan 9-12 ay öncesinde tamamlanmakta ve uçuş ağı tasarımı, uçuş sıklığını ve saatlerini belirleme alt problemlerinden meydana gelmektedir. Uçuş çizelgeleme süreci sonucunda ortaya çıkan uçuş tarifi diğer planlama süreçlerinin temelini oluşturmaktadır.

Uçuş çizelgeleme sürecinin ardından uçak çizelgeleme süreci gelmektedir. Uçak çizelgeleme süreci ise filo atama ve uçak rotalama olmak üzere iki alt problemden oluşmaktadır.

Uçak çizelgeleme sürecinin ardından, uçuştan 1-2 ay önce ekip çizelgeleme yapılmaktadır. Ekip çizelgeleme süreci ise uçuş dizisi bulma ve ekip atama süreçlerinden meydana gelmektedir. Hava yolu işletmelerinde operasyonel planlama süreçlerinin son adımında ise düzensiz olayların yönetimi kapsamında yeniden uçuş, uçak ve ekip çizelgeleme yapılmaktadır.

2.3.1. Filo Atama Problemi

Hava yolu operasyonlarının planlama sürecindeki filo atama problemi, farklı kapasitelerdeki uçakların önceden çizelgelenmiş uçuşlara operasyonel maliyetleri enküçükleyecek ya da işletme kazancını enbüyükleyecek şekilde atanmasını kapsamaktadır [27].

Filo atama probleminin çözülebilmesi için uçuş tarifesinin hazırlanmış olması gerekmektedir. Uçuş tarifi filo atama probleminin verisini oluşturmaktadır [16]. Filo atama probleminde temel olarak uçuş tarifesindeki uçuşların havalimanı bilgileri, uçuş süreleri, doluluk oranları, uçakların kapasite bilgileri, her filo türü için uçuş maliyeti ve uçuş gelirleri yer almaktadır [16].

Filo atamada uygulanan matematiksel modeller maliyetin minimizasyonunu ya da gelirin maksimizasyonunu sağlamaktadır. Klasik bir filo atama modelinin amaç fonksiyonunda maliyeti belirten “*Arz edilen Koltuk Kilometre Başına Gider*” ya da geliri belirten “*Ücretli Yolcu Kilometre Birim Gelir*” ifadeleri yer almaktadır. *Arz edilen Koltuk Kilometre Başına Gider (AKKBG)*; her bir kilometrede her koltuğu işletmenin birim maliyetini, *Ücretli Yolcu Kilometre Birim Gelir (ÜYKBG)* ise her bir kilometrede ücretini ödeyerek uçan her yolcunun birim getirisini ifade etmektedir. *AKKBG* ve *ÜYKBG* parametrelerinin formülleri Denklem 2.1 ve Denklem 2.2’de yer almaktadır.

$$AKKBG = \frac{\text{Toplam operasyon maliyeti}}{\text{Arz edilen koltuk kilometre}} \quad (2.1)$$

$$ÜYKBG = \frac{\text{Toplam ücretli yolcu geliri}}{\text{Ücretli yolcu kilometre}} \quad (2.2)$$

Denklem 2.1’deki Arz Edilen Koltuk Kilometre (AKK), hava yolunun koltuk arzını ifade etmektedir. Denklem 2.2’deki Ücretli Yolcu Kilometrenin (ÜYK) formülü ise Denklem 2.3’te verilmiştir.

$$\text{ÜYK} = \text{Doluluk oranı} * \text{AKK} \quad (2.3)$$

İkinci bölümde hava taşımacılığı ile ilgili genel bilgiler verilmiş ve çalışmanın önemi sunulmuştur. Üçüncü bölümde ise literatürde yapılan çalışmalar tanıtılacaktır.



3. LİTERATÜRDE YAPILAN ÇALIŞMALAR

Havacılık sektörünün önemi ve durağan olmayan, belirsizliği yüksek ortamı araştırmacıların ilgisini çekerek talep tahmini çalışmalarında havacılık sektörünü incelemeye yöneltmiştir. Talep tahmininin belirlenmesi ve bu tahmin aracılığıyla hava yolu gelirlerinin, hava trafik yoğunluğunun, hava yolu pazar payının, bilet fiyatlarının belirlenmesi gibi çeşitli konularda yapılan çalışmalar bulunmaktadır. Aynı zamanda sektöre şok yaşatan ve talepleri alt üst eden durumları ve bu durumların etkilerini önceden öngörerek yumuşatmayı planlayan çalışmalar da yapılmaktadır. Bu çalışmada literatüre ait incelenen çalışmalar iki başlık altında toplanmıştır.

3.1. Havacılık Sektörü Talep Tahmini Konusunda Yapılan Çalışmalar

Ba-Fail ve ark. [28], Suudi Arabistan'daki uluslararası hava yolculuğu talebini analiz etmek amacıyla ekonometrik modeller oluşturmuşlardır. Hava yolcu talebini etkileyen değişkenleri, toplam petrol dışı GSYİH, Tüketici Fiyat Endeksi, mal ve hizmet ithalatı, kişi başına gelir, nüfus büyüklüğü, toplam harcamalar ve toplam tüketim harcamaları olarak belirlemişlerdir. Değişkenleri gruplara ayırarak farklı regresyon modelleri ile talep tahmini yapan Ba-Fail ve ark., nüfus büyüklüğü ve toplam harcamalar değişkenlerinin Suudi Arabistan'daki uluslararası hava yolculuğunun ana belirleyicileri olduğunu tespit etmişlerdir.

Erdem [29], İzmir Adnan Menderes, Antalya ve Ankara-Esenboğa Havalimanlarının aylık iç hat yolcu verilerini kullanmıştır. Sonraki 5 yıllık değerlerini zaman serisi ile tahmin etmiş, havalimanlarının yolcu kapasitelerini aşma durumunu incelemiştir.

Önder ve Kuzu [30], hava trafik yoğunluğunun tahminlenmesi amacıyla yolcu trafiği, toplam kargo trafiği, toplam uçak trafiği ve toplam ticari uçak trafiği olmak üzere dört hava trafik parametresini incelemişlerdir. Zaman serilerinin düzgünleştirme ve ayrıştırma yöntemlerinin performanslarını incelemişler ve parametreler için en uygun yöntem seçimini yapmışlardır.

Ozan ve ark. [31], iç hat yolcu talebini Satın Alma Gücü Paritesi (SGP) ve jet yakıtı fiyatlarına bağlı olarak indeksleme yöntemi ile modellemişlerdir. SGP ve jet yakıtı fiyatlarının iyimser ve kötümser olması durumlarına göre talebi 4 farklı senaryo altında aylık bazda tahmin etmişlerdir.

Havalimanlarının performanslarının ölçülmesi ve mevcut ya da yeni açılacak bir havalimanının etkinliğinin tahmin edilmesi amaçlarıyla Gürler [32], bir yapay sinir ağı modeli geliştirmiştir. Çalışma kapsamında veri zarflama analizi ile 41 adet havalimanını incelemiş, bunlardan 19 adetini etkin, 22 adet havalimanını ise etkin olmayan olarak sınıflandırmıştır. Veri zarflama analizinden elde edilen sonuçlar ile yapay sinir ağı modelini oluşturarak test eden Gürler, %100 oranda başarı sağlamıştır.

Srisaeng ve ark. [33], Avustralya'nın iç hat yolcu miktarları ve yolcu gelirleri için iki farklı genetik algoritma modeli önermişlerdir. Modeller oluşturulurken hava yolu talebini etkileyen 8 adet değişkenin (nüfus, Gayri Safi Yurtiçi Hasıla (GSYİH), kişi başı GSYİH, uçak bileti, işsizlik oranı, reel faiz oranları, jet yakıt fiyatları, turistik yatak kapasiteleri) yanı sıra 3 adet yapay (dummy) değişken (Ansett Australia Hava Yolu'nun 2001'deki çöküşü, 2000'deki Sidney Olimpiyat Oyunları, 2006'daki Melbourne Commonwealth Oyunları) de modellere eklenmiştir. Dummy değişkenler, etkilerinin görüldüğü aralıklarda 1, diğer durumlarda 0 değerini almışlardır.

Küçükyılmaz ve ark. [34], Eskişehir iline ait yolcu potansiyelinin belirlenmesi amacıyla anket yöntemi ile veri toplamış ve karar ağacı yöntemi ile potansiyel yolcuları gruplara ayırmışlardır. Ulaşımda hava yolunu kullanan kişiler arasında iş ve akraba ziyareti amacıyla seyahat edenlerin çoğunlukta olduğunu tespit etmişlerdir.

GSYİH ile yolcu talebi arasındaki ilişkiyi inceleyen çalışmalardan başka bir tanesi ise Phyoe ve arkadaşlarının [35] makalesidir. Phyoe ve ark. GSYİH'nin hava trafiği üzerinde büyük bir etkisinin olduğunu ve hava trafiğini tahminleme çalışmalarında kullanılabileceğini belirtmişlerdir. Ayrıca kullandıkları verilerde ARIMAX yönteminin ARIMA ve üstel trend modellerinden daha başarılı sonuçlar verdiğini gözlemlemişlerdir.

Hava yolu ikram operasyonunu inceleyen Aladağ [36], gıda güvenlik standartlarına dikkat çekmiş ve ikram talebini belirlemenin öneminden bahsetmiştir. İkram talebinin temel performans göstergesinin yolcu talebi olduğunu belirterek yolcu talep tahminine yönelik bir çalışma hazırlamıştır. Zaman serileri ile farklı senaryolar altında modelleri oluşturmuştur. Çalışmada, Türkiye'de havacılık sektörünün olası krizlere karşı duyarlı olduğunun ve kriz dönemlerinde hava yolu seyahat miktarının büyük oranda azaldığının sonucuna varmıştır.

İlgün [37], hava kargo pazar payının tahmini üzerine bir çalışma gerçekleştirmiştir. Model parametrelerini seçerken uzmanların görüşüne başvurmuş, hava kargo pazar payını en çok etkileyebilecek parametreleri, pazarın ortalama birim geliri, firmanın uyguladığı ortalama birim gelir, firmanın sunduğu kapasite, pazarda yer alan rakip sayısı olarak belirlemiştir. Oluşturduğu modeller arasından yapay sinir ağı modellerinin Winters üstel düzleştirme modeline kıyasla gerçeğe daha yakın sonuçlar verdiğini görmüştür. Ayrıca İlgün, modele girdi olarak eklenen değişkenlerin modele etkisini de araştırmıştır. Tahmini en çok etkileyen değişkeni rakip sayısı olarak belirlemiştir.

Türkiye'de iç hatlarda yolcu taleplerinin yapay sinir ağları kullanarak tahmini konusunda ilk çalışanlardan biri olan Koç [38], hava taşımacılığında talebi etkileyen faktörleri iki kategoriye ayırmıştır:

- i. sosyal-ekonomik ve coğrafi faktörler;
- ii. hava taşımacılığı hizmetiyle ilgili faktörler.

Sosyal-ekonomik deęişkenler arasından en yaygın kullanılan deęişkenin popölasyon olduęunu ifade etmiş ve çalışmasında 14 adet deęişken (yolcu, nüfus, giden vatandaşlar, turist sayısı, GSYİH, kiři başına gelir, Tüketici Fiyat Endeksi, jet akaryakıt fiyatı, istihdam, yatak ve koltuk kapasitesi, frekans, bilet fiyatı, enflasyon) kullanmıştır. Ayrıca Koç, çoklu doğrusallığın yapay sinir aęlarına etkisini incelemiş, yapay sinir aęlarının çoklu doğrusallığa duyarsız olduęunu ifade etmiştir.

Dantas ve ark. [39], hava yolu yolcu talebinin tahmin edilmesi için Bagging (Bootstrap aggregating) ve Holt Winters yöntemlerinin birleştirildięi bir yaklaşım önermişlerdir. Önerilen yöntemi 14 ülkenin yolcu talep verileri üzerinde uygulamışlar ve geleneksel tahminleme metotları ile karşılaştırmışlardır. Bagging Holt Winters yönteminin dięer yöntemlerden daha başarılı olduęunu bulmuşlardır.

Hava yolu yolcu taşımacılığı tahmini konusunda yapılan 114 adet çalışmayı inceleyen Efendil ve Eminler [40], bu çalışmalarda en çok ekonometrik modellerin ve yapay zekaya dayanan yöntemlerin istatistiksel metot olarak tercih edildięini tespit etmişlerdir. Ayrıca, çoklu regresyon analizi, uyarlamalı aę tabanlı bulanık çıkarım sistemi (ANFIS) ve yapay sinir aęları yöntemlerini kullandıkları uygulamada regresyon analizinin en yüksek hata deęerine sahip olduęunu görmüşlerdir.

Kalathilparmbil ve Şahin [41], çalışmalarında 2002-2017 yıllarına ait iç hat ve dış hat; uçak, yolcu ve yük trafięi verilerini kullanmışlardır. Eğri uyurma yöntemlerinden en küçük kareler yöntemi ile trafik verilerini tahmin ederek ve Devlet Hava Meydanları İşletmesi'nin (DHMI) yapmış olduęu tahminler ile karşılaştırmışlardır.

Yazgan ve ark. [42], koltuk fiyatlarının talebe baęlı olarak dinamik fiyatlandırıldığı bir çalışma ortaya koymuşlardır. Talebin, destek vektör makinesi, en küçük kareler ve Poisson regresyon denklemi ile belirlendięi makalede koltukların kapasite kısıtları da denkleme ilave edilerek doğrusal olmayan programlama modeli kurularak optimal bilet deęerleri bulunmuştur.

Wang ve Gao [43], petrol fiyatlarındaki deęişimlerin hava yolu kazançlarındaki öngörülebilirliği engellediğini öne sürmüşlerdir. 1994-2017 döneminde ABD'de işlem gören 30 hava yolu şirketini örneklem olarak alarak sabit etkiler regresyon modeli ile petrol fiyatı dinamiklerinin hava yolu kazançları üzerindeki etkisini ve tahmin edilebilirliği incelemişlerdir.

Madhavan ve ark. [44], hava yolu yolcu ve hava kargo talebini tahmin etmek için 2009–2018 yılları arası Hindistan hava yolu endüstrisi verilerini kullanmışlardır. ARIMA ve Bayes yapısal zaman serileri (BSTS) modellerini uygulayarak karşılaştırmışlardır.

Al-Sultan ve ark. [45], Uluslararası Kuveyt Havalimanı'ndaki hava yolcusu sayısını modellemek ve tahmin etmek için 2012-2018 yılları arasındaki aylık hava trafięi hacmi verilerini kullanmışlardır. ARIMA, hata terimli üstel düzeltirme (ETS), Holt-Winters, sinir ağı otoregresyonu (NNAR), BSTS ve hibrit bir yöntem olmak üzere toplam altı farklı yöntem ile oluşturulan modellerin artıklarını incelemişlerdir. Tüm modeller zaman serisine yeterli uyum göstermesine rağmen MAPE ölçütüne göre BSTS yönteminin performansının daha iyi olduęu görülmüştür.

Imanaka ve ark. [46], dışsal deęişkenler eklenerek zaman serisi olmayan verilerde de kullanılabilen, LSTM'nin geliştirilmiş hali olan LSTMX yöntemini sunmuşlardır. Giden/gelen uçuşlar (0 veya 1), hava yolu şirketi, kalkış tarihi, kalkış saati ve rezervasyon sınıfı (A'dan Z'ye) deęişkenlerini kullanarak uçak bileti talebinin tahmininde, sundukları LSTMX ve SARIMAX yöntemlerinin performanslarını karşılaştırmışlardır.

Arı [47], Türkiye'de bulunan üç havalimanının 2007 ve 2019 yılları arasındaki aylık yolcu sayılarını analiz etmiştir. Tez çalışmasında hareketli ortalama, üstel düzeltme, regresyon analizi, Holt'un doğrusal eğilim yöntemi, yapay sinir ağı ve bu yöntemlerin mevsim etkisi arındırılmış modellerini uygulayan Arı, yöntemler arasında en iyi performans gösteren modelin yapay sinir ağı olduğunu gözlemleyerek yapay sinir ağı ile gelecek 132 aya yönelik yolcu sayısı tahmini oluşturmuştur.

Havacılık sektöründe talep tahmini konusunda yapılan çalışmalar Tablo 3.1’de özetlenmiştir.

Tablo 3.1. Havacılık sektöründe talep tahmini literatür taraması

Çalışmanın Yazarı	Yıl	Çalışmanın Konusu	Yöntem ve Araçlar
Ba-Fail vd.	2001	Uluslararası hava yolculuğu talebinin tahmin edilmesi	Regresyon
Erdem I.	2012	Havalimanlarının 5 yıllık iç hat yolcu değerlerinin tahmin edilmesi ve havalimanı kapasite kontrolü	AR, ARMA
Ozan C. vd.	2014	Hava yolu yolcu talebinin gelir ve jet yakıtı fiyatlarına bağlı olarak modellenmesi	İndeksleme
Gürler H.	2015	Havalimanlarının etkinliğinin tahmin edilmesi	Veri zarflama analizi, yapay sinir ağları
Srisaeng vd.	2015	Avustralya'nın iç hat yolcu talebinin modellenmesi	Genetik algoritma (GAPAXD, GARPXSDE)
Küçükyılmaz vd.	2016	Eskişehir ilindeki hava yolu yolcu potansiyelinin belirlenmesi	Karar ağacı
Phyoe vd.	2016	Ekonomik değişkenler ile hava yolu talebi arasındaki ilişkinin analiz edilmesi	ARIMA, ARIMAX
Aladağ A.O.	2016	Hava yolu yolcu ve ikram talebinin belirlenmesi	Naive, üstel düzeltme, ARIMA
İlgün D.	2016	Hava kargo pazar payının tahmin edilmesi	Winters, yapay sinir ağları
Koç İ.	2017	İç hat hava yolu yolcu talebinin tahmin edilmesi	Yapay sinir ağları
Dantas vd.	2017	Kısa ve orta vadeli hava yolu yolcu talebinin modellenmesi	Bagging Holt Winters, SARIMA, Holt Winters, üstel düzeltme
Efendigil ve Eminler	2017	Hava yolu taşımacılığında tahmine dair literatür araştırması ve tahmin yöntemlerinin karşılaştırılması	Yapay sinir ağları, ANFIS, regresyon
Kalathilparmbil ve Şahin	2019	Uçak, yolcu ve yük trafik sayılarının tahmin edilmesi	En küçük kareler
Yazgan vd.	2019	Müşteri taleplerini tahmin ederek geliri maksimize eden bilet fiyatının bulunması	En küçük kareler, Poisson regresyonu, destek vektör makineleri
Wang ve Gao	2020	Petrol fiyatları ve hava yolu kazançlarındaki ilişkinin araştırılması	Regresyon

Madhavan vd.	2020	Hava yolu yolcu ve hava kargo talebinin tahmin edilmesi	ARIMA, BSTS
Al-Sultan vd.	2021	Havalimanı hava yolcusu sayısının tahmin edilmesi	ARIMA, üstel düzeltme, Holt-Winters, NNAR, BSTS, hibrit yöntem
Imanaka vd.	2021	Uçak bileti talebinin tahmin edilmesi	LSTMX, SARIMAX
Arı D.	2023	Havalimanı yolcu sayısının tahmin edilmesi	Hareketli ortalama, üstel düzeltme, regresyon, Holt'un doğrusal eğilim yöntemi, yapay sinir ağları ve yöntemlerin mevsim etkisi arındırılmış modelleri

Tablo 3.1'deki çalışmalar incelendiğinde 2001 ve 2023 yılları arasında talep tahmininde çoğunlukla geleneksel zaman serisi yöntemlerinin kullanıldığı görülmektedir. Bununla birlikte son yıllarda makine öğrenmesi yöntemi dahil edilen ve sonuçlarını geleneksel yöntemler ile karşılaştıran çalışmalarda artış olduğu gözlemlenmiştir.

3.2. COVID-19 ve Havacılık Sektörü Konusunda Yapılan Çalışmalar

2019 yılında ortaya çıkarak tüm havacılık sektörüne büyük bir şok yaşatan ve mevcut sistemleri alt üst eden COVID-19 salgını sektör çalışanları kadar araştırmacıların da ilgisini kısa sürede üzerine ve sektöre çekmiştir. Bununla birlikte, araştırmacılar tarafından kriz dönemi ve kriz dönemi sonrası ile ilgili birçok kalitatif ve kantitatif çalışma yapılmıştır.

COVID-19 pandemisinin etkilerini göz önüne alarak havacılık sektörüne yönelik ilk niteliksel tahminleme çalışmalarından birini oluşturan Günay ve ark. [48], senaryo analizi yöntemini kullanarak COVID-19'un Türkiye'ye gelen yabancı ziyaretçi sayısı üzerindeki dolaylı etkilerini incelemeyi amaçlamışlardır. Günay ve ark., iki adet alternatif senaryo ve her senaryoda sınırların kapatılma sürelerinin değiştiği farklı alternatifler üzerine çalışmışlardır. Bu senaryolardan birincisi; turizm talebindeki düşüş oranının her ay sabit kaldığı, ikincisi ise talepteki düşüşün aralık ayına kadar sabit bir oranla düzeleceğidir. Elde ettikleri sonuçlara göre turizm talebindeki düşüş oranının sınırların kapalı kalma süresine bağlı olarak %5 ile %53 aralığında olması beklenmektedir.

Iacus ve ark. [49], 2010 ve Ekim 2019 aralığındaki hava trafik verilerine farklı senaryolar uygulayarak Kasım 2019 ve Aralık 2020 tarih aralığındaki hava yolcu hacmini Poisson aracılığıyla tahmin etmeye çalışmışlardır. Aynı zamanda COVID-19'un yaşatacağı sosyal etkiyi de hesaplayan Iacus ve ark., veri setine farklı senaryolar uygulamışlardır. Bu senaryolar arasında hiçbir uçuşun ya da rotanın kesintiye uğramadığı basit tahmine dayanan senaryoyla birlikte, rotaların ve uçuşların azaldığı birbirinden farklı kötü durum senaryoları da bulunmaktadır.

Cheong ve ark. [50], elektronik tablo modeli kullanarak ülkelere göre COVID-19 iyileşme oranlarını ve buna bağlı olarak ülkelerin kısmi açılış tarihlerini tahmin etmişlerdir. Aşıların Aralık 2022'de geniş çapta kullanılabilir hale geleceğini ve bir sene sonrasında ise ülkelerin tam açılma konumunda olacağını varsayarak yolcu talebi modelini oluşturmuşlardır. Modelleri oluştururken 2020 yılı Mart ve Ekim ayları arasındaki veri setini kullanmışlardır. Singapur Hava Yolları'nın 2021-2025 yılları arasındaki toplam kârını tahmin eden Cheong ve ark., 2025 yılında bile COVID öncesi seviyeye ulaşamayacağını ve kâr oranlarının aşı çıkış tarihlerine duyarlı olduğunu ifade etmişlerdir.

Truong [51], ABD'deki iç ve dış hat uçuşlarının sayılarını tahmin etmek amacıyla 2020 yılı Mart ve Aralık ayları arasındaki veri setini kullanmıştır. Çalışmada değişken olarak; günlük seyahat edenlerin sayısı, mesafelerine göre seyahat sayıları, Haftalık Ekonomik Endeks (HEE), günlük bildirilen yeni COVID-19 vaka, test, ölüm ve hastaneye yatış sayıları, yurt içi ve yurt dışı seyahat kısıtlamaları kullanılmıştır. Truong, yapay sinir ağları ile modelleri oluşturmuş ve sinir ağını belirlemede her bir değişkenin önem derecesini tahmin etmek için bir duyarlılık analizi gerçekleştirmiştir. İç hat uçuşlarda en önemli değişkenlerin HEE, 50 ile 250 mil arası yolculuklar ve yeni vakalar olduğunu; en az önemli değişkenlerin, günlük test sayısı ve mesafesi 500 milden uzak olan yolculuklar olduğunu belirlemiştir. Dış hat uçuşlarda ise en önemli değişkenlerin, HEE, günlük vaka ve test sayıları, 100 ile 250 mil arasındaki yolculuklar ve uluslararası kısıtlamalar olduğu görülmektedir. Bununla birlikte en az öneme sahip değişkenin ise 500 milden uzak olan yolculuklar olduğu görülmüştür. Ayrıca Truong, simülasyon modellerini kullanarak aşılama hızları ve seyahat kısıtlamaları üzerine oluşturduğu farklı senaryoları da incelemiştir.

Li ve ark. [52], hava yolu yolcularını; yaş, seyahat amacı, sadakat programına üyelik ve uçuş sürelerine göre farklı segmentlere ayırarak her segmente ait talebi belirlemeyi amaçlamışlardır. 1 Haziran 2018 ile 31 Mayıs 2020 tarihleri arasındaki veri setini kullanarak iki senaryo simüle eden Li ve ark., ilk senaryoda yolcuların geçmiş davranış özelliklerini gösterdiğini ve pandeminin olmadığını, ikinci senaryoda ise seyahat kısıtlamalarının olduğunu ve belirli rotaların kullanılamaz hale getirildiğini, bununla birlikte yolcuların davranış özelliklerinin aynı kaldığını varsaymışlardır.

Gudmundsson ve ark. [53], hava yolcu ve kargo taşımacılığının ekonomik şoklara tepkisini inceleyerek COVID-19 sürecinde bölgesel olarak hava trafiğinin toparlanma süresini tahmin etmeyi amaçlamışlardır. GYİH ve petrol fiyatlarına dayalı olarak oluşturdukları ARIMAX modellerine, ekonomik şokların yaşandığı yılları dummy değişken olarak eklemişlerdir. Bu değişken yıkıcı olayların (örneğin 9/11 saldırısı ya da 2008 kredi krizi) yaşandığı yıllarda 1; aksi halde 0 değerini almaktadır. Elde ettikleri sonuçlar, hava taşımacılığının 2022-2023 yılları arasında 2019 seviyesine ulaşabileceğini göstermiştir.

COVID-19 pandemisi döneminde havalimanlarının etkinlik değişimlerini analiz eden Alnıpak ve Apak [54], 2019 yılı verilerine göre Türkiye'deki toplam yolcu trafiğinin %95,22'sini oluşturan 16 ilin havalimanını incelemişlerdir. Geçmiş yıllara ait yolcu ve uçak trafiği istatistiklerini kullanarak 2020 yılının değerlerini Double Exponential Smoothing (Çift Üstel Düzeltme) yöntemi ile tahmin etmişlerdir. 2015-2020 yılları arasındaki değişimin analiz edildiği çalışmada, pandemi döneminin etkilerinin görülebilmesi için 2020 yılına ait tahmini değerler ve gerçek veriler kullanılarak karşılaştırma yapılmıştır. Elde edilen sonuçlara göre, illerde yıllık ortalama %6 verimlilik artışı beklenirken, pandemi nedeniyle %41'lik düşüş gerçekleşmiştir.

Nurmi [55] çalışmasında, tahmin yöntemlerinin kriz dönemlerindeki başarılarını karşılaştırmayı ve COVID-19 ile ilgili değişkenlerin model üzerindeki etkisini incelemeyi amaçlamıştır. Nurmi, Ocak 2010 - Eylül 2020 arası aylık ve Ocak 2016 - Aralık 2020 arası günlük havalimanı yolcu trafiği verilerini kullanarak, pandemi öncesi ve pandemi dönemindeki tahminleme yöntemlerinin performanslarını araştırmıştır. Kriz öncesi verilerde SARIMA, TBATS, Facebook's Prophet ve Yapay Sinir Ağları yöntemlerinin başarılı sonuç gösterdiğini, tahmin periyodunun artmasıyla hata değerinin azaldığını gözlemlemiştir. Pandemi döneminde ise bu yöntemler başarılı sonuçlar vermemiştir. Nurmi ayrıca, uluslararası seyahat kontrollerini ikinci bir değişken olarak yöntemlere eklemiş ve yöntemlerin anlamlı sonuçlar verdiğini ifade etmiştir.

Pandeminin neden olduğu hava yolu yolcu kaybı miktarını tahmin etmek amacıyla Barczak ve ark. [56], pandemi öncesi trende dayalı talep tahmini ile pandemi sırasında taşınan yolcu sayısı arasındaki farkı incelemiştir. AB ülkelerinin havalimanlarının 2015-2019 tarih aralığı verileri ile 2020 ve 2021'in her bir çeyreği için bir yolcu trafiği tahmini hazırlayarak gerçek verilerle karşılaştırmışlardır. Bununla birlikte, incelenen havalimanlarında COVID-19 salgını nedeniyle hizmet verilen yolcu sayısında hesaplanan kayıpların büyüklüğünün gösterilmesini mümkün kılmışlardır.

Rabbouch ve ark. [57], Varyasyonel Mod Ayırıştırma (VMD), Uzun Kısa Süreli Bellek (LSTM) ve ARIMA yöntemlerini entegre eden hibrit bir yöntem geliştirerek COVID-19 döneminde gerçek dünya verileri üzerinde test etmeyi amaçlamışlardır. 2019-2022 tarih aralığındaki verilere yeni hibrit yöntemi uygulayarak iki farklı yöntem ile karşılaştırmışlar ve modelin verimliliğini test etmişlerdir.

COVID-19 ve havacılık sektörü konusunda yapılan çalışmalar Tablo 3.2’de özetlenmiştir.

Tablo 3.2. COVID-19 ve havacılık literatür taraması

Çalışmanın Yazarı	Yıl	Çalışmanın Konusu	Yöntem ve Araçlar
Günay vd.	2020	COVID-19'un Türkiye'ye gelen yabancı ziyaretçi sayısı üzerindeki dolaylı etkilerinin tahmin edilmesi	Senaryo analizi
Iacus vd.	2020	Hava yolcu hacminin ve COVID-19'un sosyal etkisinin tahmin edilmesi	Poisson regresyonu
Cheong M. vd.	2021	Yolcu ve kargo talebinin tahmin edilmesi, gelir, gider ve karın tahmin edilmesi, optimum uçak sayısı için optimizasyon modelinin oluşturulması	Elektronik tablo
Truong D.	2021	Orta ve uzun vadede, yurtiçi ve yurtdışı hava yolculuğu talebinin tahmin edilmesi	Monte Carlo, yapay sinir ağları, duyarlılık analizi
Li X. vd.	2021	Yolcuların farklı segmentlere ayrılması ve farklı senaryolarda her segmente ait talebin belirlenmesi	SARIMA, TBATS
Gudmundsson vd.	2021	Yolcu ve kargo taşımacılığı için iyileşme döneminin tahmin edilmesi	ARIMAX
Alnıpak ve Apak	2021	Havalimanlarının COVID-19 öncesi ve sonrası etkinlik değişimlerinin analiz edilmesi	MTFV Index, çift üstel düzeltme
Nurmi N.	2021	Pandemi dönemi hava yolu yolcu trafiğinin tahmin edilmesi	ARIMA, TBATS, Facebook’s Prophet, yapay sinir ağları
Barczak vd.	2022	COVID-19'un yarattığı hava yolu yolcu kaybı miktarının tahmin edilmesi	Fourier analizi
Rabbouch vd.	2022	Hibrit yöntemin COVID-19 dönemi verilerinde test edilmesi	VMD-LSTM-ARIMA hibrit yöntemi

Tablo 3.2 incelendiğinde COVID-19'un DSÖ tarafından küresel salgın ilan edildiği 2020 tarihinden itibaren çalışmaların uygulanmaya ve yayımlanmaya başladığı, günümüzde ise hala bu salgının etkilerinin test edildiği görülmektedir. Araştırmacılar hava yolu ve havalimanı etkinliklerinin değişimlerini incelemekte ve bu büyük krize ve kriz sonrası toparlanmaya çözüm yolları aramaktadır. Çalışmalarda kullanılan yöntemlere bakıldığında ise son yıllarda makine öğreniminin yaygınlaşmasıyla birlikte kullanılan yöntemlerin de bu yöne kaydığı görülmektedir.

3.3. Filo Atama Konusunda Yapılan Çalışmalar

Filo atama problemi hava yolu işletmesinin karlılığını doğrudan etkileyen bir planlama sürecidir. Filo atama sürecinin hassasiyetinin yanı sıra yüzlerce uçak ve uçuş noktası barındırabilen problemlerde problemin büyüklüğü sebebiyle optimum çizelgenin oluşturulmasında zorluklar yaşanmaktadır. Araştırmacılar çeşitli çalışmalarla problemin optimum çözüm yollarını araştırmıştır.

Sherali ve ark. [58], filo atama problemi için geliştirilen temel ve gelişmiş modelleri tanıtan bir çalışma sunmuşlardır. Sherali ve ark. çalışmalarında, filo atama problemlerinin uçak bakım rotalama ve mürettebat çizelgeleme gibi diğer havayolu operasyonel planlama süreçleriyle entegrasyonunun incelemesini yapmışlardır. Ayrıca güncellenen taleplerle dinamik filo atama mekanizmasını incelemiş, çözüm yaklaşımlarının etkinliklerini araştırmışlardır.

Sarsenov [59], İstanbul kalkışlı Türk Hava Yolları'nın uçuş verilerini kullanmış ve maliyeti minimum yapan filo atama modelini kurmuştur.

Pilla ve ark. [60], her güzergâh için talebin ortalamasının ve varyansının bilindiğini varsayarak iki aşamalı haftalık filo atama modeli oluşturmuşlardır. Ardından model çözümü için yeni bir yaklaşım öneren Pilla ve ark., modelin hesaplama süresini 8.68 günden 5.80 güne indirgemeyi başararak önerdikleri modelin verimliliğini ortaya koymuşlardır.

Li ve Tan [61], gelir maksimizasyonunu amaçlayan filo atama modelini kurmuşlardır. Li ve Tan, model çözümü için genetik algoritma yöntemini tercih etmişlerdir.

Şafak ve ark. [62], talep ve seyir süresi belirsizliği altında uçuş zamanlaması, uçuş ve rotalama kararlarını belirleyen üç aşamalı stokastik programlama modeli oluşturmuşlardır. Şafak ve ark. aynı zamanda uyguladıkları modelde seyir dışı gecikmeleri telafi etmek için hızlı uçuş ve fazla yakıt yakma ya da yavaş uçarak yakıt tasarrufu sağlama kararını vermeye çalışmışlardır.

Liu ve ark. [63], hava yolu stokastik filo atama probleminin çözümü üzerine iki aşamalı bir model geliştirmişlerdir. Yolcu taleplerini rassal olarak ele alan Liu ve ark., belirli bir riskten kaçınma seviyesinde beklenen toplam karı maksimize etmeyi amaçlamışlardır.

Polat [64], Türk Hava Yolları'nın gerçek verilerini kullanarak hibrit bir filo atama modeli geliştirmiştir. İşletme masraflarını ve yolcu kayıp masraflarını modele ekleyen Polat, örüntü arama, kısıtlı doğrusal olmayan optimizasyon ve genetik algoritma yöntemlerini kullanarak maliyeti minimize eden modeli oluşturmaya çalışmıştır.

Ünal ve ark. [27], filo atama ve uçak rotalama problemlerini tek modelde birleştirmişlerdir. Ünal ve ark. 710 uçuş ve 170 uçağı kapsayan iki günlük çizelge oluşturmuş ve şirket tarafından kullanılan mevcut yöntemle göre %36 daha iyi çözüm üretmişlerdir.

İnanç [65], yapay sinir ağları ile Türk Hava Yolları'nın filo atama probleminin çözümü üzerine çalışmıştır. Yolcu kayıp masrafı, tekrar alım oranı ve uçak denge kısıtları dahil altı girdi ile yapay sinir ağı modelini oluşturan İnanç, çıktı olarak hava yolu filolarını tahminlemiştir.

Liu ve ark. [66], belirsiz talep ve yakıt miktarını dikkate alan ve geliri maksimize etmeyi hedefleyen bir filo atama modeli geliştirmişlerdir. Riskten kaçınan bakış açısıyla oluşturdukları iki aşamalı stokastik modeli örneklem ortalama yaklaşımı yöntemi ile çözmüşlerdir.

Glomb ve ark. [67], orta vadeli uçak atamaları ve kısa vadeli planlanabilir dönüş süreçlerini otomatikleştirmek için filo atama, kuyruk atama ve uçak çevrim sürecini dikkate alan bir model geliştirmişlerdir. Glomb ve ark. mevcut çözücülerin böyle büyük bir problemde yetersiz kaldığını söyleyerek yeni bir ayrıştırma yöntemini öne sürmüşlerdir.

2000 yılı ve sonrası, özellikle güncel çalışmalar dikkate alınarak filo atama konusunda yapılan çalışmalar incelenmiştir. İncelenen çalışmalar Tablo 3.3'te özetlenmiştir.

Tablo 3.3. Filo atama problemi literatür taraması

Çalışmanın Yazarı	Yıl	Çalışmanın Konusu	Yöntem ve Araçlar
Sherali ve ark.	2006	Filo atama problemi için geliştirilen modellerin tanıtılması	Doğrusal programlama
Sarsenov B.	2011	Maliyeti minimum yapan filo atama modelinin kurulması	Doğrusal programlama
Pilla ve ark.	2012	Haftalık filo atama modelinin kurulması ve model çözümü için yeni bir algoritma önerilmesi	Stokastik doğrusal programlama
Li ve Tan	2013	Hava yolu filo atama modelinin geliştirilmesi	Genetik algoritma
Şafak ve ark.	2018	Talep ve seyir süresi belirsizliği altında uçuş zamanlaması, uçuş ve rotalama kararlarını veren modelin oluşturulması	Karma tam sayılı stokastik doğrusal olmayan programlama
Liu ve ark.	2019	Rassal yolcu talepleri ile stokastik filo atama modelinin geliştirilmesi	Karma tam sayılı stokastik doğrusal programlama
Polat F.	2019	Türk Hava Yolları verileri ile maliyeti minimize eden filo atama modelinin oluşturulması	Örüntü arama, kısıtlı doğrusal olmayan optimizasyon ve genetik algoritma

Ünal ve ark.	2021	Filo atama ve uçak rotalama problemlerini tek bir sistemde birleştiren ve toplam maliyeti minimize eden modelin oluşturulması	Karma tam sayılı doğrusal programlama
İnanç Y.	2022	Filo atama probleminin çözülmesi	Yapay sinir ağları
Liu ve ark.	2023	Belirsiz yolcu talebi ve yakıt miktarını dikkate alan filo atama modelinin geliştirilmesi	Stokastik doğrusal programlama
Glomb ve ark.	2023	Filo atama, kuyruk atama ve uçak çevrim sürecini dikkate alan bir model geliştirilmesi	Karma tam sayılı doğrusal programlama

Tablo 3.3'teki çalışmalar incelendiğinde çalışmaların büyük çoğunluğunun belirsiz yolcu taleplerini dikkate almadığı görülmüştür. Yolcu taleplerini kullanan çalışmalarda önceden belirli satış miktarlarının kullanıldığı, yalnızca sayılı çalışmada ise rassallığın senaryolar ile modellendiği görülmüştür.

21. yüzyılda salgın hastalıklarla birlikte savaşlar, terör saldırıları, ekonomik krizler ve petrol fiyatlarının dalgalanması da işletmeleri hazırlıksız yakalamaktadır. Böyle istikrarsız ortamda işletmelerin rakiplerinden önde olmaları için krizlere hızlı bir şekilde uyum sağlamaları gerekmektedir.

Bu çalışmanın literatüre katkı yapacağı en önemli noktalar şu şekilde sıralanabilir:

- Bu çalışma ile, kriz ortamında hava yolu operasyonlarının planlanması ve çizelgelenmesi için hava yolu yöneticilerine yol gösterilmesi amaçlanmaktadır. Bu amaçla veri setinin hazırlanması, tahmin yöntemlerinin uygulanması ve karşılaştırılması, geleceğe yönelik öngörü ve uçak çizelgesinin oluşturulması aşamalardan meydana gelen bir karar destek sistemi oluşturulacaktır. Bu çalışma, bütünlük olarak hem tahminleme hem planlama yapan bir karar destek sistemi önerilmesi ile literatürdeki çalışmalardan ayrılmaktadır.

- İncelenen çalışmalarda, pandemi dönemi sırasınca tahminleme yapılabilmesi için yeterli veri elde edilememesinden kaynaklı olarak pandemi-öncesi verilerin de kullanıldığı görülmüştür. Bu çalışmada ise yalnızca pandemi verilerini kapsayan 2020-2023 yılları arasındaki günlük yolcu sayısı verileri kullanılacaktır. Bu açıdan da COVID-19 salgınının havacılık sektörü üzerindeki etkisini görebilmemizi sağlayacak çalışmalardan biri olarak literatüre katkı sağlayacaktır.



4. TALEP TAHMİN YÖNTEMLERİ

Talep tahmini; işletmelerin mal veya hizmet çıktılarının tüketici tarafından tercih edilme ve satın alınma miktarlarının öngörülmesine denilmektedir. Talep tahmini işletmelerde planlama prosedürlerinin önemli bir adımıdır. Talebin öngörülmesi ile satın alma, üretim, satış, pazarlama ve nakliye gibi çeşitli faaliyetlerin planlamasının ve hazırlığının yapılması da mümkün olmaktadır.

Bir talep tahmin süreci dört adımdan oluşmaktadır. Bunlar;

1. Veri toplama
2. Talep tahmin periyodunun belirlenmesi
3. Tahmin yönteminin seçilmesi
4. Tahmin sonuçlarının geçerliliğinin araştırılmasıdır.

Talebin tahmin edilmesi sürecinde kullanılan birçok yöntem bulunmaktadır. Bu yöntemler kalitatif (nitel) tahmin yöntemleri ve kantitatif (nicel) tahmin yöntemleri olarak ikiye ayrılmaktadır.

4.1. Kalitatif (Nitel) Tahmin Yöntemleri


Kalitatif (nitel) tahmin yöntemleri; bilimsel verilere dayanmayan, kişilerin görüşlerine ve tecrübelerine dayanan yöntemlerdir. Literatürde en sık kullanılan kalitatif tahmin yöntemleri;

- Delphi Tekniği
- Pazar Araştırması ve
- Uzman Görüşleri tekniğidir.

Kalitatif teknikler genellikle sayısal verilere ulaşamadığı durumlarda tercih edilmektedir. Bununla birlikte, kalitatif teknikler sayısal analizler yerine insan görüşlerine dayandığı için gerçek verilerden daha uzak ve daha düşük bir tahmin performansı sunmaktadırlar [68].

4.2. Kantitatif (Nicel) Tahmin Yöntemleri

Kantitatif tahmin yöntemleri; bilimsel verilere ve istatistiksel analizlere dayanan yöntemlerdir. Sayısal verilere ulaşılabilen ve gerçek değerlere yakın bir tahmin elde etmek istenildiği zaman tercih edilmektedir. En sık kullanılan nicel yöntemler zaman serileri analizi, yapay zekâ ve sezgisel algoritmalar, nedensel yöntemler başlıkları altında Şekil 4.1’de verilmiştir.



Şekil 4.1 Kantitatif tahmin yöntemlerinin sınıflandırılması [55]

Zaman serileri analizi; bir değişkenin geçmiş gözlem değerleri analiz edilerek belirli kurallar altında gelecekteki değerlerinin tahmin edildiği geleneksel tahmin yöntemleridir. Zaman serileri analizinde kullanılan geleneksel yöntemlerden en çok tercih edilenleri; üstel düzeltme, hareketli ortalamalar ve Box-Jenkins metodudur. Nedensel yöntemler ise tahmin edilecek değişken ile başka bir değişken arasındaki ilişkinin analiz edildiği, bu ilişkinin tanımlandığı ve ilgili değişkenin tahmininde kullanıldığı yöntemlerdir [68]. Regresyon analizi ve ekonometrik modeller en sık kullanılan nedensel yöntemlerdir. Bunlarla birlikte, geleneksel tahmin yöntemlerinden ayrılan makine öğrenimi yöntemleri de bulunmaktadır. Yapay sinir ağları, destek vektör makineleri ve genetik algoritma ise bu tahmin yöntemlerine örnek verilebilir.

4.2.1. Zaman Serileri Analizi

Bir değişkenin zaman içerisinde belirli aralıklarla aldığı değerlerin grubuna zaman serisi denilmektedir. Yıllık yağış miktarı, aylık enflasyon oranları, günlük brent petrol fiyatları, saatlik üretim miktarları gibi çeşitli zaman aralıklarında ve farklı değişken türleri ile zaman serileri oluşturulabilmektedir. Zaman serileri; değişkenlerin zaman içerisindeki değişimlerini inceleme, gelecekte belirli bir tarih aralığındaki değerlerini tahmin etme, diğer zaman serileri ile aralarındaki ilişkiyi inceleme gibi amaçlarla oluşturulmakta ve analiz edilmektedir [69].


Zaman serileri analizi kavramı ilk olarak George E. P. Box ve Gwilym M. Jenkins'in 1970 yılında yayınladığı "Time Series Analysis: Forecasting and Control" kitabında ortaya konularak yöntem haline getirilmiş ve kullanılmaya başlanmıştır [69]. 1980'li yıllarda ise zaman serileri hakkında çeşitli yöntemler geliştirilmiş ve zaman serisi kavramının önemi artarak kullanımı yaygınlaşmıştır [69].

Zaman serisi analizinde ilk yapılması gereken zaman serisinin özelliklerinin belirlenmesidir. Özelliklerinin belirlenmesinin ardından çeşitli amaçlar doğrultusunda ekonometrik modeller kullanılmaktadır.

Zaman serileri dört bileşenden oluşmaktadır. Bileşenler Denklem 4.1'de verilmiştir.

$$Y_i = T + C + S + I \quad (4.1)$$

Denklemdaki T ; trend bileşenini, C ; konjonktürel hareketleri, S ; mevsimsel dalgalanmalar ve I , düzensiz hareketleri ifade etmektedir [70]. Bir zaman serisi bu bileşenlerden birkaçını ya da tamamını içerebilmektedir [70]. Bileşenlerin görselleştirilmesi Şekil 4.2'de yer almaktadır.



Şekil 4.2. Zaman serisi bileşenleri [69]

Trend bileşeni bir zaman serisinin, zaman içindeki eğilimini veren doğrusal bir fonksiyondur. Bu eğilim uzun bir dönemde fark edilmektedir. Bununla birlikte zaman serisi artan ya da azalan trende sahip olabilir [70]. Konjonktürel hareketler bir eğri etrafında gelişen uzun dönemli dalgalanmalardır [69]. Mevsimsel dalgalanmalar ise zaman serisinin periyodik hareketlerini ifade etmektedir. Yıllık, aylık, haftalık ya da günlük mevsimsel dalgalanmalar görülebilir. Düzensiz hareketler; zamandan bağımsız gelişen, kriz ortamlarında görülebilen, öngörülemeyen bileşenlerdir. Trend, mevsimsel dalgalanmalar ve konjonktürel hareketler zaman serisinin deterministik sürecini gösterirken düzensiz hareketler stokastik kısmını göstermektedir ki bu nedenle düzensiz hareketler tahmin edilemezler [69].

Zaman serisine iyi uyum saęlayan bir modelleme yapabilmek için öngörü yapmadan önce zaman serisinin bileşenlerinin incelenmesi gerekmektedir. Zaman serisinin içerdęi bileşenlere göre farklı modeller uygulanabilmektedir. Bununla birlikte analizden önce serinin duraęan olup olmama durumunun da belirlenmesi iyi bir öngörü için büyük bir önem arz etmektedir.

4.2.1.1. Zaman Serilerinde Duraęanlık

Zaman serilerinin ortalama, varyans ve kovaryansının zaman içinde sabit olma durumuna zaman serisinin duraęan olma durumu denilmektedir [70]. Duraęan sürecin dağılımı zamanla aynı kalmakta, olasılık yapısı zamana baęlı deęişmemektedir [71].

Zaman serisi analizlerinde yapılan en genel hata; analiz öncesinde zaman serisinin duraęanlığının incelenmemesidir. Bununla birlikte çoęu zaman serisi duraęan deęildir ve analiz öncesi duraęanlaştırılması gerekmektedir. Duraęanlık durumu incelenmeden yapılan analizler yanlış sonuçlar vermektedir.

Zaman serisinde trend etkisinin olması ve varyansın ortalama ile artması durumunda zaman serisinin farkının alınarak dönüşüm yapılması gerekmektedir [71]. Benzer şekilde, mevsimsel büyüklüğün ortalama ile artması durumunda da mevsim etkisini kaldırmak için dönüşüm önerilmektedir [71]. Duraęan olmayan zaman serilerinin birinci ve ikinci dereceden ve mevsimsel fark alma işlemlerinin matematiksel formülleri denklemlerde verilmiştir [70].

Zaman serisinin birinci farkı

$$\Delta X_t = X_t - X_{t-1} \quad (4.2)$$

Zaman serisinin ikinci farkı

$$\Delta^2 X_t = \Delta X_t - \Delta X_{t-1} \quad (4.3)$$

Aylık zaman serisinin mevsimsel farkı

$$\Delta_{12} X_t = X_t - X_{t-12} \quad (4.4)$$

4.2.1.2. Box-Jenkins Yöntemi

Talep tahmininde en sık kullanılan yöntemlerden biri de George E. P. Box ve Gwilym M. Jenkins'in 1970 yılında önerdiği Box-Jenkins yöntemidir. Box-Jenkins yönteminin temel mantığı; alternatif modeller arasından en az parametre içeren en iyi modelin seçilerek zaman serisine uygulanmasıdır [70].

Box-Jenkins yönteminde üç model mevcuttur. Bunlar; Otoregresif (AR) süreci, Hareketli Ortalama (MA) ve iki modelin birleşiminden meydana gelen Otoregresif Hareketli Ortalama (ARMA) sürecidir [70]. Üç modelin yanı sıra ARMA modelinin logaritmik farkının alınması ile Otoregresif Entegre Hareketli Ortalama (ARIMA) süreci, ARIMA modelinin mevsimsel parametre içermesi durumunda ise Mevsimsel ARIMA (SARIMA) modeli oluşmaktadır. Kısaca durağan serilerde AR, MA ve ARMA modelleri, durağan olmayan serilerde ise ARIMA modelleri uygulanmaktadır. Aşağıda AR, MA, ARMA ve ARIMA başlıkları altında model yapılarından bahsedilmiştir.

a) AR (p) Modeli

Zaman serilerinde yalnızca otoregresif sürece sahip olan modeller AR (p) olarak adlandırılmaktadır. AR (p) modellerinde p ; otoregresif mertebesini belirtmektedir. Otoregresif süreç yalnızca durağan zaman serilerinde uygulanmaktadır. p . mertebeden AR (p) modeli Denklem 4.5 ile ifade edilmektedir.

$$Y_t = \delta + \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \dots + \alpha_p Y_{t-p} + \varepsilon_t \quad (4.5)$$

Denklemdaki δ ; sabit terimi, α otoregresif parametreleri, ε_t ise beyaz gürültü hata terimini simgelemektedir [69].

b) MA (q) Modeli

Zaman serilerinde yalnızca hareketli ortalama sürecine sahip olan modeller MA (q) olarak adlandırılmaktadır. MA (q) modellerinde q ; hareketli ortalama mertebesini belirtmektedir. Hareketli ortalama süreci de otoregresif süreç gibi yalnızca durağan zaman serilerinde uygulanmaktadır. q . mertebeden MA (q) modeli Denklem 4.6 ile ifade edilmektedir.

$$Y_t = \mu + \beta_t \varepsilon_{t-1} + \dots + \beta_q \varepsilon_{t-q} + \varepsilon_t \quad (4.6)$$

Denklemdaki μ ; sabit terimi, β hareketli ortalama parametrelerini, ε_t ise beyaz gürültü hata terimini simgelemektedir [69].

c) ARMA (p, q) Modeli

Zaman serilerinde hem otoregresif hem de hareketli ortalama sürecine sahip olan modeller ARMA (p,q) olarak adlandırılmaktadır. ARMA (p,q) modellerinde p; otoregresif mertebesini, q ise hareketli ortalama mertebesini belirtmektedir. Otoregresif hareketli ortalama süreci yalnızca durağan zaman serilerinde uygulanmaktadır. ARMA (p,q) modeli Denklem 4.7 ile ifade edilmektedir.

$$Y_t = \delta + \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \dots + \alpha_p Y_{t-p} + \varepsilon_t + \beta_t \varepsilon_{t-1} + \dots + \beta_q \varepsilon_{t-q} \quad (4.7)$$

Denklemdaki δ ; sabit terimi, α otoregresif parametreleri, β hareketli ortalama parametrelerini, ε_t ise beyaz gürültü hata terimini simgelemektedir [69].

d) ARIMA (p, d, q) Modeli

Zaman serilerinde durağan olmayan ve farkı alınarak durağanlaştırılan ARMA (p,q) modelleri, ARIMA (p,d,q) modelleri olarak adlandırılmaktadır. ARIMA (p,d,q) modellerinde p; otoregresif mertebesini, d; serinin homojenlik mertebesini, q ise hareketli ortalama mertebesini belirtmektedir. ARIMA (p,d,q) modeli Denklem 4.8 ile ifade edilmektedir [72].

$$\phi(B) (1-B)^d Y_t = c + \theta(B) \varepsilon_t \quad (4.8)$$

Denklemdaki $\phi(B)$; otoregresif parametresini, $\theta(B)$; hareketli ortalama parametresini, ε_t ise beyaz gürültü hata terimini simgelemektedir [71]. ARIMA (p,d,q) modelinin öngörüsü Denklem 4.9 ile hesaplanmaktadır [71].

$$w_t = \phi_1 w_{t-1} + \phi_2 w_{t-2} + \dots + \phi_p w_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} + \delta \quad (4.9)$$

Denklemdaki w_t , d. mertebe farkı alınan durağan seriyi simgelemekte olup t. dönem öngörüsünü vermektedir.


Zaman serilerinde, mevsimsel bileşen içeren ARIMA (p,d,q) modelleri Mevsimsel ARIMA $(p,d,q)(P,D,Q)_s$ modelleri olarak adlandırılmaktadır. Mevsimsel ARIMA $(p,d,q)(P,D,Q)_s$ modellerinde P ; mevsimsel sürecin otoregresif mertebesini, D ; mevsimsel sürecin homojenlik mertebesini, Q ; mevsimsel sürecin hareketli ortalama mertebesini, s ise mevsimsellik periyodunu belirtmektedir. Mevsimsel ARIMA (SARIMA) modeli Denklem 4.10 ile ifade edilmektedir.

$$\phi(B) \Phi(B^s) (1-B)^d (1-B^s)^D y_t = c + \theta(B) \Theta(B^s) \varepsilon_t \quad (4.10)$$

Denklemdaki $\Phi(B^s)$ mevsimsel otoregresif parametresini, $\Theta(B^s)$ ise mevsimsel hareketli ortalama parametresini simgelemektedir [72].

4.2.1.2.1. Box-Jenkins Modelinin Kurulması

Box-Jenkins metodolojisinin temel mantığı olan alternatif modeller arasından en iyi modelin seçilmesi için “model kurma stratejisi” geliştirilmiştir [71]. Box-Jenkins yöntemi temel olarak 3 ana aşamadan meydana gelmektedir. Bu aşamalar model tanımlama, parametre tahmini ve teşhis kontrolüdür [73]. Şekil 4.3’te yöntemin akış şeması yer almaktadır.



Şekil 4.3. Box-Jenkins metodunun akış şeması [74]

Adım 1- Modelin Tanımlanması


Bir zaman serisi ile öngörü yapılabilmesi için zaman serisinin durağan olması gerekmektedir. Durağanlığın tanımsal olarak iki koşulu bulunmaktadır:

1. Zaman serisinin ortalama ve varyansının zamandan bağımsız olması, zamanın bir fonksiyonu olmaması gerekmektedir.
2. Kovaryansın geçmişten bağımsız olması gerekmektedir [71].

Serilerde durağanlık koşulunun sağlanıp sağlanmadığının kontrol edilebilmesi için çeşitli analiz yöntemleri mevcuttur.

a) Grafiksel Analiz

Durağanlık analiz yöntemlerinin ilki grafiksel analizdir. Grafiksel analiz yöntemi yalnızca gözleme dayanan, istatistiksel testlerin yapılmadığı bir metottur. Zaman serisinin grafiği incelenerek kesin bir yargıya varılamasa da durağanlık durumu hakkında bilgi edinmek mümkündür. Örneğin Şekil 4.4'teki grafikte durağan olmayan bir zaman serisi yer almaktadır. Grafiksel analizlerin istatistiksel testler ile desteklenmesi gerekmektedir.



Şekil 4.4. Durağan olmayan zaman serisi grafiği

b) Birim Kök Testi

Birim kök testi zaman serilerinde durağanlığı araştırmanın başka bir yöntemidir. Birim köke sahip zaman serisi durağan değildir ve durağanlaştırılması gerekmektedir. Literatürde çeşitli birim kök testleri mevcuttur. Bunların en sık kullanılanı Dickey ve Fuller tarafından ortaya konulan, Dickey-Fuller testi olarak da adlandırılan istatistiksel testtir. Dickey-Fuller testi birim kökün varlığını test ederken aşağıdaki hipotezi uygulamaktadır [69].

$$Y_t = \alpha_1 Y_{t-1} + \varepsilon_t \quad (4.11)$$

$H_0 : \alpha_1 = 1$ ise Y_t durağan değildir ve birim köke sahiptir

$H_1 : \alpha_1 < 1$ ise Y_t durağandır.

c) Otokorelasyon Fonksiyonu

Otokorelasyon fonksiyonu (ACF) durağanlık hakkında bilgi sağlayan önemli bir istatistiksel analizdir. Otokorelasyon fonksiyonu, farklı zamanlardaki gözlemler arasındaki ilişkiyi gösteren katsayılar olup, serinin komşu değerleri arasındaki korelasyonun derecesini ortaya koymaya yönelik uygulanmaktadır [71]. Otokorelasyon katsayısının yüksek bir değer alması, değişkenin geçmiş dönem gözlemlerine bağımlı olduğunu, düşük bir değer alması ise değişkenin geçmiş gözlemlerden bağımsız ve tesadüfi olduğunu göstermektedir [69]. *k-gecikmeli* otokorelasyon katsayısı Denklem 4.12 ile ifade edilmektedir.

$$p_k = \frac{\gamma_k}{\gamma_0} \quad (4.12)$$

Denklemdeki γ_k ; *k-gecikmeli* kovaryansı, γ_0 ise varyansı simgelemektedir [69].

Otokorelasyon katsayılarının *k-gecikmeleri* için çizilen grafiğine korelogram denilmektedir [69]. Korelogramlar incelenirken kullanılan bilgiler şu şekildedir:

1- p_k otokorelasyon katsayıları *k-gecikmeler* arttıkça hızla azalıyor ve eksenle kesişiyorsa bu durum serinin durağan olduğunun göstergesidir.

2- p_k otokorelasyon katsayıları *k-gecikmeler* arttıkça yavaş bir şekilde azalıyor ve eksenle ancak çok sayıda gecikme sonrasında kesişiyorsa bu durum serinin durağan olmadığının göstergesidir. Böyle bir durumda zaman serisinin farkının alınması gerekmektedir. Zaman serisinin farkının alınmasının ardından farkı alınan yeni seri üzerinden inceleme yapılmalıdır.

3- Farkı alınan zaman serisi 1. maddedeki durağanlık koşulunu sağlıyor ise serinin durağanlık derecesinin o ana kadarki alınan fark sayısı olduğuna karar verilir. Eğer ki sağlamıyorsa 2. maddeye geçilir ve 1. maddedeki koşul sağlanana dek farkı alınmaya devam edilir.

Otokorelasyon fonksiyonu yardımıyla serinin mevsimsel dalgalanmalar bulundurma durumunun da incelenmesi mümkün olmaktadır. Belirli periyodik aralıklardaki *k-gecikmelerde* p_k değerlerinde zirve görülüyorsa bu durum serinin mevsimsellik bileşenini barındırdığının göstergesidir. Aylık bir zaman serisinde $k=12,24,36..$ gibi 12 ay periyodunda zirve p_k değerleri görülüyorsa 12. mertebeden fark alınarak serinin durağan hale getirilmesi gerekmektedir [71].

Zaman serisinin durağanlık durumunun incelenmesinin ardından seriye uygulanacak sürecin belirlenmesi gerekmektedir. Otokorelasyon fonksiyonu hem serinin durağanlığının incelenmesinde hem de seriye uygulanacak sürecin belirlenmesinde kullanılmaktadır ancak model belirleme aşamasında otokorelasyon fonksiyonu ile birlikte kısmi otokorelasyon fonksiyonunun da kullanılması önerilmektedir. Kısmi otokorelasyon fonksiyonu otoregresif sürecin mertebesini belirlemede otokorelasyon fonksiyonu yetersiz kaldığı için kullanılmaktadır [71]. Kısmi otokorelasyon katsayıları Denklem 4.13 ile ifade edilmektedir [69].

$$p_{kj} = p_{k-1,j} - p_{kk} p_{k-1,j} \quad j = 1, 2, \dots (k-1) \quad (4.13)$$

Grafikler yardımıyla seçilen model, geçici model olarak isimlendirilmektedir. Bu aşamada durağanlık durumunun incelenmesinde olduğu gibi gerekliyse zaman serisinin farkının alınması gerekmektedir. Zaman serisinin farkının alınmasının ardından farkı alınan yeni seri incelenmelidir. Tablo 4.1’de model seçiminde AR, MA ve ARMA süreçlerinin otokorelasyon ve kısmi otokorelasyon grafiklerinin görünümünün özeti yer almaktadır.

Tablo 4.1. AR, MA ve ARMA sürecine ilişkin otokorelasyon yapısı [70]

Otokorelasyon Yapısı	Süreç
Otokorelasyon fonksiyonunda üssel azalma	AR(p) modeli
Kısmi otokorelasyon fonksiyonunda üssel azalma	MA(q) modeli

Otokorelasyon ve kısmi otokorelasyon fonksiyonunda üssel azalma	ARMA(p,q) modeli
Otokorelasyon ve kısmi otokorelasyon fonksiyonunda tüm değerler sıfır	Seri tesadüfi değişkendir
Belirli aralıklarla otokorelasyon ve kısmi otokorelasyon değerlerinin sıfırdan farklı olması (12., 24. değer gibi)	Mevsimsel otoregresif terim içerir
Otokorelasyon ve kısmi otokorelasyon değerlerinin sıfıra doğru azalmaması	Durağan değildir

Adım 2- Parametrelerin Belirlenmesi

Otokorelasyon ve kısmi otokorelasyon fonksiyonu grafikleri yardımıyla seçilen geçici modelin parametrelerinin belirlenmesi aşamasında tekrar ACF ve PACF grafiklerinden yararlanılmaktadır. Korelogramlar gözlemlenerek gecikme değerlerinin artma ve azalma gibi görünüşleri üzerinden parametre tahmini yapmak mümkündür. Bununla birlikte, hızlı ve güvenilir olmaları nedeniyle parametre tahmini genellikle paket programlar üzerinden yapılmaktadır.

Paket programlar da dahil olmak üzere parametre belirlerken ve model kıyaslaması yapılırken Akaike Bilgi Kriteri (AIC) ve Schwartz Kriteri (SC) ölçütlerinden faydalanılmaktadır. Akaike Bilgi Kriteri ve Schwartz Kriteri ölçütlerinin formülleri Denklem 4.14 ve Denklem 4.15'te yer almaktadır.

$$\text{Akaike Bilgi Kriteri} = \ln \left(\frac{RSS}{T} \right) + \frac{2k}{T} \quad (4.14)$$

$$\text{Schwartz Kriteri} = \ln \left(\frac{RSS}{T} \right) + \frac{k \cdot \ln T}{T} \quad (4.15)$$

Denklemlerdeki T ; örnek büyüklüğünü, k ; değerleri en küçük yapan değişken sayısını, RSS ise hata kareleri toplamını ifade etmektedir [69]. Modellerde AIC ve SC ölçütlerini minimum yapan parametreler seçilmelidir. İki ölçüt de aynı amaçla kullanılabilmekte ve genellikle aynı model parametresini seçmektedir.

Adım 3- Teşhis Kontrolü

Seçilen modelin seriye uyum sağlayıp sağlamama durumu bu aşamada kontrol edilmektedir. Bununla birlikte, modelin seriye uyum sağlamadığına kanaat getirilirse birinci aşama olan model belirleme aşamasına geri dönülmesi gerekmektedir.

Teşhis kontrolü aşamasında çeşitli testlerle modelin yeterliliği sorgulanmaktadır. Modelin yeterliliği için gerekli durumlar şu şekildedir [71].

- Artıklar rassal olmalı ve normal dağılmalıdır.
- Model mümkün olduğunca en az parametre ile oluşturulmalıdır.
- Model en küçük kök ortalama hata kareye sahip olmalıdır.
- Parametreler istatistiksel açıdan önemli olmalı ve durağanlık sınırları içinde olmalıdır.

Teşhis kontrolünün ardından model yeterli ise ilgili model öngörü aşamasında kullanılmak üzere seçilmektedir. Seçilen model nihai model olarak adlandırılmaktadır.

Adım 4- Öngörü

Teşhis kontrolü ile nihai modele karar verilmesinin ardından zaman serisine seçilen periyot ile öngörü (gelecek tahmini) yapılmalıdır. Öngörünün ardından tahmin değerlerinin gerçek değerlere yakınlığının sınanması gerekmektedir.

4.2.2. Yapay Sinir Ağları

Yapay sinir ağları, insan beynini oluşturan nöronların çalışma prensibini temel alarak geliştirilen bir tahmin yöntemidir.


İlk nörobilişimle ilgili yayın McCulloch ve Pitts tarafından 1943 yılında yayımlanmış ve McCulloch ve Pitts'in geliştirdikleri matematiksel model ile yapay nöron kavramı tanıtılmıştır [75]. 1943 yılından bu yana biyolojik nöronlar ve yapay sinir ağları ile ilgili çeşitli kavramlar, yöntemler ve kurallar ortaya konulmuş, yapay sinir ağları araştırmacılar tarafından sıkça tercih edilen bir yöntem haline gelmiştir. Yapay sinir ağlarının uygulama alanları aşağıdaki gibi sınıflandırılmaktadır [75].

- Eğri uydurma
- Süreç kontrolü
- Sınıflandırma
- Kümeleme
- Tahminleme
- Sistem optimizasyonu
- Çağrışimli bellek

4.2.2.1. Yapay Sinir Ağı Yapısı

İnsan beyni birbirleri ile iletişim halinde binlerce sinir hücresi bulunmaktadır. Beyni oluşturan bu hücrelere nöron denilmektedir. Nöronlar aksonları ile sinaptik bağlantılar kurarak bilgi aktarımı gerçekleştirmektedir. Yapay sinir ağı mimarisi, bir nöronun hücre zarının elektriksel uyarıları nasıl ürettiğinin ve yaydığının analizinden esinlenerek geliştirilmiştir [75]. Yapay sinir ağları da beyindeki sinir sistemine benzer şekilde paralel ve eş zamanlı işlem yapan nöronlardan oluşmaktadır. Girdi nöronları bir dizi işlemde geçirilerek çıktı sinyaline dönüştürülmektedir.

Sinir sisteminden ilham alınarak geliştirilen yapay nöronlarda üç ana bölüm bulunmaktadır. Bunlar; sinapslar, toplayıcı ve aktivasyon fonksiyonudur. Yapay nöronun modeli Şekil 4.5'te verilmiştir.



Şekil 4.5. Yapay nöronun yapısı [75]

Şekil 4.5'teki nöron yapısında dış ortamdan gelen girdi sinyalleri $\{x_1, x_2, x_3, \dots, x_n\}$ kümesi ile girdi değişkenlerini ağırlıklandırmak için kullanılan sinaptik ağırlıklar ise $\{w_1, w_2, w_3, \dots, w_n\}$ kümesi ile temsil edilmektedir. Nörona gelen x_i girdileri w_i ağırlıkları ile çarpılmakta ve toplamaları alınmaktadır. Lineer toplam işleminde aktivasyon eşiği θ , lineer toplayıcı tarafından üretilen sonucun nöron çıkışına doğru bir tetikleme değeri oluşturması için sahip olması gereken uygun eşiği belirtmek için kullanılan bir değişkendir [75]. Bu işlem sonucunda ise girdilerin ağırlıklı toplamı olarak açıklanabilen u çıktısı oluşmaktadır. Aktivasyon potansiyeli u , lineer toplayıcı ile aktivasyon eşiği arasındaki farkın ürettiği sonuçtur [75]. Aktivasyon fonksiyonu g ise nöron çıkışını belirli bir aralıkta tutmak için uygulanmaktadır. Tüm işlemler sonucunda ise y çıktısı oluşmaktadır. Kısaca; nöron girdileri sinaptik ağırlıklar ile çarpılarak toplanmakta, ardından elde edilen toplam nöronun aktivasyon fonksiyonundan geçirilerek çıktı elde edilmektedir [76]. Ağırlıklı toplam formülü Denklem 4.16'da ve nöron çıkışının hesaplanma formülü ise Denklem 4.17'de verilmiştir [75].

$$u = \sum_{i=1}^n w_i x_i - \theta \quad (4.16)$$

$$y = g(u) \quad (4.17)$$


4.2.2.2. Aktivasyon Fonksiyonları

Bir yapay sinir ağında model başarısını etkileyen önemli değişkenlerden bir tanesi aktivasyon fonksiyonlarıdır. Aktivasyon fonksiyonu kullanılmayan bir yapay sinir ağının modeli çıktı sinyali olarak basit doğrusal fonksiyon verecektir [78]. Doğrusal fonksiyonların öğrenme yeteneği zayıftır ve karmaşık problemler üzerinde başarılı olamamaktadır. Yapay sinir ağlarında doğrusal olmayan bir çıktı alınabilmesi için doğrusal olmayan bir aktivasyon fonksiyonunun kullanılması gerekmektedir.

Yapay sinir ağları için çeşitli aktivasyon fonksiyonları mevcuttur. Bununla birlikte modellerde kullanılması gereken fonksiyonlar için kesin bir yargı bulunmamaktadır. Deneme yanılma yolu ile modellerin aktivasyon fonksiyonlarına karar verilmesi gerekmektedir. Literatürdeki aktivasyon fonksiyonlarından bazıları aşağıdaki gibi açıklanabilir:

4.2.2.2.1. Basamak (Step) Fonksiyonu


Basamak fonksiyonu yalnızca 0 ya da 1 değerini alabilir, bu nedenle ikili sınıflayıcı olarak bilinmektedir. Türevi alınmadığı için yalnızca çıktı katmanında kullanılmakta, girdi ve gizli katmanlarda kullanılmamaktadır [77]. Şekil 4.6'da basamak fonksiyonunun ve türevinin grafiği verilmiştir.



Şekil 4.6. Basamak fonksiyonunun grafiği [77]

4.2.2.2. Doğrusal (Linear) Fonksiyon


Doğrusal fonksiyon; basamak fonksiyonunun aksine türevi alınabilen bir aktivasyon fonksiyonudur. Ancak doğrusal fonksiyonun formülü gereği türevi alındığında formülde kullanılan sabit değer elde edilmektedir. Dolayısıyla öğrenme fonksiyonu gerçekleşmemekte, problemlerin sonucunda hep aynı sonuç bulunmaktadır. Bu nedenle doğrusal fonksiyonun kullanım alanları kısıtlıdır. Şekil 4.7’de doğrusal aktivasyon fonksiyonunun ve türevinin grafiği yer almaktadır.



Şekil 4.7. Doğrusal fonksiyonun grafiği [77]

4.2.2.2.3. Sigmoid Fonksiyonu


Sigmoid aktivasyon fonksiyonu, en sık kullanılan aktivasyon fonksiyonudur. Doğrusal olmayan bir fonksiyon çeşidi olan sigmoid fonksiyonu; 0 ve 1 aralığında değer almaktadır. Sigmoid fonksiyonu sürekli türevlenebilir ve düzgün bir S-şeklinindedir [78]. Şekil 4.8’de sigmoid aktivasyon fonksiyonunun ve türevinin grafiği yer almaktadır.



Şekil 4.8. Sigmoid fonksiyonunun grafiği [77]

4.2.2.2.4. Hiperbolik Tanjant (Tanh) Fonksiyonu


Hiperbolik tanjant fonksiyonu orijin etrafında simetrik olması nedeniyle sigmoid fonksiyonu ile benzerdir. Tanh fonksiyonu da sürekli türevlenebilirdir ve -1 ve 1 aralığında değer almaktadır. Sigmoid fonksiyonuna kıyasla tanh fonksiyonunun türevi daha diktir, bu nedenle daha çok değer alabilir [77]. Şekil 4.9’da hiperbolik tanjant aktivasyon fonksiyonunun ve türevinin grafiği verilmiştir.



Şekil 4.9. Tanh fonksiyonunun grafiği [77]

4.2.2.2.5. ReLU (Rectified Linear Unit) Fonksiyonu


ReLU aktivasyon fonksiyonu da sıklıkla kullanılan doğrusal olmayan aktivasyon fonksiyonları arasındadır. 0 ve sonsuz aralığında değer alabilen reLU aktivasyon fonksiyonunda tüm nöronların aynı anda etkinleştirilmemesi fonksiyonun avantajıdır. ReLU fonksiyonunda bir nöron doğrusal dönüşümün çıktısı sıfır olduğunda devre dışı bırakılmaktadır [78]. Bu nedenle hesaplama yükü diğer aktivasyon fonksiyonlarına göre daha azdır, bu da fonksiyonun çok katmanlı ağlarda tercih edilmesini sağlamaktadır [77]. Şekil 4.10'da reLU aktivasyon fonksiyonunun ve türevinin grafiği yer almaktadır.



Şekil 4.10. ReLU fonksiyonunun grafiği [77]

4.2.2.2.6. Sızıntı (Leaky) ReLU Fonksiyonu

Sızıntı reLU fonksiyonu, reLU fonksiyonunda x 'in negatif değerlerinde çıktının sıfır değerini almaması için sıfır yerine 0.01 eklenerek geliştirilen bir aktivasyon fonksiyonudur. Sızıntı reLU fonksiyonunun tanım aralığı eksi sonsuz ve sonsuz aralığındadır. Şekil 4.11'de sızıntı reLU aktivasyon fonksiyonunun ve türevinin grafiği yer almaktadır.



Şekil 4.11. Sızıntı ReLU fonksiyonunun grafiği [77]

Tablo 4.2’de aktivasyon fonksiyonlarının denklemleri ve değer aralıkları yer almaktadır [77].

Tablo 4.2. Aktivasyon fonksiyonu formül ve değer aralıkları

Aktivasyon Fonksiyonu	Denklem	Değer Aralığı
Basamak Fonksiyonu	$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$	$\{0, 1\}$
Doğrusal Fonksiyon	$f(x) = ax$	$\{-\infty, \infty\}$
Sigmoid Fonksiyonu	$f(x) = \frac{1}{1 + e^{-x}}$	$(0, 1)$
Hiperbolik Tanjant Fonksiyonu	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	$(-1, 1)$
ReLU Fonksiyonu	$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases}$	$[0, \infty)$
Sızıntı ReLU Fonksiyonu	$f(x) = \begin{cases} 0.01, & x < 0 \\ x, & x \geq 0 \end{cases}$	$(-\infty, \infty)$

4.2.2.3. Yapay Sinir Ağı Mimarileri

Çeşitli nöronların birbirleri ile ilişkili olarak yerleşimi ve düzenlenmesi yapay sinir ağı mimarisini tanımlamaktadır [75]. Genel olarak bir yapay sinir ağı mimarisi üç bölümden oluşmaktadır; girdi katmanı, gizli katman ve çıktı katmanı. Girdi katmanı; dış dünya ile bağlantısı olan ve dış dünyadan veri almakla görevli katmandır. Modelin başarısının artması için genellikle alınan veriler başka katmana aktarılmadan normalleştirilmektedir. Girdi katmanı bir ya da birden fazla nörondan oluşabilir. Gizli katmanın dış dünya ile bağlantısı yoktur, girdi katmanında aktivasyon fonksiyonu ile üretilen çıktıyı kullanır. Bir yapay sinir ağı modeli bir ya da daha fazla gizli katman içerebilir. Gizli katman sayısına model oluşturulurken karar verilmektedir. Gizli katman ve gizli katmanlardaki nöron sayıları model başarısını etkilemektedir, buna rağmen bu sayıları belirlemede belirli bir yöntem ya da kural bulunmamaktadır. Deneme yanılma yolu ile en iyi model belirlenmektedir. Çıktı katmanı ise nihai çıktının üretildiği katmandır.


Yapay sinir ağı mimarileri ileri beslemeli ve geri beslemeli sinir ağları olmak üzere ikiye ayrılmaktadır.

4.2.2.3.1. İleri Beslemeli Yapay Sinir Ağları

a- Tek Katmanlı İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli yapay sinir ağları, veri akış yönü yalnızca ileriye doğru olan sinir ağlarıdır. Tek katmanlı ileri beslemeli yapay sinir ağları ise yalnızca girdi ve çıktı katmanları olan, bilgi akışının girdi katmanından çıktı katmanına doğru olduğu ağlardır. Girdi ve çıktı katmanlarındaki nöron sayıları uygulanan problemin gerekliliklerine göre değişiklik gösterebilmektedir. Bu yapay sinir ağı mimarisi genellikle sınıflandırma ve doğrusal filtreleme problemlerinde uygulanmakta olup, doğrusal olmayan problemlerde tercih edilmemektedir [75].

Şekil 4.12’de n girdili ve m çıktılı, n - m nöron düzenine sahip tek katmanlı ileri beslemeli yapay sinir ağı modeli verilmiştir.




Şekil 4.12. Tek katmanlı ileri beslemeli yapay sinir ağı modeli [75]

b- Çok Katmanlı İleri Beslemeli Yapay Sinir Ağları

Çok katmanlı ileri beslemeli yapay sinir ağları; bir girdi katmanı, bir ya da daha fazla gizli katman ve bir çıktı katmanından oluşan, bilgi akışının girdi katmanından çıktı katmanına doğru olduğu yapay sinir ağı modelidir. Girdi ve çıktı katmanları problemin gerekliliğine göre bir ya da daha fazla sayıda nöron barındırabilir. Gizli katmanlardaki optimum nöron sayısı ise deneme yanılma yöntemi ile bulunmaktadır. Çok katmanlı ileri beslemeli yapay sinir ağları; sınıflandırma, sistem tanımlama, optimizasyon, robotik vb. gibi çeşitli problemlerde kullanılmaktadır [75].

Şekil 4.13'te n girdili ve m çıktılı ve iki gizli katmanlı, $n-n_1-n_2-m$ nöron düzenine sahip çok katmanlı ileri beslemeli yapay sinir ağı modeli verilmiştir.




Şekil 4.13. Çok katmanlı ileri beslemeli yapay sinir ağı modeli [75]

4.2.2.3.2. Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli yapay sinir ağlarında en az bir nöronun çıktısı başka nöronların geri besleme girdisi olarak kullanılmaktadır. Bu yapay sinir ağı mimarisi, zaman serisi tahmini, optimizasyon, süreç kontrolü gibi zamanla değişen dinamik sistemlerde kullanılabilmektedir [75].

Şekil 4.14'te n girdili ve m çıktılı, $n-1-m$ nöron düzenine sahip, bir çıktı sinyalinin gizli katmana geri besleme girdisi olarak aktarıldığı geri beslemeli yapay sinir ağı modeli verilmiştir.




Şekil 4.14. Geri beslemeli yapay sinir ağı modeli [75]

4.2.2.4. Yinelenen Sinir Ağları (Recurrent Neural Networks)

Yinelenen sinir ağları, düğümler arasındaki bağlantı yoluyla kendisinin ve diğer düğümlerin bilgilerini alarak döngülü bir ağ yapısı oluşturan bir derin öğrenme yapay sinir ağı mimarisidir [79]. Bir başka tanımla RNN mimarisi farklı nöronlar arasında bilginin akış tipini belirleyerek döngüsel olarak yeni değerleri hesaplayan makine öğrenimi yöntemidir [80].

Şekil 4.15'te yinelenen sinir ağının mimarisi yer almaktadır.



Şekil 4.15. Yinelene sinir ağı modeli [80]

t. zamanda gizli katmanın çıktısı h_t ve çıktı katmanının çıktısı y_t şu şekilde hesaplanmaktadır [79]:

$$h_t = F(W_{hh} h_{t-1} + W_{xh} x_t + b_h) \quad (4.18)$$

$$y_t = \sigma(W_{hy} h_t + b_y) \quad (4.19)$$


Denklemlerde yer alan x_t ; t. zamandaki girdiyi, $F()$; gizli katmanın aktivasyon fonksiyonunu, σ ; çıktı katmanının aktivasyon fonksiyonunu, W_{hh} ; bir önceki gizli katmanın çıkışına karşılık gelen ağırlık matrisini, W_{xh} ; t zamanındaki girişe karşılık gelen ağırlık matrisini, W_{hy} ; çıktı katmanına karşılık gelen ağırlık matrisini, b_h ve b_y ise sırasıyla gizli katman ve çıktı katmanına karşılık gelen sapmaları simgelemektedir [79].

Yinelemeli sinir ağları bir geri beslemeli yapay sinir ağı mimarisidir. Ancak RNN mimarisinde veriler tüm katmanlarda kullanıldığı için her çıktıdaki ağırlıkları belirleyen gradyan önceki katmanlardan bağımsız olamamaktadır [81]. Dolayısıyla yinelemeli sinir ağlarında geri yayılım işlemi sürekli tekrarlanmakta, sonuç küçülmekte ve gradyan kaybolmaktadır [81]. Geriye yayılma sürecinde RNN mimarisi gradyan kaybolma problemi yaşadığı için Uzun Kısa Süreli Bellek (LSTM) mimarisi geliştirilmiştir [79].

4.2.2.4.1. Uzun Kısa Süreli Bellek (Long Short Term Memory)

Uzun Kısa Süreli Bellek (LSTM); ilk olarak 1997 yılında Hochreiter ve Schmidhuber tarafından önerilen bir yinelemeli sinir ağı mimarisidir. LSTM mimarisi, kaybolan gradyan sorununun çözülerek, uzun vadeli bilgilerin hatırlanması için tasarlanmıştır [80]. LSTM ağları bir dizi LSTM biriminden oluşmaktadır [82]. Bununla birlikte, tekrar eden, döngüsel bir ağ yapısına sahip olması sebebiyle RNN ağlarına benzerdir ancak çok daha komplike bir mimariye sahiptir.

Şekil 4.16'da LSTM ağının hücre yapısı ve genişleme diyagramı yer almaktadır.



Şekil 4.16. LSTM ağının hücre yapısı ve genişleme diyagramı [79]

LSTM ağları, hangi birimin unutulup hangi birimin hafızaya alınacağına karar vermek için üç farklı iç kapıya sahiptir. Hücre durumunu korumak ve kontrol etmek için kullanılan bu kapılar; unutma kapısı, girme kapısı ve çıkı kapısı olarak adlandırılır. Unutma kapısı; önceki düğümden gelen girdiyi seçici olarak unutmak için kullanılmaktadır [82]. Girdi kapısı; girdileri geçici olarak hafızaya almak için kullanılmakta ve iki kısımdan oluşmaktadır; ilk kısım mevcut girdilerin hücre durumuna kaydedilmesi, ikinci kısım ise mevcut girdi tarafından yeni bilgi üretimi için kullanılmaktadır [82]. Çıkı kapısı ise hangi çıktıların mevcut duruma alınacağını belirlemektedir [82]. Unutma kapısı, girme kapısı ve çıkı kapısı formülleri Denklem 4.20'de yer almaktadır [79].

Unutma kapısı: $f_t = \sigma (W_{hf} h_{t-1} + W_{xf} x_t + b_f)$

Girdi kapısı (1. Kısım): $i_t = \sigma (W_{hi} h_{t-1} + W_{xi} x_t + b_i)$

Girdi kapısı (2. Kısım): $\bar{C}_t = \tanh (W_{hc} h_{t-1} + W_{xc} x_t + b_c)$

$$C_t = f_t * C_{t-1} + i_t * \bar{C}_t \quad (4.20)$$

Çıktı kapısı: $o_t = \sigma (W_{ho} h_{t-1} + W_{xo} x_t + b_o)$

$h_t = o_t * \tanh (C_t)$

$y_t = \sigma (W_y h_t + b_y)$

Formüldeki x_t ; t zamanındaki girdi dizisini, h_{t-1} ; (t-1) zamanındaki LSTM ağ hücrelerinin çıktısını, W_{hf} , W_{xf} , W_{hi} , W_{xi} , W_{ho} , W_{xo} , W_{hc} , W_{xc} ve W_y ; ilgili ağırlık matrislerini, b_f , b_i , b_c ve b_o ; sırasıyla unutma, girdi ve çıktı kapılarının hatalarını, b_f ; tahmin sapmasını, f_t , i_t , ve o_t ; sırasıyla unutma, girdi ve çıktı kapılarının durumlarını $\sigma ()$ ise sigmoid aktivasyon fonksiyonunu temsil etmektedir [79].

$\bar{C}_t$; t zamanındaki girdinin geçici durumunu, C_t ; güncel hücre durumunu, $\tanh()$; hiperbolik tanjant aktivasyon fonksiyonunu, h_t ; güncel hücre çıktısını, y_t ; t zamanındaki tahmin değerini, (*) ve (+) ise doğrusal işlemleri temsil etmektedir [79].

4.2.3. Tahmin Yöntemlerinin Performans Kriterleri

Tahmin yöntemlerinde, öngörü sonuçlarının serinin gerçek değerlerine yakınlığı ölçülerek yöntemlerin başarıları incelenmektedir. Ortalama hata kare, kök ortalama hata kare, ortalama mutlak hata, ortalama mutlak yüzde hata, ortalama yüzde hata ve kök ortalama yüzde hata metriklerinin formülleri Tablo 4.3'te yer almaktadır.

Tablo 4.3. Performans metrikleri [79]


Performans Metrikleri	Formülü
Ortalama Hata Kare (<i>Mean Squared Error: MSE</i>)	$MSE = \frac{\sum (Y^T - Y^G)^2}{t-k}$
Kök Ortalama Hata Kare (<i>Root Mean Squared Error: RMSE</i>)	$RMSE = \sqrt{\frac{\sum (Y^T - Y^G)^2}{t-k}}$
Ortalama Mutlak Hata (<i>Mean Absolute Error: MAE</i>)	$MAE = \frac{\sum Y^T - Y^G }{t-k}$
Ortalama Mutlak Yüzde Hata (<i>Mean Absolute Percentage Error: MAPE</i>)	$MAPE = \frac{\sum Y^T - Y^G }{t-k} \cdot \frac{100}{t}$
Ortalama Yüzde Hata (<i>Mean Percent Error: MPE</i>)	$MPE = \frac{1}{t-k} \cdot \sum \left(\frac{Y^T - Y^G}{Y^G} \right)$
Kök Ortalama Yüzde Hata (<i>Mean Squared Percentage Error: MSPE</i>)	$MSPE = \sqrt{\frac{1}{t-k} \cdot \sum \left(\frac{Y^T - Y^G}{Y^G} \right)^2}$

Denklemlerdeki t ; serinin gözlem sayısını, k modelde tahmin edilen parametre sayısını, Y^T ; modelin tahmin değerini, Y^G ise zaman serisinin gerçek değerlerini simgelemektedir [79]. Hata metriklerinin düşük olması istenilen durumdur, bu nedenle tahmin yöntemleri karşılaştırılırken düşük hata oranına sahip yöntem seçilmektedir.

5. KARAR DESTEK SİSTEMİNİN OLUŞTURULMASI

2020 yılında tüm dünyada havacılık sektörü üzerinde yıkıcı etkisini gösteren COVID-19 pandemisi, sektörün hassasiyetini bir kez daha ortaya koymuştur. Dış hat uçuşlarının durdurulması, iç hat uçuşlarında ise yolcuların güvensiz hissetmeleri sebebiyle şehirlerarası ulaşımına ara vermeleri hava yolu aktivitelerini büyük bir sekteye uğratmıştır. Pandemi dönemi, kriz yönetiminin ve iyi bir hava yolu planlamasının önemini bir kez daha vurgulamakla birlikte böyle bir dönemdeki hava yolu yolcularının taleplerindeki değişimlerin ne kadar yüksek olabileceğini ve bu talep değişimlerini öngörmenin zorluğunu bizlere göstermiştir. Bu tez çalışması kapsamında kriz dönemlerinde bu önemli sektörün uçuş planlarını yapabilmesi için bir karar destek sistemi önerisi sunulmuştur.

Bir hava yoluna ait verilerle hava yolu planlarının hazırlanmasındaki uçak çizelgeleme aşamasına yönelik oluşturulan karar destek sisteminin kavramsal çerçevesi Şekil 5.1’de verilmiştir.



Şekil 5.1. Uygulamanın kavramsal çerçevesi

Şekil 5.1’ den de görüldüğü gibi önerilen karar destek sistemi genel olarak üç ana aşamadan meydana gelmiştir. Bunlar; veri ön işleme, tahmin yöntemi seçimi ve filo atama olarak adlandırılabilir. İlk aşama olan veri ön işleme aşamasında hava yoluna ait veriler toplanmış ve yolcu sayılarına ilişkin zaman serisi oluşturulmuştur. Oluşturulan 1065 günlük zaman serisinden tahminleme dönemleri 30, 92 ve 365 gün olan, üç farklı analiz için veriler hazırlanmıştır. İkinci aşamada ise bu veriler, zaman serisi analizinde kullanılan Uzun-Kısa Süreli Bellek (LSTM) ve Box-Jenkins yöntemleri ile en uygun parametreler seçilerek modellenmiştir. Modelleme sonucunda toplam altı farklı öngörü yapılmış ve öngörü sonuçları MAE, RMSE ve MAPE performans metrikleri ile karşılaştırılmıştır. Karşılaştırma sonucunda kullanılan zaman serilerinde en iyi tahminleme performansı gösteren tahminleme yöntemi seçilmiştir. Üçüncü aşamada ise matematiksel modelde kullanılmak üzere seçilen tahminleme yöntemi ile örneklem dışı öngörü yapılmıştır. Aynı zamanda ilgili hava yolunun gerçek zamanlı uçuş verileri çekilerek tablo haline getirilmiştir. Hava yolunun yurtiçi uçuşlarındaki filo ataması problemini çözerek günlük uçuş kazancını enbüyüklemeyi amaçlayan bir matematiksel model geliştirilmiş ve gerçek verilerle çalıştırılmıştır. Modelin çıktısı olarak günlük filo çizelgesi elde edilmiş olup tüm sistem günlük tekrarlanabilen bir karar destek sistemi haline getirilmiştir.

Karar destek sistemi uygulaması sırasıyla Bölüm 5.1; verilerin toplanması, Bölüm 5.2; çalışmada kullanılan yazılımlar, Bölüm 5.3; veri ön işleme toplanması, Bölüm 5.4; tahmin yöntemi seçimi ve Bölüm 5.5; uçak çizelgesinin oluşturulması başlıkları altında anlatılacaktır.

5.1. Verilerin Toplanması

Karar destek sistemi uygulaması için verilerin toplanması aşamasında Eurocontrol, Pegasus Hava Yolları ve Sabiha Gökçen Havalimanı tarafından açık kaynak kodlu paylaşılan verilerden yararlanılmıştır. Eurocontrol ’ün “Günlük Trafik Gösterge Paneli”, Pegasus Hava Yolları’nın “Operasyonel ve Finansal Veriler”i Sabiha Gökçen Havalimanı’nın “Uçuş Bilgi Ekranı” web sayfaları üzerinden ilgili veriler çekilmiştir [83] [84] [85].

Tahmin yöntemlerinin uygulanması için Eurocontrol ve Pegasus Hava Yolları'nın veri ambarlarından 01.07.2020 ve 31.05.2023 tarihleri arasındaki tarih ve yolcu bilgileri alınmıştır. Eurocontrol, Avrupa'daki hava taşımacılığı sistemini desteklemek için kurulmuş bir sivil-askeri teşkilattır [86]. Eurocontrol Avrupa havacılığının daha güvenli ve verimli olması, hava taşımacılığının çevreye zararlarının indirgenmesi amacıyla iş birliği ülkeleriyle çalışmalarda bulunmaktadır. Günümüzde, Türkiye dahil olmak üzere Eurocontrol 'ün 41 Üye Devleti bulunmaktadır. Eurocontrol, 2020 yılından bu yana web sitesi üzerinden günlük hava trafik verilerini araştırmacılar ve ilgililerle paylaşmaktadır.

Uçak çizelgeleme problemi için ise Sabiha Gökçen Havalimanı'nın veri ambarından 01.06.2023 ve 07.06.2023 tarihleri arasındaki uçuş bilgileri çekilmiştir.

5.2. Çalışmada Kullanılan Yazılımlar

Çalışma kapsamında gerçekleştirilen karar destek sistemi uygulamasında, verilerin bir araya getirilerek işlenmesi, zaman serilerinin oluşturulması, performans metriklerinin hesaplanması ve grafiklerin oluşturulması aşamalarında Microsoft Excel programından yararlanılmıştır. Zaman serisi analizinde kullanılan LSTM ve Box-Jenkins yöntemlerinin kodlarının yazılması, düzenlenmesi, uygulanması ve öngörülerin oluşturulmasında Anaconda platformunda yer alan Jupyter Notebook yazılımı kullanılmıştır.

Jupyter Notebook kod yazmaya, kodları düzenlemeye ve görselleştirmeye olanak sağlayan açık kaynak kodlu ve web tabanlı bir programdır [87]. Kullanıcılar için etkileşimli bir ortam sağlaması, kodların hücre hücre çalıştırılıp sonuçlarının görülebilmesi ve not alınabilmesi gibi avantajları sebebiyle veri biliminde sıklıkla tercih edilmektedir.

Jupyter Notebook, Python, R, Julia, Ruby gibi birçok programlama dilini desteklemektedir. Yapılan çalışmada ise veri analizi ve makine öğreniminde yaygın olarak kullanılan Python programlama dili tercih edilmiştir.

Python, sade ve anlaşılır kod yapısı sayesinde öne çıkan, isteğe bağlı olarak modül eklenerek genişletilebilen ve oldukça geniş bir kullanım alanına sahip olan nesne tabanlı, açık kaynak kodlu üst düzey bir programlama dilidir [88]. Python'un en önemli özelliklerinden birisi çeşitli geliştiriciler tarafından oluşturulan hazır fonksiyon grupları olan kütüphane koleksiyonudur. Kütüphaneler sayesinde kullanıcılar veri türetme, matematiksel analiz ve görselleştirme gibi çeşitli işlemlerin hazır kodlarına kolaylıkla ulaşabilmekte ve "import" komutuyla hızlı bir şekilde not defteri belgesine aktararak kullanıma hazır hale getirebilmektedir. Sıklıkla tercih edilen ve bu uygulamada da kullanılan kütüphaneler ve işlevleri şu şekilde açıklanabilir:

Uygulamada kullanılan kütüphaneler:

Pandas: Python dilinin en önemli kütüphanelerinden biridir. Veri ekleme, verileri okuma, analiz etme, dönüştürme ve yönetme görevlerinde kullanılmaktadır [89].

Statsmodels: Teşhis diyagramları, ANOVA testi, zaman serileri analizleri, lineer regresyon modelleme gibi çeşitli istatistiksel model tahmininin ve istatistiksel testlerin yapılmasını sağlayan bir kütüphanedir [90].

Scikit-Learn(Sklearn): Statsmodels kütüphanesine benzer şekilde makine öğrenimi ve veri analizlerinde kullanılmaktadır. Regresyon, sınıflandırma, kümeleme, veri madenciliği gibi modüller içermektedir [91].

Matplotlib: Verileri görselleştirmek için en sık tercih edilen kütüphanedir. Matplotlib kütüphanesi ile verileri iki veya üç boyutlu görsel haline getirmek mümkün hale gelmektedir [92].

Numpy: En önemli kütüphanelerden biri olan Numpy, çok boyutlu diziler oluşturmakta kullanılmaktadır [93]. Aynı zamanda ileri düzey matematiksel hesaplamaları hızlı bir şekilde gerçekleştirmeyi sağlamaktadır.

Keras: Derin öğrenme algoritmalarının geliştirilmesinde kullanılmaktadır [94].

Pyramid-arima(Pmdarima): Zaman serisi analizi için tasarlanan istatistiksel kütüphanedir [95].

Son adım olan uçak çizelgeleme probleminin matematiksel modeli ise LINGO paket programında yazılmıştır. LINGO; tam sayılı, doğrusal ve doğrusal olmayan matematiksel modellerin yazılmasına ve en iyilenmesine imkân sağlayan bir modelleme aracıdır [96]. Modelleme dilinin basit olması, hızlı ve otomatik çözümleri sebebiyle kullanıcılar tarafından tercih edilmektedir.

5.3. Veri Ön İşleme

Hava yolu uçak çizelgelerinin hazırlanması için oluşturulacak karar destek sisteminin ilk aşamasında yolcu sayılarının zaman serilerinin hazırlanması yer almaktadır. Karar destek sistemindeki tahmin modellerinin oluşturulmasında kullanılmak üzere Eurocontrol veri ambarı içerisinde Pegasus Hava Yolları'nın 01.07.2020 ve 31.05.2023 tarihleri arasındaki günlük uçuş sayısı verileri çekilmiştir. Tablo 5.1'de veri setinin ilk 30 günlük verileri yer almaktadır.

Tablo 5.1. Günlük uçuş sayıları

Uçuş Sayıları									
2020									
1.Tem	2.Tem	3.Tem	4.Tem	5.Tem	6.Tem	7.Tem	8.Tem	9.Tem	10.Tem
186	228	231	230	226	214	181	200	221	224
11.Tem	12.Tem	13.Tem	14.Tem	15.Tem	16.Tem	17.Tem	18.Tem	19.Tem	20.Tem
222	229	209	186	210	251	236	244	254	241
21.Tem	22.Tem	23.Tem	24.Tem	25.Tem	26.Tem	27.Tem	28.Tem	29.Tem	30.Tem
212	227	263	283	278	286	269	245	275	310


Günlük uçuş sayılarının elde edilmesinin ardından karar destek sistemi uygulamasında yolcu sayısı verilerinin kullanılması planlandığı için Pegasus Hava Yolları'nın paylaştığı aylık trafik verilerine ulaşılmıştır. 2020 Temmuz ve 2023 Mayıs tarihleri arasındaki aylık trafik veri setinin örnek bir kısmı Tablo 5.2'de verilmiştir.

Tablo 5.2. Aylık trafik verileri

AYLIK		2023	2023	2023	2023	2023
		Ocak	Şubat	Mart	Nisan	Mayıs
Toplam	Misafir sayısı, mn	2.14	2.00	2.14	2.39	2.63
	Konma	12,810	11,696	12,863	14,890	15,997
	Koltuk sayısı, mn	2.54	2.32	2.58	2.97	3.2
	Doluluk Oranı	84.5%	85.9%	83.0%	80.50%	82.00%
	ASK (mln km)	3,735	3,392	3,827	4,709	5,009
	Konma başına Misafir	167	171	166	161	164
İç Hat	Misafir sayısı, mn	0.89	0.85	0.83	0.83	0.96
	Konma	5,346	5,013	5,165	5,098	5,660
	Koltuk sayısı, mn	1.03	0.97	1.00	1	1.12
	Doluluk Oranı	86.5%	87.0%	82.9%	82.90%	85.50%
	ASK (mln km)	787	754	747	728	797
	Konma başına Misafir	167	169	161	163	169
Dış Hat	Misafir sayısı, mn	1.25	1.15	1.31	1.56	1.67
	Konma	7,464	6,683	7,698	9,792	10,337
	Koltuk sayısı, mn	1.50	1.35	1.57	1.97	2.08
	Doluluk Oranı	83.1%	85.1%	83.0%	79.30%	80.20%
	ASK (mln km)	2,948	2,637	3,080	3,981	4,211
	Konma başına Misafir	167	172	170	160	161

*ASK (Available Seat Kilometer): Arz edilen Koltuk Kilometre

Pegasus Hava Yolları'nın paylaştığı bilgiler arasında aylık misafir sayıları, konma sayıları, uçuşlardaki koltuk sayıları, doluluk oranları, Arz Edilen Koltuk Kilometre (AKK), konma başına misafir sayıları ve ortalama günlük uçak kullanımı yer almaktadır. Günlük yolcu sayıları çevrimiçi kaynaklardan elde edilemediği için iki veri ambarından alınan verilerden Eurocontrol 'ün yayınladığı günlük uçuş sayıları ile Pegasus Hava Yolları'nın paylaştığı aylık konma başına misafir sayıları çarpılarak günlük yolcu sayısı veri seti oluşturulmuştur. Pegasus Hava Yolları'nın 01.07.2020 ve 31.05.2023 tarihleri arasındaki günlük yolcu sayıları grafiği Şekil 5.2'de verilmiştir.




Şekil 5.2. 01.07.2020 - 31.05.2023 tarihleri arası günlük yolcu sayıları

Uygulamaya başlamadan önce oluşturulan veri setinin özellikleri incelenmiştir. Veri setinin istatistiksel bilgileri Tablo 5.3'te, kutu ve histogram grafikleri ise Şekil 5.3'te verilmiştir.

Tablo 5.3. Veri setinin istatistiksel bilgileri

Veri Sayısı	1065
Eksik Veri Sayısı	0
Ortalama	62418.75
Standart Sapma	19720.26
Minimum	11739
Maksimum	99400
Çarpıklık	-0.22
Basıklık	-0.87

Veri seti, ortalaması 62418 ve standart sapması 19720 olan 1065 adet veriden oluşmaktadır. Veri seti elle oluşturulduğu için eksik veri bulunmamaktadır. Veri seti sola çarpık ve basık bir dağılım göstermektedir. Bununla birlikte kutu grafiğinde aykırı değer görülmemekte, histogram grafiğinde ise neredeyse simetrik bir dağılım görülmektedir.



Şekil 5.3. Veri setinin kutu grafiği ve histogram grafiği

Günlük yolcu sayıları verilerinin çekilmesinin ardından LSTM ve Box-Jenkins modellerinde kullanmak üzere veriler hazırlanmıştır. İki tahmin yöntemi ile eğitim verilerinin aynı kaldığı ancak tahmin periyotlarının değiştiği üçer analiz yapılacaktır. Bununla birlikte, farklı dönemlerdeki hava yolu operasyonel planlama süreçleri için tahmin edilen yolcu taleplerinin tutarlılığının araştırılması amaçlanmıştır. İlk analiz 700 eğitim verisi ve 30 test verisi; ikinci analiz 700 eğitim verisi ve 92 test verisi; üçüncü analiz ise 700 eğitim verisi ve 365 test verisi kullanılarak uygulanmıştır. Üç analiz ile yolcu sayıları tahmin edilecektir.

Günlük yolcu sayılarını içeren zaman serisinin hazırlanmasının ardından öngöründe kullanılacak tahmin yöntemine karar verilmesi için ikinci aşamaya geçilmiştir.

5.4. Tahmin Yöntemi Seçimi

Karar destek sistemi uygulamasında kullanılmak üzere veriler toplanmış, modellerin girdi ve çıktıları belirlenmiştir. Oluşturulacak tahmin modellerinin girdisi günlük yolcu sayılarının geçmiş gözlem değerleri, çıktısı ise belirlenen aralıktaki tahmin değerleri olacaktır.

İkinci aşamada yinelemeli yapay sinir ağı mimarisi Uzun-Kısa Süreli Bellek (LSTM) ve zaman serisi tahmin yöntemlerinden Box-Jenkins kullanılacaktır. İlgili yöntemler sırasıyla Bölüm 4.2.2.4.1 ve Bölüm 4.2.1.2’de tanıtılmıştır. Bu adımda ise veri setlerine LSTM ve Box-Jenkins yöntemleri uygulanacak ve öngörüler elde edilecektir. Ardından öngörülerin MAE, RMSE ve MAPE performans ölçütlerine bakılarak uçak çizelgesinin oluşturulması için gerekli olan tahmin yöntemine karar verilecektir.

5.4.1. Uzun Kısa Süreli Bellek (LSTM) İle Talep Tahmini

Uzun Kısa Süreli Bellek (LSTM), döngüsel ağ yapısına sahip yapay sinir ağı mimarisidir. Tahmin modellerinde başarılı sonuçlar gösteren bir derin öğrenme modeli olduğu için bu çalışmada kullanılmak üzere seçilmiştir. LSTM yönteminin mimari yapısı ve ayrıntılı açıklamaları Bölüm 4.2.2.4.1’de yer almaktadır. Talep tahmini uygulamasında kullanılacak yöntemin sözde kodu Şekil 5.4’te verilmiştir. Modele ait Python kodu ise Ek 5.1’de yer almaktadır.

LSTM Algorithm	
1	procedure LSTM
2	create input database
3	import libraries
4	import modules
5	import database
6	split train and test data
7	
8	#model selection
9	for hidden layers = 1 to 2 do (change hidden layer for every run)
10	for neurons = 2 to 850 do (increase neurons for every run)
11	for activation function = sigmoid (change activation function for every run)
12	for repeat = 1 to 90 do (repeat run 90 times)
13	compile model
14	fit model $\leftarrow$ train data
15	make prediction $\leftarrow$ test data
16	end for
17	end for
18	end for
19	calculate MAE, RMSE and MAPE $\leftarrow$ save to storage
20	end for
21	Return

22 **Select** best prediction
 23
 24 **end procedure**

Şekil 5.4. LSTM Pseudocode

LSTM yöntemi için öncelikle yapay sinir ağlarının önemli bir adımı olan normalizasyon işlemi uygulanmıştır. “MinMaxScaler” fonksiyonu kullanılarak veri setinde bulunan tüm değerler 0-1 aralığına ölçeklendirilmiştir. “MinMaxScaler” fonksiyonu verileri verilen değer aralığında ölçeklendirmektedir. Fonksiyona ait formül Denklem 5.1’de verilmiştir.

$$X_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (5.1)$$

Veri setinin normalize edilmesinin ardından eğitim ve test kümeleri oluşturulmuştur. Birinci analizde veri setinin ilk 700 verisi eğitim, son 30 verisi ise test amacıyla kullanılacaktır.

Uygulamadaki model mimarisinde girdi katmanında bir nöron ve çıktı katmanında bir nöron bulunmaktadır. Ancak gizli katman ve gizli katmandaki nöron sayıları bilinmemektedir. Bölüm 4.2.2.3’te bahsedildiği üzere, yapay sinir ağları mimarileri kurulurken karşılaşılan en önemli zorluk, optimum gizli katman ve nöron sayısının belirlenmesidir. Çok sayıda farklı katman ve nöron sayıları ile denemeler yapılarak en iyi parametreler araştırılmıştır. İncelenen ağ yapıları ve modellerin performans ölçütleri Tablo 5.4’te verilmiştir.

Tablo 5.4. Birinci analizin LSTM ağ araştırması

Gizli Katman Sayısı	1. Katmandaki Nöronlar	2. Katmandaki Nöronlar	Aktivasyon Fonksiyonu	MAE	RMSE	MAPE
1	2	–	Sigmoid	17704.92	17956.52	0.210
1	2	–	ReLU	30700.84	30868.03	0.366
1	2	–	tanh	5034.16	5512.76	0.060
1	5	–	Sigmoid	4223.69	4865.16	0.050
1	5	–	ReLU	3428.28	4217.39	0.042

1	5	–	tanh	3487.19	4209.17	0.042
1	8	–	Sigmoid	7120.34	7628.99	0.084
1	8	–	reLU	3402.03	4235.72	0.041
1	8	–	tanh	3378.68	4193.33	0.041
1	15	–	Sigmoid	4033.19	4745.34	0.048
1	15	–	reLU	3113.57	4248.13	0.038
1	15	–	tanh	3072.30	3951.76	0.037
1	40	–	Sigmoid	3026.19	3922.43	0.037
1	40	–	reLU	3380.68	4222.46	0.041
1	40	–	tanh	3627.67	4398.60	0.044
1	65	–	Sigmoid	3581.57	4384.98	0.043
1	65	–	reLU	3793.30	4559.61	0.046
1	65	–	tanh	3976.04	4754.22	0.048
1	100	–	Sigmoid	4203.82	4883.74	0.050
1	100	–	reLU	4050.17	4829.64	0.049
1	100	–	tanh	3080.00	3969.10	0.038
1	125	–	Sigmoid	3552.96	4298.92	0.043
1	125	–	reLU	3831.74	4663.13	0.046
1	125	–	tanh	3153.92	4043.43	0.039
1	180	–	Sigmoid	4699.05	5317.39	0.056
1	180	–	reLU	3414.52	4272.47	0.042
1	180	–	tanh	3395.56	4259.71	0.041
1	230	–	Sigmoid	3742.10	4479.65	0.045
1	230	–	reLU	3833.34	4615.81	0.046
1	230	–	tanh	3249.38	4120.50	0.040
1	450	–	Sigmoid	3701.68	4445.44	0.045
1	450	–	reLU	3243.67	4147.47	0.040
1	450	–	tanh	3288.31	4162.03	0.040
1	600	–	Sigmoid	2811.79	3755.10	0.034
1	600	–	reLU	3598.84	4396.45	0.044
1	600	–	tanh	3385.80	4240.96	0.041
1	670	–	Sigmoid	3131.77	3972.62	0.038
1	670	–	reLU	4498.13	5200.73	0.054
1	670	–	tanh	3083.90	3982.73	0.038

1	750	–	Sigmoid	2834.18	3770.40	0.035
1	750	–	reLU	4121.65	4883.36	0.050
1	750	–	tanh	3437.69	4272.71	0.042
1	850	–	Sigmoid	3862.79	4597.72	0.047
1	850	–	reLU	3862.79	4597.72	0.047
1	850	–	tanh	3541.43	4375.09	0.043
2	40	20	Sigmoid	6329.69	6769.80	0.075
2	40	20	reLU	3254.92	4132.56	0.040
2	40	20	tanh	3122.93	3999.45	0.038
2	50	50	Sigmoid	5829.53	6335.68	0.069
2	50	50	reLU	4675.15	5471.24	0.056
2	50	50	tanh	2995.93	3909.87	0.037
2	100	50	Sigmoid	5728.69	6230.75	0.068
2	100	50	reLU	3777.31	4623.92	0.046
2	100	50	tanh	3474.52	4293.54	0.042
2	125	100	Sigmoid	4826.63	5411.15	0.058
2	125	100	reLU	3979.08	4782.47	0.048
2	125	100	tanh	3037.59	3924.60	0.037
2	160	125	Sigmoid	3442.92	4183.96	0.042
2	160	125	reLU	3571.29	4402.25	0.043
2	160	125	tanh	3105.10	3973.97	0.038
2	230	70	Sigmoid	4613.30	5183.87	0.055
2	230	70	reLU	3337.31	4227.55	0.041
2	230	70	tanh	3409.19	4225.11	0.041
2	250	40	Sigmoid	4815.85	5368.63	0.058
2	250	40	reLU	3302.24	4162.50	0.040
2	250	40	tanh	4038.84	4760.99	0.049
2	250	100	Sigmoid	5666.51	6220.78	0.068
2	250	100	reLU	3455.31	4306.40	0.042
2	250	100	tanh	3347.89	4176.80	0.041
2	350	150	Sigmoid	4512.29	5112.73	0.054
2	350	150	reLU	3539.63	4379.35	0.043
2	350	150	tanh	3490.44	4302.97	0.042
2	400	260	Sigmoid	3194.20	4012.41	0.039

2	400	260	reLU	3254.17	4119.01	0.040
2	400	260	tanh	4602.48	5242.63	0.055
2	450	180	Sigmoid	2925.99	3781.63	0.036
2	450	180	reLU	3114.50	4259.31	0.038
2	450	180	tanh	4343.32	5040.37	0.052
2	480	350	Sigmoid	2654.09	3600.32	0.032
2	480	350	reLU	3871.36	4640.70	0.047
2	480	350	tanh	3161.43	4000.96	0.039
2	520	260	Sigmoid	3959.95	4649.10	0.048
2	520	260	reLU	3241.21	4117.63	0.040
2	520	260	tanh	3065.29	3940.37	0.037
2	600	150	Sigmoid	4369.54	4978.21	0.052
2	600	150	reLU	4368.33	5129.93	0.053
2	600	150	tanh	3470.00	4273.65	0.042
2	600	300	Sigmoid	2813.75	3950.09	0.035
2	600	300	reLU	3211.22	4055.24	0.039
2	600	300	tanh	3011.82	3893.24	0.037


Ağ yapısı araştırması kapsamında her yeni modelde gizli katman sayısı ve katmanlardaki nöron sayıları arttırılmıştır. Her katman ve nöron kombinasyonu “Sigmoid”, “reLU” ve “tanh” aktivasyon fonksiyonu ile denenmiştir. Bu şekilde farklı gizli katman sayıları, nöron sayıları ve aktivasyon fonksiyonları kullanılarak toplam 90 deneme yapılmıştır. Denemeler sonucunda ağ yapılarının performans ölçütleri incelenmiş, ilgili kriterlerden MAPE kriterine seçim önceliği verilerek en iyi performans gösteren ağ mimarisi modelde kullanılmak üzere seçilmiştir. Seçilen ağ yapısına ait bilgiler Tablo 5.5’te yer almaktadır.

Tablo 5.5. Birinci veri setinin LSTM ağ mimarisi

Eğitim Veri Sayısı	700
Test Veri Sayısı	30
Gizli Katman Sayısı	2
Gizli Katmandaki Nöronlar	480-350
Aktivasyon Fonksiyonu	Sigmoid

Seilen modelde 480 ve 350 n6rondan oluřan iki gizli katman bulunmaktadır. Modelin aktivasyon fonksiyonu olarak ‘‘Sigmoid’’ aktivasyon fonksiyonu seilmiřtir. Hata fonksiyonu ‘‘Hata Kareler Ortalaması’’ olarak belirlenerek modelin tasarımı gerekleřtirilmiř ve model derlenmiřtir. Derlemenin ardından model 700 eėitim verisi ile eėitilmiřtir. Eėitilen model ile 30 g6nl6k 6ng6r6 oluřturulmuřtur. Oluřturulan 6ng6r6 deėerleri geri 6leklendirilerek eski deėer aralıėına getirilmiřtir. Modelin performans 6l6tlerinin deėerleri tahmin modellerinin karřılařtırmasında kullanılmak 6zere kaydedilmiřtir.

LSTM modeli ile 6ng6r6len g6nl6k yolcu sayısı deėerlerinin ve test deėerlerinin grafiėi řekil 5.5’te yer almaktadır.



řekil 5.5. Birinci analizin LSTM tahmin grafiėi

řekil 5.5’te 01.06.2022 ve 30.06.2022 tarihleri arasındaki g6nl6k yolcu sayılarının tahmin deėerleri bulunmaktadır. Model, veri setindeki trend ve mevsimsellik bileřenlerini iyi bir řekilde modellemiř ancak kriz d6neminin yarattıėı rassal bileřenler modelin uyum yeteneėini etkilemiřtir. Dolayısıyla istenilen bařarıda bir tahmin modeli oluřturulamamıřtır.

Birinci analiz için öngörü yapılmasının ardından ikinci analiz verilerine normalizasyon işlemi uygulanmıştır. Ardından veri seti eğitim ve test kümelerine ayrılarak gizli katman ve nöron sayısının belirlenmesi için denemeler yapılmıştır. İncelenen ağ yapıları ve modellerin performans ölçütleri Tablo 5.6’da verilmiştir.

Tablo 5.6. İkinci analizin LSTM ağ araştırması

Gizli Katman Sayısı	1. Katmandaki Nöronlar	2. Katmandaki Nöronlar	Aktivasyon Fonksiyonu	MAE	RMSE	MAPE
1	2	–	Sigmoid	25711.18	26109.92	0.281
1	2	–	reLU	3662.67	4336.38	0.041
1	2	–	tanh	4342.84	4998.37	0.047
1	5	–	Sigmoid	11212.78	11668.31	0.122
1	5	–	reLU	3091.61	3952.81	0.034
1	5	–	tanh	3984.61	4626.52	0.044
1	8	–	Sigmoid	4467.72	5082.05	0.049
1	8	–	reLU	3071.71	3763.26	0.034
1	8	–	tanh	3095.80	3745.78	0.034
1	15	–	Sigmoid	9316.68	9770.79	0.102
1	15	–	reLU	2842.07	3699.43	0.032
1	15	–	tanh	2662.05	3514.00	0.030
1	40	–	Sigmoid	3859.81	4477.96	0.043
1	40	–	reLU	2632.96	3442.88	0.030
1	40	–	tanh	2669.07	3492.53	0.030
1	65	–	Sigmoid	3479.63	4125.78	0.039
1	65	–	reLU	2625.23	3408.07	0.030
1	65	–	tanh	2625.20	3438.37	0.030
1	100	–	Sigmoid	3928.45	4543.93	0.043
1	100	–	reLU	3034.64	3768.25	0.034
1	100	–	tanh	2702.57	3522.23	0.030
1	125	–	Sigmoid	4255.92	4873.89	0.047
1	125	–	reLU	2613.34	3438.48	0.029
1	125	–	tanh	3186.58	3974.54	0.036
1	180	–	Sigmoid	2353.39	3197.77	0.027

1	180	–	ReLU	2615.39	3443.47	0.029
1	180	–	tanh	2668.58	3485.61	0.030
1	230	–	Sigmoid	3556.34	4223.96	0.039
1	230	–	ReLU	2675.62	3522.99	0.030
1	230	–	tanh	2778.26	3604.41	0.031
1	450	–	Sigmoid	2429.72	3262.71	0.027
1	450	–	ReLU	3854.51	4596.34	0.043
1	450	–	tanh	2662.74	3477.89	0.030
1	600	–	Sigmoid	3490.70	4191.71	0.039
1	600	–	ReLU	2790.61	3605.32	0.031
1	600	–	tanh	3381.22	4141.89	0.038
1	670	–	Sigmoid	4702.44	5344.33	0.052
1	670	–	ReLU	3694.99	4428.15	0.041
1	670	–	tanh	3214.61	3984.07	0.036
1	750	–	Sigmoid	2728.55	3523.13	0.031
1	750	–	ReLU	2771.94	3605.35	0.031
1	750	–	tanh	3869.85	4611.75	0.043
1	850	–	Sigmoid	3441.22	4134.70	0.038
1	850	–	ReLU	3176.93	4112.00	0.036
1	850	–	tanh	3720.70	4457.61	0.041
2	40	20	Sigmoid	5025.27	5622.19	0.055
2	40	20	ReLU	3197.45	4027.36	0.036
2	40	20	tanh	2935.64	3705.77	0.033
2	50	50	Sigmoid	2304.87	3116.56	0.026
2	50	50	ReLU	2932.90	3727.63	0.033
2	50	50	tanh	3627.97	4362.77	0.040
2	100	50	Sigmoid	2926.25	3588.58	0.032
2	100	50	ReLU	3074.74	3874.37	0.035
2	100	50	tanh	4107.38	4827.87	0.045
2	125	100	Sigmoid	2457.14	3250.16	0.027
2	125	100	ReLU	2841.53	3667.37	0.032
2	125	100	tanh	2922.40	3721.48	0.033
2	160	125	Sigmoid	2986.53	3661.38	0.033
2	160	125	ReLU	3182.16	4036.46	0.036

2	160	125	tanh	2755.32	3563.13	0.031
2	230	70	Sigmoid	4193.59	4793.90	0.046
2	230	70	reLU	2852.43	3664.41	0.032
2	230	70	tanh	2718.36	3523.27	0.030
2	250	40	Sigmoid	4999.53	5603.80	0.055
2	250	40	reLU	3276.49	4100.25	0.037
2	250	40	tanh	2657.89	3439.00	0.030
2	250	100	Sigmoid	3886.89	4486.11	0.043
2	250	100	reLU	2964.68	3754.56	0.033
2	250	100	tanh	3244.64	4012.20	0.036
2	350	150	Sigmoid	2563.72	3321.18	0.029
2	350	150	reLU	2708.41	3476.84	0.031
2	350	150	tanh	3906.02	4644.32	0.043
2	400	260	Sigmoid	4078.35	4682.06	0.045
2	400	260	reLU	2877.94	3672.69	0.032
2	400	260	tanh	2780.26	3587.96	0.031
2	450	180	Sigmoid	5527.54	6133.84	0.061
2	450	180	reLU	2681.01	3437.17	0.030
2	450	180	tanh	4899.70	5584.13	0.054
2	480	350	Sigmoid	4864.02	5475.32	0.054
2	480	350	reLU	2843.93	3679.78	0.032
2	480	350	tanh	2639.11	3425.69	0.030
2	520	260	Sigmoid	2224.23	3123.26	0.025
2	520	260	reLU	3093.58	3913.45	0.035
2	520	260	tanh	2620.22	3403.77	0.029
2	600	150	Sigmoid	4071.44	4672.24	0.045
2	600	150	reLU	2936.19	3711.67	0.033
2	600	150	tanh	3703.08	4431.31	0.041
2	600	300	Sigmoid	2560.41	3339.57	0.029
2	600	300	reLU	2858.27	3599.01	0.032
2	600	300	tanh	2919.00	3706.07	0.033


Ağ yapısı araştırması kapsamında katman sayıları ve katmanlardaki nöron sayıları her adımda artırılarak üç farklı aktivasyon fonksiyonuyla toplam 90 deneme yapılmıştır. Denemeler sonucunda en iyi performans gösteren ağ mimarisi modelde kullanılmak üzere seçilmiştir. Seçilen ağ yapısına ait bilgiler Tablo 5.7’de yer almaktadır.

Tablo 5.7. İkinci analizin LSTM ağ mimarisi

Eğitim Veri Sayısı	700
Test Veri Sayısı	92
Gizli Katman Sayısı	2
Gizli Katmandaki Nöronlar	520-260
Aktivasyon Fonksiyonu	Sigmoid

Seçilen model mimarisinde tek nöron içeren bir girdi katmanı, sırasıyla 520 ve 260 nöron içeren iki gizli katman ve tek nöron içeren bir çıkış katmanı bulunmaktadır. Üç aktivasyon fonksiyonu arasında en iyi sonucun Sigmoid aktivasyon fonksiyonunda görüldüğü belirlenerek ilgili aktivasyon fonksiyonu modelde kullanılmak üzere seçilmiştir. Hata fonksiyonu “Hata Kareler Ortalaması” olarak belirlenmiş ve model derlenmiştir. Derlemenin ardından model 700 eğitim verisi ile eğitilmiş ve eğitilen model ile 92 günlük öngörü oluşturulmuştur. Oluşturulan öngörü değerleri geri ölçeklendirilerek eski değer aralığına getirilmiştir. Modelin performans ölçütlerinin değerleri analiz edilmiş ve kaydedilmiştir.

LSTM modeli ile öngörülen günlük yolcu sayısı değerlerinin ve test değerlerinin grafiği Şekil 5.6’da verilmiştir.



Şekil 5.6. İkinci analizin LSTM tahmin grafiği

Şekil 5.6’da 01.06.2022 ve 31.08.2022 tarihleri arasındaki günlük yolcu sayılarının tahmin değerleri bulunmaktadır. Seçilen LSTM modeli zaman serisi ile iyi bir uyum göstermiştir.

Son olarak, üçüncü analiz için normalizasyon işlemi uygulanmıştır. Veri seti eğitim ve test kümelerine ayrılarak gizli katman ve nöron sayısının belirlenmesi için denemeler yapılmıştır. Araştırılan ağ yapıları ve performans ölçütleri Tablo 5.8’de yer almaktadır.

Tablo 5.8. Üçüncü analizin LSTM ağ araştırması

Gizli Katman Sayısı	1. Katmandaki Nöronlar	2. Katmandaki Nöronlar	Aktivasyon Fonksiyonu	MAE	RMSE	MAPE
1	2	—	Sigmoid	6390.58	7161.04	0.080
1	2	—	reLU	5138.61	6443.95	0.068
1	2	—	tanh	5473.43	6393.74	0.070
1	5	—	Sigmoid	14581.83	15005.22	0.159
1	5	—	reLU	10945.16	12789.99	0.130
1	5	—	tanh	4114.47	5292.34	0.054

1	8	—	Sigmoid	4233.16	4850.06	0.046
1	8	—	ReLU	4859.55	6131.26	0.063
1	8	—	tanh	4351.74	5681.29	0.058
1	15	—	Sigmoid	5161.26	6192.23	0.067
1	15	—	ReLU	4132.11	5355.84	0.054
1	15	—	tanh	4319.88	5502.04	0.057
1	40	—	Sigmoid	4413.01	5608.68	0.058
1	40	—	ReLU	4296.01	5548.19	0.056
1	40	—	tanh	4222.02	5461.18	0.055
1	65	—	Sigmoid	4529.44	5741.30	0.060
1	65	—	ReLU	4104.73	5323.10	0.055
1	65	—	tanh	4118.46	5342.24	0.054
1	100	—	Sigmoid	4711.07	5763.45	0.061
1	100	—	ReLU	4158.14	5242.92	0.054
1	100	—	tanh	4182.41	5401.20	0.055
1	125	—	Sigmoid	4787.47	5874.26	0.062
1	125	—	ReLU	3988.94	5138.06	0.052
1	125	—	tanh	4107.89	5312.98	0.054
1	180	—	Sigmoid	4117.09	5464.14	0.055
1	180	—	ReLU	4401.53	5506.52	0.057
1	180	—	tanh	4101.77	5300.89	0.054
1	230	—	Sigmoid	4880.69	5917.51	0.062
1	230	—	ReLU	4172.45	5379.23	0.055
1	230	—	tanh	4274.10	5428.19	0.056
1	450	—	Sigmoid	5283.52	6310.39	0.067
1	450	—	ReLU	4156.59	5351.02	0.055
1	450	—	tanh	5147.47	6201.06	0.065
1	600	—	Sigmoid	4164.19	5355.49	0.055
1	600	—	ReLU	4220.50	5400.81	0.055
1	600	—	tanh	4195.27	5366.33	0.055
1	670	—	Sigmoid	5505.20	6538.48	0.069
1	670	—	ReLU	4705.37	5766.44	0.060
1	670	—	tanh	4100.58	5310.36	0.054
1	750	—	Sigmoid	4114.21	5324.69	0.054

1	750	–	ReLU	4058.71	5226.54	0.054
1	750	–	tanh	4186.58	5412.55	0.056
1	850	–	Sigmoid	4125.96	5347.72	0.055
1	850	–	ReLU	5057.97	6117.42	0.064
1	850	–	tanh	4209.25	5366.80	0.055
2	40	20	Sigmoid	6392.36	7171.82	0.080
2	40	20	ReLU	3910.30	5012.25	0.051
2	40	20	tanh	4637.26	5666.18	0.059
2	50	50	Sigmoid	5439.66	6337.01	0.069
2	50	50	ReLU	4256.12	5534.78	0.055
2	50	50	tanh	4872.66	5891.66	0.062
2	100	50	Sigmoid	5708.73	6585.16	0.072
2	100	50	ReLU	4143.81	5296.61	0.054
2	100	50	tanh	4063.48	5221.52	0.054
2	125	100	Sigmoid	4187.18	5506.03	0.056
2	125	100	ReLU	4575.94	5598.96	0.058
2	125	100	tanh	4147.50	5277.63	0.054
2	160	125	Sigmoid	4639.98	5722.94	0.060
2	160	125	ReLU	4153.43	5310.18	0.055
2	160	125	tanh	4996.91	5994.82	0.063
2	230	70	Sigmoid	4504.30	5625.38	0.059
2	230	70	ReLU	4228.96	5311.98	0.054
2	230	70	tanh	5396.62	6394.11	0.067
2	250	40	Sigmoid	4207.06	5622.20	0.057
2	250	40	ReLU	4103.82	5235.65	0.053
2	250	40	tanh	4962.40	5956.48	0.063
2	250	100	Sigmoid	4495.71	5622.75	0.059
2	250	100	ReLU	4026.43	5246.84	0.054
2	250	100	tanh	4054.33	5219.44	0.054
2	350	150	Sigmoid	4674.75	5743.75	0.061
2	350	150	ReLU	4000.51	5138.42	0.053
2	350	150	tanh	4080.52	5216.48	0.054
2	400	260	Sigmoid	4230.87	5500.72	0.056
2	400	260	ReLU	4284.50	5461.31	0.056

2	400	260	tanh	4154.43	5278.15	0.054
2	450	180	Sigmoid	4238.42	5476.20	0.056
2	450	180	reLU	4551.42	5594.40	0.058
2	450	180	tanh	4031.95	5210.00	0.053
2	480	350	Sigmoid	4150.54	5635.59	0.056
2	480	350	reLU	5102.49	6119.08	0.064
2	480	350	tanh	4240.45	5490.42	0.057
2	520	260	Sigmoid	4397.63	5579.06	0.058
2	520	260	reLU	3989.79	5118.81	0.052
2	520	260	tanh	4397.30	5444.12	0.057
2	600	150	Sigmoid	4943.62	5949.43	0.063
2	600	150	reLU	4137.06	5219.53	0.053
2	600	150	tanh	4569.01	5594.72	0.058
2	600	300	Sigmoid	7290.90	8455.52	0.090
2	600	300	reLU	4396.96	5464.37	0.056
2	600	300	tanh	4037.23	5237.23	0.054


Ağ yapısı araştırması kapsamında farklı sayıda katman, nöron ve farklı aktivasyon fonksiyonları kullanılarak toplam 90 deneme yapılmıştır. Denemeler sonucunda en iyi performans gösteren ağ mimarisi modelde kullanılmak üzere seçilmiştir. Seçilen ağ yapısına ait bilgiler Tablo 5.9’da yer almaktadır.

Tablo 5.9. Üçüncü analizin LSTM ağ mimarisi

Eğitim Veri Sayısı	700
Test Veri Sayısı	365
Gizli Katman Sayısı	1
Gizli Katmandaki Nöronlar	8
Aktivasyon Fonksiyonu	Sigmoid

Seilen modelde 8 n6ron ieren bir gizli katman bulunmaktadır. Modelin aktivasyon fonksiyonu olarak ‘‘Sigmoid’’ aktivasyon fonksiyonu seilmiřtir. Hata fonksiyonu ‘‘Hata Kareler Ortalaması’’ olarak belirlenmiř ve tasarlanan model derlenmiřtir. Derlemenin ardından model 700 eęitim verisi ile eęitilmiřtir. Eęitilen model ile 365 g6nl6k 6ng6r6 oluřturulmuřtur. Oluřturulan 6ng6r6 deęerleri geri 6leklendirilerek eski deęer aralıęına getirilmiřtir. Modelin performans 6l6tlerinin deęerleri bulunmuř ve kaydedilmiřtir.

LSTM modeli ile 6ng6r6len g6nl6k yolcu sayısı deęerlerinin ve test deęerlerinin grafięi řekil 5.7’de yer almaktadır.



řekil 5.7. 66nc6 veri setinin LSTM tahmin grafięi

řekil 5.7’de 01.06.2022 ve 31.05.2023 tarihleri arasındaki g6nl6k yolcu sayılarının tahmin deęerleri bulunmaktadır. Seilen y6ntem veri setiyle y6ksek bir uyum g6stererek gerek deęerlere yakın sonular elde edilmesini saęlamıřtır.

Uzun Kısa S6reli Bellek (LSTM) y6nteminde 6 farklı analiz iin toplam 270 aę yapısı denenmiř ve her analiz iin en uygun aę seilmiřtir. İlgili aęların MAE, RMSE ve MAPE 6l6tlerine bakılmıř ve sonular kaydedilmiřtir. Sırada modele Box-Jenkins y6nteminin uygulanması ve performans 6l6tlerine bakılması adımları bulunmaktadır.

5.4.2. Box-Jenkins Yöntemi


Box-Jenkins yöntemi geleneksel zaman serisi yöntemlerinden olan bir talep tahmin yöntemidir. Kapsamlı model belirleme adımları ve zaman serilerinde büyük bir performans göstermesi sebebiyle bu uygulamada kullanılmak üzere seçilmiştir. Box-Jenkins yönteminin aşamaları ve ayrıntılı açıklamaları Bölüm 4.2.1.2’de yer almaktadır. Talep tahmini uygulamasında kullanılacak yöntemin sözde kodu Şekil 5.8’de verilmiştir. Modele ait Python kodu ise Ek 5.2’de yer almaktadır.

Box-Jenkins Algorithm	
1	procedure Box-Jenkins
2	import libraries
3	import modules
4	
5	#model selection
6	import database
7	draw ACF, PACF plot
8	check stationarity
9	if not stationary: difference data
10	Repeat
11	Select model
12	import auto.arima
13	set parameters ← auto.arima
14	select best AIC
15	check diagnostics
16	if residuals are not suitable ← turn to model selection
17	if residuals are suitable ← break
18	
19	#prediction
20	split train and test data
21	model = selected model
22	compile model
23	fit model ← train data
24	make prediction ← test data
25	calculate MAE, RMSE and MAPE
26	
27	end procedure


Şekil 5.8. Box-Jenkins Pseudocode

Box-Jenkins yönteminde zaman serisine en uygun modelin belirlenebilmesi için Bölüm 4.2.1.2.1’de anlatıldığı üzere, ilk olarak korelogram grafikleri yardımıyla zaman serisinin durağanlık durumu incelenecektir.

Durağanlık tespiti için öncelikle 50 gecikmeli otokorelasyon fonksiyonu (ACF) ve kısmi otokorelasyon fonksiyonu (PACF) grafikleri oluşturulmuştur. Oluşturulan ACF grafiği Şekil 5.9’da ve PACF grafiği Şekil 5.10’da verilmiştir.




Şekil 5.9. Zaman serisinin ACF grafiği




Şekil 5.10. Zaman serisinin PACF grafiği

Otokorelasyon fonksiyonu (ACF) grafiği incelenmiş ve gecikmelerin tepe değerinden yavaş yavaş azalarak sıfıra doğru yaklaştığı gözlenmiştir. Grafikteki 50 otokorelasyon değeri çok yüksek olmakla birlikte güven sınırları dışında kalmaktadır. Bölüm 4.2.1.2.1’de anlatıldığı üzere ACF grafiğindeki böyle bir görüntü zaman serisinin durağan olmadığını ve durağanlaştırılması gerektiğinin ifadesidir. Bununla birlikte grafikteki trend ve mevsimsellik bileşenleri açıkça gözlenmektedir. Dolayısıyla zaman serisine uygulanacak Box Jenkins modelinin hem trend hem mevsimsellik parametrelerini barındıran bir Mevsimsel Otoregresif Entegre Hareketli Ortalama (SARIMA(p,d,q)(P,D,Q)_s) modeli olması gerektiği ortaya çıkmıştır.

Zaman serisinin mevsimsel olmayan ve mevsimsel farkları alınarak trend ve mevsimsellik etkisi kaldırılacaktır. İlk olarak zaman serisinin mevsimsel olmayan birinci dereceden farkı alınmıştır. Mevsimsel olmayan farkı alınan zaman serisinin ACF grafiği Şekil 5.11’de ve PACF grafiği Şekil 5.12’de yer almaktadır.




Şekil 5.11. Birinci derece farkı alınan zaman serisinin ACF grafiği




Şekil 5.12. Birinci derece farkı alınan zaman serisinin PACF grafiği

Birinci dereceden mevsimsel olmayan farkı alınmış zaman serisinin ACF ve PACF grafiklerine bakıldığında zaman serisinin trend etkisinden arındığı görülmektedir. Bu durumda farkı alınmış zaman serisinin trend durağan hale geldiği anlaşılmaktadır. Ancak gecikmelerde mevsimsellik bileşeninden kaynaklanan periyodik artışlar devam etmektedir. Bu artışlar 7 gecikmede bir meydana geldiği için mevsim periyodu 7 gün olarak kabul edilmiştir.

Zaman serisindeki trend etkisinin kaldırılmasının ardından mevsimsellik etkisinin de kaldırılması için serinin birinci dereceden mevsimsel farkı alınmıştır. Mevsimsel farkı alınan zaman serisinin ACF grafiği Şekil 5.13'te ve PACF grafiği Şekil 5.14'te yer almaktadır.



Şekil 5.13. Mevsimsel birinci derece farkı alınan zaman serisinin ACF grafiği



Şekil 5.14. Mevsimsel birinci derece farkı alınan zaman serisinin PACF grafiği

Birinci dereceden mevsimsel ve mevsimsel olmayan farkı alınan zaman serisinin otokorelasyon ve kısmi otokorelasyon grafiklerine bakıldığında zaman serisinin trend ve mevsimsellik etkilerinin kalkarak gecikmeler arasındaki anlamlılığın kaybolduğu, dolayısıyla serinin durağan hale geldiği görülmektedir. Mevsimsel olmayan birinci dereceden alınan farkla trend durağan hale geldiği için SARIMA(p,d,q)(P,D,Q)s modelinin d parametresi d=1 olarak belirlenmiştir. Aynı zamanda mevsimsel birinci dereceden alınan farkla mevsimsellik etkisi kalktığı için mevsimsellik derecesi D=1 ve mevsim periyodu s=7 olarak belirlenmiştir.

SARIMA(p,d,q)(P,D,Q)s modelinin d, D ve s parametrelerinin belirlenmesinin ardından modelin otoregresif (AR) ve hareketli ortalama (MA) derecelerinin belirlenmesi için “auto.arima” fonksiyonundan faydalanılmıştır.

“Auto.arima”; tanımlanan parametre aralığına göre veri setine farklı modelleri uygulayarak veri setine en uygun model parametrelerini Akaike Bilgi Kriteri (AIC) değerine göre belirlemektedir. Akaike Bilgi Kriterinin formülü Denklem 4.14’te verilmiştir.


“Auto.arima” fonksiyonu, verilen aralıktaki parametreler ile toplam 32 model çalıştırmıştır. Denemeler sonucunda ise en iyi Akaike Bilgi Kriteri değerini veren SARIMA(p,d,q)(P,D,Q)_s modelini SARIMA(2,1,2)(0,1,1)[7] olarak belirlemiştir. Auto.arima fonksiyonunun çalıştırdığı tüm denemeler ve Akaike Bilgi Kriteri değerleri Tablo 5.10’da yer almaktadır.

Tablo 5.10. SARIMA modelleri ve modellerin Akaike Bilgi Kriteri değerleri

SARIMA(p,d,q)(P,D,Q) _s	Akaike Bilgi Kriteri
ARIMA(2,1,2)(1,1,1)[7]	inf
ARIMA(0,1,0)(0,1,0)[7]	13440.703
ARIMA(1,1,0)(1,1,0)[7]	13318.963
ARIMA(0,1,1)(0,1,1)[7]	13226.820
ARIMA(0,1,1)(0,1,1)[7]	13432.257
ARIMA(0,1,1)(1,1,1)[7]	13227.336
ARIMA(0,1,1)(0,1,2)[7]	13227.411
ARIMA(0,1,1)(1,1,0)[7]	13312.139
ARIMA(0,1,1)(1,1,2)[7]	inf
ARIMA(0,1,0)(0,1,1)[7]	13250.918
ARIMA(1,1,1)(0,1,1)[7]	13199.561
ARIMA(1,1,1)(0,1,0)[7]	inf
ARIMA(1,1,1)(1,1,1)[7]	13233.180
ARIMA(1,1,1)(0,1,2)[7]	13233.165
ARIMA(1,1,1)(1,1,0)[7]	13263.001
ARIMA(1,1,1)(1,1,2)[7]	13200.565
ARIMA(1,1,0)(0,1,1)[7]	13262.800
ARIMA(2,1,1)(0,1,1)[7]	13201.337
ARIMA(1,1,2)(0,1,1)[7]	13201.203
ARIMA(0,1,2)(0,1,1)[7]	13203.148
ARIMA(2,1,0)(0,1,1)[7]	13212.625
ARIMA(2,1,2)(0,1,1)[7]	13198.270
ARIMA(2,1,2)(0,1,0)[7]	13384.534
ARIMA(2,1,2)(0,1,2)[7]	13202.575
ARIMA(2,1,2)(1,1,0)[7]	inf
ARIMA(2,1,2)(1,1,2)[7]	inf
ARIMA(3,1,2)(0,1,1)[7]	13216.405
ARIMA(2,1,3)(0,1,1)[7]	13211.868

ARIMA(1,1,3)(0,1,1)[7]	inf
ARIMA(3,1,1)(0,1,1)[7]	13232.241
ARIMA(3,1,3)(0,1,1)[7]	13230.698
ARIMA(2,1,2)(0,1,1)[7]	13224.807

“Auto.arima” fonksiyonu ile bir modelin seçilmesinin ardından seçilen modelin zaman serisine uygunluğunu görmek amacıyla teşhis grafikleri görselleştirilmiştir. SARIMA(2,1,2)(0,1,1)₇ modelinin standardize edilmiş kalıntı, histogram ve Kernel yoğunluk tahmini, Q-Q ve korelogram grafikleri Şekil 5.15’de verilmiştir.




Şekil 5.15. SARIMA(2,1,2)(0,1,1)₇ modelinin teşhis grafikleri

SARIMA(2,1,2)(0,1,1)₇ modelinin teşhis grafiklerinin uygunluğu incelenmiştir. Standardize edilmiş kalıntı grafiğinde kalıntılarda belirgin bir örüntü görülmemekte, kalıntılar rastgele dağılmaktadır. Histogram ve Kernel yoğunluk tahmini grafiğinde normal dağılıma benzer bir eğri gözlenmektedir. Q-Q grafiğinde noktaların büyük çoğunluğu çizginin üzerinde yer almakta, olağandışı bir sapma gözlenmemektedir. Korelogram grafiği ise önceki adımlarda incelendiği üzere modelin uyumunu göstermektedir. Dolayısıyla tüm teşhis grafikleri incelendiğinde modelin zaman serisine uygunluğu ortaya çıkmaktadır. İncelemelerin ardından seçilen model ile devam edilmesine ve veri setlerine ARIMA(2,1,2)(0,1,1)₇ modelinin uygulanmasına karar verilmiştir.

Nihai modele karar verilmesinin ardından son aşama olan öngörü adımına geçilmiştir. Birinci analiz için veri setinin 700 verisi eğitim ve 30 verisi test için ayrılmıştır. Ardından model eğitilerek 30 günlük öngörü yapılmıştır. Daha sonra uygulanan modellerin karşılaştırmasını yapmak amacıyla ilgili modelin performans ölçütleri kaydedilmiştir.

Birinci analizin SARIMA modeli öngörülen günlük yolcu sayısı değerlerinin ve test değerlerinin grafiği Şekil 5.16’da yer almaktadır.




Şekil 5.16. Birinci veri setinin SARIMA tahmin grafiği

Şekil 5.16'da 01.06.2022 ve 30.06.2022 tarihleri arasındaki günlük yolcu sayılarının tahmin değerleri bulunmaktadır. Zaman serisinin özellikle mevsimsellik bileşenini iyi bir şekilde modellediği görülmektedir. LSTM modelinde olduğu şekilde kriz döneminin yarattığı etkiler model performansını etkilememektedir.

Ardından ikinci analiz için veri setinin 700 verisi eğitim ve 92 verisi test için ayrılmıştır. Model eğitilerek 92 günlük öngörü yapılmış, modelin performans ölçütlerinin değerleri bulunmuş ve kaydedilmiştir.

İkinci analizin SARIMA modeli öngörülen günlük yolcu sayısı değerlerinin ve test değerlerinin grafiği Şekil 5.17'de yer almaktadır.




Şekil 5.17. İkinci veri setinin SARIMA tahmin grafiği

Şekil 5.17'de 01.06.2022 ve 31.08.2022 tarihleri arasındaki günlük yolcu sayılarının tahmin değerleri bulunmaktadır. İlk öngörü grafiğine benzer şekilde gerçek değerlere yakın sonuçlar görülmekle birlikte sapmaların azaldığı ve bu öngörü sonucunda daha yakın sonuçlar elde edildiği söylenebilir.

Son olarak üçüncü analiz için veri setinin 700 verisi eğitim ve 365 verisi test için ayrılmıştır. Model eğitilerek 365 günlük öngörü yapılmış, modelin performans ölçütlerinin değerleri bulunmuş ve kaydedilmiştir.

Üçüncü analizin SARIMA modeli öngörülen günlük yolcu sayısı değerlerinin ve test değerlerinin grafiği Şekil 5.18’de yer almaktadır.



Şekil 5.18. Üçüncü veri setinin SARIMA tahmin grafiği

Şekil 5.18’de 01.06.2022 ve 31.05.2023 tarihleri arasındaki günlük yolcu sayılarının tahmin değerleri bulunmaktadır. Bu öngörü modeli de zaman serisi ile iyi bir uyum göstermiştir.

Mevsimsel Otoresif Entegre Hareketli Ortalama (SARIMA) yönteminde üç farklı analiz ile üç farklı tahmin modeli oluşturulmuştur. İlgili ağların MAE, RMSE ve MAPE ölçütlerine bakılmış ve sonuçlar kaydedilmiştir. 5.4.3. bölümde 5.4.1 ve 5.4.2. bölümlerden elde edilen model sonuçları karşılaştırılacaktır.

5.4.3. Modellerin Performans Ölçütlerinin İncelenmesi

5.4.1 ve 5.4.2. bölümlerde Uzun Kısa Süreli Bellek (LSTM) ve SARIMA yöntemlerinin üç farklı veri seti için öngörülerini yapılmış ve MAE, RMSE ve MAPE performans ölçütlerine bakılmıştır. İlgili ölçütlerin formülleri Tablo 4.3'te yer almaktadır.

Tablo 5.11'da birinci analizin model sonuçlarının karşılaştırması, Tablo 5.12'de ikinci analizin model sonuçlarının karşılaştırması ve Tablo 5.13'te üçüncü analizin model sonuçlarının karşılaştırması verilmiştir.

Tablo 5.11. Birinci analizin LSTM ve SARIMA model sonuçlarının karşılaştırması

	LSTM	SARIMA
MAE	2654.09	1955.04
RMSE	3600.32	2487.45
MAPE	0.032	0.024

Tablo 5.12. İkinci analizin LSTM ve SARIMA model sonuçlarının karşılaştırması

	LSTM	SARIMA
MAE	2224.23	1469.10
RMSE	3123.26	1987.13
MAPE	0.025	0.016

Tablo 5.13. Üçüncü analizin LSTM ve SARIMA model sonuçlarının karşılaştırması

	LSTM	SARIMA
MAE	4233.16	1920.41
RMSE	4850.06	2920.81
MAPE	0.046	0.025


İki yöntemin üç analizdeki sonuçlarına bakıldığında tüm modellerde %95'in üzerinde bir başarı sağlandığı görülmüştür. İki yöntemin de hata değerleri istenilen aralıkta olmakla birlikte SARIMA modellerinden LSTM modellerine kıyasla daha düşük bir hata oranı elde edilmiştir. Bu nedenle çalışmanın üçüncü bölümündeki uçak çizelgesinin hazırlanması aşamasında SARIMA yönteminden faydalanılmasına karar verilmiştir.

5.5. Filo Çizelgesinin Oluşturulması

Karar destek sistemi uygulamasında veri ön işleme ve tahmin yöntemi seçme adımlarının ardından matematiksel modelin ve filo çizelgesinin oluşturulması aşamalarına geçilmiştir.

5.5.1. Uçak ve Uçuş Bilgilerinin Çekilmesi

Matematiksel modelin oluşturulabilmesi için Pegasus Hava Yolları'nın [97] web sitesinden hava yolunun gerçekleştirdiği uçuşlara ait bilgilere ulaşılmıştır. Pegasus Hava Yolları 43 şehire uçmakla birlikte bu uçuşların neredeyse tamamı İstanbul Sabiha Gökçen Havalimanı aracılığıyla gerçekleşmektedir. Bu nedenle çizelgeleme çalışmasında Sabiha Gökçen Havalimanı kalkışlı uçuşların kullanılmasına karar verilmiştir. Şekil 5.19'da ilgili hava yolunun Sabiha Gökçen Havalimanı kalkışlı uçuş noktaları harita üzerinde gösterilmiştir.



Şekil 5.19. Sabiha Gökçen Havalimanı uçuş noktaları

Sabiha Gökçen Havalimanı'nın [95] web sitesi üzerinden günlük Pegasus Hava Yolları'nın iç hat uçuş planı çekilmiştir. Tablo 5.14'te uçuş kodları, varış havalimanları, planlı kalkış ve iniş saatleri ve uçuş mesafeleri yer almaktadır.

Tablo 5.14. Günlük uçuş planı

UÇUŞ KODU	ŞEHİR	PLANLI KALKIŞ	PLANLI İNİŞ	MESAFE (Km)
PC 2098	ADANA	00:05	01:35	720
PC 2028	ANTALYA	00:15	01:30	502
PC 2404	GAZİANTEP	00:25	02:00	866
PC 2678	ANKARA	00:30	01:30	357
PC 2746	KAYSERİ	00:40	02:00	618
PC 2402	GAZİANTEP	05:45	07:20	866
PC 2000	ANTALYA	05:50	07:05	502
PC 2770	RİZE-ARTVIN	05:50	07:30	990
PC 2080	ADANA	05:55	07:25	720
PC 2180	İZMİR	05:55	07:05	347
PC 2380	DIYARBAKIR	06:10	08:00	1031
PC 4051	DALAMAN	06:10	07:25	493
PC 2860	ORDU-GİRESUN	06:15	07:50	762
PC 2430	MARDİN	06:25	08:20	1099
PC 2490	MUS	06:30	08:25	1131
PC 2590	KARS	06:55	08:55	1181
PC 2004	ANTALYA	07:20	08:35	502
PC 2662	ANKARA	07:20	08:20	357
PC 2790	SAMSUN	07:30	08:55	614
PC 2700	KONYA	07:45	08:55	477
PC 2150	ADİYAMAN	07:50	09:30	878
PC 2284	DALAMAN	07:55	09:10	493
PC 2814	TRABZON	07:55	09:35	906
PC 2184	İZMİR	08:05	09:15	347
PC 2006	ANTALYA	08:15	09:30	502
PC 2082	ADANA	08:50	10:20	720
PC 2792	SAMSUN	09:05	10:30	614
PC 2244	MILAS - BODRUM	09:15	10:30	482
PC 2732	KAYSERİ	09:15	10:35	618
PC 2008	ANTALYA	09:45	11:00	502
PC 2086	ADANA	10:35	12:05	720
PC 2664	ANKARA	10:40	11:40	357
PC 2816	TRABZON	11:00	12:40	906
PC 2188	İZMİR	11:20	12:30	347
PC 2734	KAYSERİ	11:40	13:00	618
PC 2010	ANTALYA	11:45	13:00	502
PC 2822	TRABZON	11:50	13:30	906

PC 2666	ANKARA	11:55	12:55	357
PC 2194	IZMIR	13:00	14:10	347
PC 2248	MILAS - BODRUM	13:05	14:20	482
PC 2286	DALAMAN	13:10	14:25	493
PC 2370	BATMAN	13:50	15:40	1105
PC 2088	ADANA	14:45	16:15	720
PC 2824	TRABZON	15:15	16:55	906
PC 2016	ANTALYA	15:25	16:40	502
PC 2570	MALATYA	15:30	17:05	835
PC 2668	ANKARA	16:20	17:20	357
PC 2092	ADANA	16:30	18:00	720
PC 2502	VAN	17:50	19:50	1293
PC 2204	IZMIR	18:15	19:25	347
PC 2384	DIYARBAKIR	18:15	20:05	1031
PC 2818	TRABZON	18:25	20:05	906
PC 2094	ADANA	18:30	20:00	720
PC 2554	ERZURUM	18:40	20:25	1062
PC 2292	DALAMAN	18:50	20:05	493
PC 2532	ELAZIG	18:55	20:40	937
PC 2670	ANKARA	18:55	19:55	357
PC 2218	IZMIR	19:05	20:15	347
PC 2258	MILAS - BODRUM	19:05	20:20	482
PC 2944	BALIKESIR	19:15	20:20	167
PC 2072	ALANYA GAZIPASA	19:30	20:45	593
PC 2862	ORDU-GIRESUN	19:40	21:15	762
PC 2420	SANLIURFA	19:45	21:30	970
PC 2022	ANTALYA	20:05	21:20	502
PC 2294	DALAMAN	20:05	21:20	493
PC 2096	ADANA	20:15	21:45	720
PC 2752	SIVAS	20:15	21:40	698
PC 2408	GAZIANTEP	20:20	21:55	866
PC 2672	ANKARA	20:30	21:30	357
PC 2740	KAYSERİ	20:40	22:00	618
PC 2794	SAMSUN	20:40	22:05	614
PC 2830	TRABZON	20:55	22:35	906
PC 2024	ANTALYA	21:00	22:15	502
PC 2706	KONYA	21:00	22:10	477
PC 2208	IZMIR	21:30	22:40	347
PC 2030	ANTALYA	21:45	23:00	502
PC 2676	ANKARA	22:05	23:05	357
PC 2026	ANTALYA	22:20	23:35	502
PC 2748	KAYSERİ	23:25	00:45	618
PC 2212	IZMIR	23:45	00:55	347
PC 2264	MILAS - BODRUM	23:45	01:00	482
PC 2698	ANKARA	23:50	00:50	357

Hava yolunun güncel filosuna ve filo bilgilerine 6 Mart 2023 tarihli “Yönetim Kurulu Yıllık Faaliyet Raporu” aracılığıyla ulaşılmıştır. Pegasus Hava Yolları’nın uçak filosunda 4 farklı uçak tipi ve toplam 101 uçak mevcuttur. Bunlardan 16 adeti Boeing 737-800, 8 adeti Airbus 320-200 CEO, 46 adeti Airbus 320-200 NEO ve 31 adeti Airbus 321-200 NEO’dur. Filodaki uçakların menzil ve koltuk kapasitesi bilgileri Tablo 5.15’te yer almaktadır.


Tablo 5.15. Hava yolu filo bilgileri

Uçak Tipi	Filodaki Uçak Sayısı	Menzil	Koltuk Kapasitesi
B737-800	16	4163	189
A320-200 CEO	8	4074	182
A320-200 NEO	46	4740	186
A321-200 NEO	31	4237	239

5.5.2. Örneklem Dışı Öngörü

Uçuş ve filo bilgilerinin çekilmesinin ardından Bölüm 5.4.3’te seçilen zaman serisi tahminleme yöntemi olan SARIMA yöntemi ile örneklem dışı öngörü gerçekleştirilmiştir.

Bölüm 5.4.2’de uygulandığı şekilde 1065 veri kullanılarak model eğitilmiş ve 7 günlük öngörü yapılmıştır. Şekil 5.20’de 3 aylık gerçek yolcu sayısı verileri ve 01.06.2023 ve 07.06.2023 tarih aralığındaki yolcu sayısı tahminleri yer almaktadır.



Şekil 5.20. 01.06.2023 ve 07.06.2023 tarih aralığındaki yolcu sayısı tahminleri

Örneklem dışı öngörü yapılmasının ardından öngörü yapılan günlere ait gerçek yolcu sayıları Pegasus Hava Yolları'ndan çekilmiştir. Tablo 5.16'da örneklem dışı öngörü değerleri ile gerçek yolcu sayılarının karşılaştırılması yer almaktadır.

Tablo 5.16. Örneklem dışı öngörü ile gerçek değerlerin karşılaştırılması

Tarih	Öngörü	Gerçek	Mutlak Hata
01-06-2023	31653	33177	1525
02-06-2023	33540	33981	441
03-06-2023	33382	33694	312
04-06-2023	32939	32948	8
05-06-2023	32604	32948	344
06-06-2023	30334	31857	1523
07-06-2023	30776	31283	507

Öngörü değerlerinin gerçek değerlere yakınlığı hesaplanmıştır. Performans ölçütlerinden MAE değeri 665.76, RMSE değeri 25.80, MAPE değeri ise 0.020 olarak bulunmuştur. Elde edilen sonuçlara bakıldığında SARIMA modeli ile oluşturulan örneklem dışı öngörü değerlerinin gerçek değerlere çok yakın olduğu ve modelin veri setinde başarılı olduğu görülmektedir.

5.5.3. Matematiksel Modelin Geliştirilmesi

Karar destek sistemi için oluşturulan matematiksel modelin amacı; yurtiçi uçuşlarındaki filo ataması problemini çözerek hava yolunun günlük uçuş kazancını enbüyükleyen uçuş-filo çizelgesinin oluşturulmasıdır. Matematiksel modelde kullanılan notasyonlar aşağıda yer almaktadır.

Kümeler ve İndisler:

$i \in I$ uçuş kümesi $i \in \{1, \dots, 82\}$

$k \in K$ uçak kümesi $k \in \{1, \dots, 4\}$

Parametreler:

D_i i uçuşunun yolcu talebi (adet)

M_i i uçuşunun mesafesi (km)

Cap_k k uçağının koltuk kapasitesi (adet)

S_k filoda bulunan k uçağının miktarı (adet)

Karar değişkenleri:

P_{ik} k uçağının i uçuşundaki karı (tl)

$X_{ik} \begin{cases} 1, & \text{eğer } k \text{ uçağı } i \text{ uçuşuna atandıysa} \\ 0, & \text{aksi halde} \end{cases}$

Amaç Fonksiyonu:

$$\max z = \sum_{i \in I} \sum_{k \in K} (X_{ik} \cdot P_{ik}) \quad (5.2)$$

Kısıtlar:

$$\sum_{k \in K} X_{ik} = 1 \quad \forall i \in I \quad (5.3)$$

$$\sum_{i \in I} X_{ik} \leq S_k \quad \forall k \in K \quad (5.4)$$

$$X_{ik} \cdot D_i \leq Cap_k \quad \forall i \in I, \forall k \in K \quad (5.5)$$

$$X_{ik} \in \{0,1\} \quad (5.6)$$

Denklem (5.2) matematiksel modelin amaç fonksiyonunu vermektedir. Hava yolu karının maksimize edilmesi amaçlanmaktadır. Denklem (5.3), her uçuşa yalnızca tek bir uçağın atanmasını sağlamaktadır. Denklem (5.4), her bir uçak modeli için toplam atanan uçuş miktarının filodaki o modele ait kapasitenin aşılmasını engellemektedir. Denklem (5.5), her bir uçuşun yolcu talebinden küçük koltuk kapasiteli bir uçağa atanmasını engellemektedir. Denklem (5.6) ise karar değişkeninin alabileceği değerleri göstermektedir.

$$P_{ik} = M_i \cdot ((1.07 \cdot D_i) - (0.65 \cdot Cap_k)) \quad \forall i \in I, \forall k \in K \quad (5.7)$$

Denklem (5.7) hava yolunun kazancını tanımlamaktadır. İlgili denklem ile koltuk kullanım oranının da aynı zamanda artması hedeflenmektedir. Modelde kazancı tanımlamakta kullanılan *Ücretli Yolcu Kilometre Birim Gelir (ÜYKBG)* ve *Arz edilen Koltuk Kilometre Başına Gider (AKKBG)* Pegasus Hava Yolları'nın "Yatırımcı İlişkileri" web sitesinde mevcut olan 2022 yılı "Mali Tablolar ve Denetçi Raporu" aracılığıyla ve 2.1, 2.2 ve 2.3. denklemler kullanılarak elde edilmiştir. Denklem (5.7)'in açılımı şu şekildedir:

$$Hava Yolu Kazancı = Uçuşun mesafesi * ((ÜYKBG * Yolcu Talebi) - (Arz edilen Koltuk Kilometre Başına Gider * Uçağın Koltuk Kapasitesi))$$

Varsayımlar:

- Uygulamada yalnızca Sabiha Gökçen Havalimanı kalkışlı uçuş verileri kullanılmıştır.
- Uygulamada 24 saatlik uçuş çizelgesi kullanılmıştır. 7 gün boyunca bu çizelgenin kullanıldığı varsayılmıştır.
- ÜYKBG ve AKKBG değerlerinin güncel olduğu varsayılmıştır.

- Hava yolu bünyesindeki tüm uçakların uygulama esnasında uçuşa müsait ve hazır oldukları varsayılmıştır.

Matematiksel model LINGO paket programında yazılmıştır. Yazılan modelin tamamı Ek 5.3'te verilmiştir.

5.5.4. Filo Atama Probleminin Çözümü

Matematiksel model LINGO paket programında 01.06.2023 tarihli veriler ile çalıştırılmış ve optimum sonuç elde edilmiştir. Tablo 5.17'de model çıktısından elde edilen, toplam 82 uçuş için her bir uçuşa atanan filo tipleri ve Tablo 5.18'de tüm uçuşların net kar değerleri yer almaktadır.

Tablo 5.17. 01.06.2023 tarihli uçak çizelgesi

Uçuş No	Uçuş Kodu	Filo Tipi	Uçuş No	Uçuş Kodu	Filo Tipi
1	PC 2098	B737-800	42	PC 2370	A321-200 NEO
2	PC 2028	A320-200 NEO	43	PC 2088	A320-200 NEO
3	PC 2404	A321-200 NEO	44	PC 2824	A320-200 CEO
4	PC 2678	A320-200 NEO	45	PC 2016	A321-200 NEO
5	PC 2746	A320-200 NEO	46	PC 2570	A321-200 NEO
6	PC 2402	A320-200 NEO	47	PC 2668	A321-200 NEO
7	PC 2000	A321-200 NEO	48	PC 2092	A320-200 NEO
8	PC 2770	A321-200 NEO	49	PC 2502	B737-800
9	PC 2080	A321-200 NEO	50	PC 2204	A320-200 NEO
10	PC 2180	A320-200 NEO	51	PC 2384	A321-200 NEO
11	PC 2380	A320-200 CEO	52	PC 2818	A320-200 CEO
12	PC 4051	A320-200 NEO	53	PC 2094	A320-200 NEO
13	PC 2860	A320-200 NEO	54	PC 2554	A320-200 CEO
14	PC 2430	A321-200 NEO	55	PC 2292	A320-200 NEO
15	PC 2490	A320-200 CEO	56	PC 2532	A320-200 CEO
16	PC 2590	A321-200 NEO	57	PC 2670	A320-200 NEO
17	PC 2004	A320-200 NEO	58	PC 2218	B737-800
18	PC 2662	A321-200 NEO	59	PC 2258	A320-200 NEO
19	PC 2790	A321-200 NEO	60	PC 2944	A321-200 NEO
20	PC 2700	A321-200 NEO	61	PC 2072	A320-200 NEO
21	PC 2150	A320-200 NEO	62	PC 2862	A320-200 NEO
22	PC 2284	A321-200 NEO	63	PC 2420	A321-200 NEO
23	PC 2814	A320-200 CEO	64	PC 2022	A321-200 NEO
24	PC 2184	A320-200 NEO	65	PC 2294	A321-200 NEO
25	PC 2006	A320-200 NEO	66	PC 2096	A320-200 NEO
26	PC 2082	A320-200 NEO	67	PC 2752	A320-200 NEO
27	PC 2792	A320-200 NEO	68	PC 2408	A321-200 NEO

28	PC 2244	A320-200 NEO	69	PC 2672	B737-800
29	PC 2732	A320-200 NEO	70	PC 2740	A320-200 NEO
30	PC 2008	A320-200 NEO	71	PC 2794	A320-200 NEO
31	PC 2086	A320-200 NEO	72	PC 2830	A321-200 NEO
32	PC 2664	A320-200 NEO	73	PC 2024	A320-200 NEO
33	PC 2816	A321-200 NEO	74	PC 2706	A320-200 NEO
34	PC 2188	A320-200 NEO	75	PC 2208	A321-200 NEO
35	PC 2734	A320-200 NEO	76	PC 2030	A320-200 NEO
36	PC 2010	A320-200 NEO	77	PC 2676	A320-200 NEO
37	PC 2822	A320-200 CEO	78	PC 2026	A320-200 NEO
38	PC 2666	A320-200 NEO	79	PC 2748	A320-200 NEO
39	PC 2194	A320-200 NEO	80	PC 2212	A320-200 NEO
40	PC 2248	A321-200 NEO	81	PC 2264	A320-200 NEO
41	PC 2286	A320-200 NEO	82	PC 2698	A320-200 NEO

Tablo 5.18. 01.06.2023 tarihli uçak çizelgesinin net kâr değerleri

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	56947	60457	58351	33547
PC 2028	27897	30344	28876	11582
PC 2404	86340	90562	88029	58195
PC 2678	14672	16412	15368	3070
PC 2746	15646	18659	16851	-4439
PC 2402	55334	59556	57023	27189
PC 2000	48999	51446	49978	32684
PC 2770	103861	108687	105792	71686
PC 2080	64590	68100	65994	41190
PC 2180	24169	25861	24846	12891
PC 2380	60825	65851	62835	27317
PC 4051	18983	21387	19945	2961
PC 2860	19276	22991	20762	-5489
PC 2430	98523	103881	100667	62806
PC 2490	55234	60748	57440	18477
PC 2590	121021	126779	123324	82639
PC 2004	19294	21741	20273	2979
PC 2662	35542	37283	36238	23940
PC 2790	51909	54902	53106	31954
PC 2700	48551	50877	49482	33049
PC 2150	64475	68755	66187	35940
PC 2284	43587	45991	44549	27565
PC 2814	20975	25392	22742	-8470
PC 2184	19768	21460	20445	8491
PC 2006	21025	23473	22004	4710
PC 2082	32896	36406	34300	9496
PC 2792	18176	21169	19373	-1779
PC 2244	23782	26132	24722	8117
PC 2732	25492	28505	26697	5407

PC 2008	21838	24285	22817	5523
PC 2086	47876	51386	49280	24476
PC 2664	24624	26365	25321	13022
PC 2816	87900	92316	89666	58455
PC 2188	13415	15107	14092	2138
PC 2734	41027	44039	42232	20942
PC 2010	37700	40147	38679	21385
PC 2822	62199	66616	63966	32754
PC 2666	14446	16187	15143	2844
PC 2194	23832	25524	24509	12555
PC 2248	50461	52810	51400	34796
PC 2286	10311	12715	11273	-5711
PC 2370	91399	96785	93553	55486
PC 2088	49952	53462	51356	26552
PC 2824	58806	63223	60573	29361
PC 2016	53668	56116	54647	37353
PC 2570	74551	78621	76179	47413
PC 2668	29078	30818	29774	17475
PC 2092	52415	55925	53819	29015
PC 2502	99209	105512	101730	57186
PC 2204	23060	24751	23736	11782
PC 2384	93088	98114	95098	59580
PC 2818	39691	44108	41458	10246
PC 2094	31155	34665	32559	7755
PC 2554	42900	48077	44971	8385
PC 2292	35394	37797	36355	19371
PC 2532	35731	40298	37558	5278
PC 2670	21563	23304	22259	9961
PC 2218	13528	15220	14205	2251
PC 2258	21162	23512	22102	5497
PC 2944	13790	14604	14115	8362
PC 2072	32885	35776	34042	13613
PC 2862	24210	27924	25695	-555
PC 2420	87974	92703	89866	56449
PC 2022	46688	49136	47667	30373
PC 2294	47531	49934	48492	31508
PC 2096	53729	57239	55133	30329
PC 2752	18018	21420	19379	-4667
PC 2408	70045	74267	71734	41900
PC 2672	27207	28947	27903	15605
PC 2740	11753	14765	12958	-8332
PC 2794	42923	45916	44120	22968
PC 2830	89393	93809	91159	59948
PC 2024	13280	15728	14259	-3035
PC 2706	28307	30632	29237	12804
PC 2208	33444	35136	34121	22166
PC 2030	11965	14412	12944	-4350
PC 2676	10784	12524	11480	-819

PC 2026	10988	13435	11967	-5327
PC 2748	23410	26423	24615	3325
PC 2212	15632	17324	16309	4354
PC 2264	29680	32030	30620	14015
PC 2698	22942	24683	23639	11340
Toplam	4	8	46	24

Tablo 5.18, her bir atama sonucunda işletmeye yansıyacak gelirleri göstermektedir. Matematiksel model optimum atama sonucunda amaç fonksiyonunu yani işletme karını 2.907.776 ₺ olarak hesaplamıştır. LINGO’da matematiksel model 01.06.2023 ve 07.06.2023 tarihleri için toplam 7 kere çalıştırılmış ve optimum sonuçlar elde edilmiştir. Matematiksel modeller sonucunda her gün için uçuş-filo atama çizelgesi ve günlük net kazanç değerleri bulunmuştur. Tüm modellere ait atama tabloları ekte sunulmuştur.

Son olarak, çalışma kapsamında oluşturulan filo atama matematiksel modelinin etkinliğini test etmek amacıyla Pegasus Hava Yolları’nın uçuş tarifesinde yer alan uçuşlara atadığı filolar uçuş takip web sitesinden çekilmiştir [98]. İlgili web sitesinde yalnızca son üç aylık veriler görüntülenebildiği için, ilgili uçuşların Ekim-Aralık 2023 tarihleri arasındaki bilgileri incelenmiştir. Örnek bir uçuş kodunun geçmiş uçuş bilgileri Şekil 5.21’de verilmiştir.

Tarih	Uçak	Kalkış Yeri	Varış Yeri
29-Eki-2023	A320	Istanbul Sabiha Gokcen Int'l (SAW / LTFJ)	İzmir Adnan Menderes Int'l (ADB / LTBJ)
28-Eki-2023	A320	Istanbul Sabiha Gokcen Int'l (SAW / LTFJ)	İzmir Adnan Menderes Int'l (ADB / LTBJ)
27-Eki-2023	A320	Istanbul Sabiha Gokcen Int'l (SAW / LTFJ)	İzmir Adnan Menderes Int'l (ADB / LTBJ)
26-Eki-2023	A320	Istanbul Sabiha Gokcen Int'l (SAW / LTFJ)	İzmir Adnan Menderes Int'l (ADB / LTBJ)
24-Eki-2023	A320	Istanbul Sabiha Gokcen Int'l (SAW / LTFJ)	İzmir Adnan Menderes Int'l (ADB / LTBJ)
24-Eki-2023	A320	Istanbul Sabiha Gokcen Int'l (SAW / LTFJ)	İzmir Adnan Menderes Int'l (ADB / LTBJ)
23-Eki-2023	A320	Istanbul Sabiha Gokcen Int'l (SAW / LTFJ)	İzmir Adnan Menderes Int'l (ADB / LTBJ)
22-Eki-2023	A320	Istanbul Sabiha Gokcen Int'l (SAW / LTFJ)	İzmir Adnan Menderes Int'l (ADB / LTBJ)
21-Eki-2023	A320	Istanbul Sabiha Gokcen Int'l (SAW / LTFJ)	İzmir Adnan Menderes Int'l (ADB / LTBJ)
20-Eki-2023	A320	Istanbul Sabiha Gokcen Int'l (SAW / LTFJ)	İzmir Adnan Menderes Int'l (ADB / LTBJ)
19-Eki-2023	A320	Istanbul Sabiha Gokcen Int'l (SAW / LTFJ)	İzmir Adnan Menderes Int'l (ADB / LTBJ)
18-Eki-2023	A320	Istanbul Sabiha Gokcen Int'l (SAW / LTFJ)	İzmir Adnan Menderes Int'l (ADB / LTBJ)
17-Eki-2023	A320	Istanbul Sabiha Gokcen Int'l (SAW / LTFJ)	İzmir Adnan Menderes Int'l (ADB / LTBJ)
16-Eki-2023	A320	Istanbul Sabiha Gokcen Int'l (SAW / LTFJ)	İzmir Adnan Menderes Int'l (ADB / LTBJ)
14-Eki-2023	A320	Istanbul Sabiha Gokcen Int'l (SAW / LTFJ)	İzmir Adnan Menderes Int'l (ADB / LTBJ)
13-Eki-2023	A320	Istanbul Sabiha Gokcen Int'l (SAW / LTFJ)	İzmir Adnan Menderes Int'l (ADB / LTBJ)
12-Eki-2023	A320	Istanbul Sabiha Gokcen Int'l (SAW / LTFJ)	İzmir Adnan Menderes Int'l (ADB / LTBJ)
12-Eki-2023	A320	Istanbul Sabiha Gokcen Int'l (SAW / LTFJ)	İzmir Adnan Menderes Int'l (ADB / LTBJ)
11-Eki-2023	A320	Istanbul Sabiha Gokcen Int'l (SAW / LTFJ)	İzmir Adnan Menderes Int'l (ADB / LTBJ)

Şekil 5.21. PC 2212 uçuş koduna ait geçmiş filo atamaları


İncelemelerin ardından uçuş koduna ait tüm uçuşlara sabit filonun atandığı uçuşlarda ilgili filo, uçuşlara göre filoların değişkenlik gösterdiği uçuş kodlarında ise son üç ay içerisinde en çok atanan filo çalışmada kullanılmak üzere kaydedilmiştir. Web sitesinden çekilen 82 uçuşa ait filo bilgileri ekte verilmiştir.

01.06.2023 ve 07.06.2023 tarih aralığı için hava yolunun atadığı filolar ile hava yolunun günlük kazanç değerleri tekrar hesaplanmıştır. Günlük atama tabloları ekte sunulmuştur.

Matematiksel model sonucunda hesaplanan günlük kazanç değerleri ile hava yolu tarafından atanan filo çizelgesinin kazanç değerlerinin karşılaştırması Tablo 5.19 ve Şekil 5.22’de verilmiştir.

Tablo 5.19. Günlük kazanç değerlerinin karşılaştırması

Gün	Matematiksel modelin atadığı filolar ile	Hava yolunun atadığı filolar ile
1	2907776	2897553
2	3386931	3378783
3	3341443	3274184
4	3171114	3107350
5	3034539	3047655
6	2760968	2321904
7	2772809	2434256



Şekil 5.22. Günlük kazanç değerlerinin karşılaştırması

Tablo 5.19 ve Şekil 5.22 incelendiğinde matematiksel modelin başarılı sonuç gösterdiği görülmektedir. Bununla birlikte, geliştirilen karar destek sistemi çerçevesinde yer alan filo atama matematiksel modeli ile haftalık kazançlarda %4 oranında iyileşme gerçekleştirildiği tespit edilmiştir.

6. SONUÇLAR VE TARTIŞMA

Küresel ekonominin belirleyicilerinden olan hava yolu endüstrisi son yıllarda büyük bir kriz döneminden geçmektedir. 2019 yılında ortaya çıkan ve 2020 yılında tüm dünyaya yayılarak etkisini gösteren COVID-19 salgınının önüne geçmek amacıyla ülkeler uçuşları durdurmuş, seyahat kısıtlamaları uygulamışlardır. Bunun sonucunda ise hava yolları operasyonları durma noktasına gelmiştir. Önlemlerin azaldığı, salgının en yoğun zamanının atlatıldığı zamanlarda bile yolcular kendilerini güvende hissetmedikleri için seyahatlerini ertelemişlerdir. Kriz dönemi sonrasında iflas noktasından dönen birçok hava yolu işletmesi bulunmaktadır. Diğer hava yolları ise yaşadıkları zararlardan kurtulmaya çalışmaktadır. Böyle bir dönem, hava yolu sektörünün hassaslığını tekrar gözler önüne sermiş ve sektörün yolculara olan bağlılığını hatırlatmıştır.

Bu tez çalışması ile hava yolu planlama süreçlerinin tüm adımlarında yer alan ve süreci belirleyen yolcu taleplerinin tahmin edilmesi ve hava yolunun önemli planlarından olan uçak atama probleminin çözümüne yönelik karar destek sisteminin oluşturulması amaçlanmıştır.

Tez çalışması kapsamında oluşturulan karar destek sistemi; veri ön işleme, tahmin yöntemi seçimi ve filo atama olarak üç ana aşamadan meydana gelmiştir. Karar destek sisteminin kurulabilmesi için öncelikle 01.07.2020 ve 31.05.2023 tarihleri arasındaki yolcu sayısı bilgileri Pegasus Hava Yolları'nın açık kaynak kodlu veri ambarından çekilmiştir.

Yinelemeli yapay sinir ağı mimarilerinden Uzun Kısa Süreli Bellek (LSTM) ve geleneksel zaman serisi tahmin yöntemlerinden Box-Jenkins çalışmada kullanılmak üzere seçilmiştir. LSTM ve Box-Jenkins yöntemleri ile üçer analiz yapılarak performans ölçütleri karşılaştırılmıştır. LSTM yönteminde en uygun ağ mimarisinin belirlenebilmesi için gizli katman sayıları ve nöron sayılarının her adımda artırıldığı ve aktivasyon fonksiyonlarının değiştirildiği 90 deneme yapılmıştır. Üç analiz için en uygun ağ mimarisi seçilerek zaman serisine uygulanmış, model sonuçları kayıt altına alınmıştır.

Ardından Box-Jenkins yöntemine geçilmiş, dört adımlı Box-Jenkins metodolojisi uygulanmıştır. İlk adımda veri setinin korelogram grafikleri incelenmiş ve durağanlık durumu araştırılmıştır. Veri setinin durağan olmadığı ve mevsimsellik bileşeni içerdiği gözlemlenerek uygulanacak modelin bir SARIMA(p,d,q)(P,D,Q)s modeli olmasına karar verilmiştir. Ardından “auto.arima” fonksiyonu kullanılarak en uygun model parametreleri araştırılmıştır. “Auto.arima” fonksiyonu ile 32 modelin Akaike Bilgi Kriteri değerlerine bakılmıştır. En düşük AIC değerine sahip model incelenmek üzere seçilmiş ve “geçici model” olarak adlandırılmıştır. Geçici modelin teşhis grafikleri görselleştirilmiş ve kalıntılar incelenmiştir. Teşhis grafiklerinin incelenmesi sonrasında modelin zaman serisine uygunluğuna karar verilerek geçici model “nihai model” durumuna geçmiştir. Nihai model ile üç analiz yapılmış ve sonuçları kayıt altına alınmıştır.

Üç analiz yapılan LSTM ve SARIMA model sonuçlarının Ortalama Mutlak Hata (MAE), Ortalama Mutlak Yüzde Hata (MAPE) ve Kök Ortalama Hata Kare (RMSE) performans metriklerine bakılmıştır. İki modelin tüm analizlerde %95’in üzerinde bir başarı sağladığı görülmüş, daha az hata oranına sahip SARIMA yöntemi karar destek sisteminin matematiksel modelinin hazırlanmasında kullanılmak üzere seçilmiştir.

Karar destek sisteminin son aşaması olan filo atama aşamasında, uçak ve uçuşlara dair bilgiler Pegasus Hava Yolları’nın açık kaynak kodlu veri ambarından çekilmiştir. Ardından SARIMA yöntemi kullanılarak örneklem dışı öngörü yapılarak ve 01.06.2023 ve 07.06.2023 tarih aralığındaki yolcu sayıları tahmin edilmiştir. Hava yolu net kazancının enbüyüklenmesi edilmesi amacıyla günlük uçuş-filo çizelgesinin geliştirildiği matematiksel model yazılmıştır. Yazılan model 01.06.2023 ve 07.06.2023 tarih aralığı için 7 kere çalıştırılmıştır. Haftalık filo çizelgesi ve hava yolu net kazancı bulunmuştur. Ardından çizelgede yer alan uçuşlara hava yolunun geçmiş dönemde atadığı gerçek filo bilgileri çekilmiştir. Hava yolunun atadığı filolar ile günlük hava yolu kazançları tekrar hesaplanmıştır. Geliştirilen matematiksel model ile haftalık hava yolu kazançlarında %4 oranında iyileşme gerçekleştirildiği tespit edilmiştir.

Bu tez çalışması ile özellikle kriz dönemleri ve kriz dönemi sonrası yüksek oynaklık ve belirsizlik gösteren hava yolu yolcu taleplerinin tahminine ve bu tahminler kullanılarak oluşturulan günlük filo atama probleminin çözümüne yönelik karar destek modeli geliştirilmiştir. Bu şekilde analitik yöntemler ile yolcu taleplerinin yüksek doğrulukta tahmin edilmesi sayesinde kriz dönemi operasyon planlaması daha verimli yapılabilecek ve bu zor dönemlerin mümkün olduğunca az zararlarla atlatılması mümkün hale gelecektir.

6.1. Gelecek Çalışmalar

Gelecek çalışmalar için verilebilecek öneriler şu şekildedir:

- Zaman serilerine uygulanacak tahmin yöntemleri arttırılabilir ve sezgisel yöntemler çalışmaya dahil edilebilir.
- Uçuş noktaları arttırılarak ve çift yön uçuşlar dahil edilerek çizelgeleme problemi büyütülebilir.
- Uçakların bekleme süreleri, bakım süreleri ve gecikmeler matematiksel modele dahil edilerek problem geliştirilebilir.
- Matematiksel modellemede ele alınan kısıtlarda bazı bulanık değerler dahil edilerek değişkenlikleri dikkate alan bir model geliştirilebilir.
- Uçuş çizelgesi modülü bu karar destek sistemine eklenebilir.
- Karar destek sistemi bir yazılım haline getirilebilir.

KAYNAKLAR

- [1] Belobaba, P., Odoni, A.R., Barnhart, C. The Global Airline Industry. John Wiley & Sons. 2009, United Kingdom
- [2] Ekonomiye Değer Katılması: Aviation: Benefits Beyond Borders. Erişim adresi: <https://aviationbenefits.org/economic-growth/adding-value-to-the-economy/> (26.04.2023)
- [3] ATAG, The Economic & Social Benefits Of Air Transport, 2005.
- [4] Sun, X., Wandelt, S., Zheng, C., Zhang, A. COVID-19 Pandemic and Air Transportation: Successfully Navigating The Paper Hurricane. Journal of Air Transport Management. 2021, 94.
- [5] International Air Transport Association, Annual Review 2023, 79th Annual General Meeting and World Air Transport Summit, 2023, İstanbul, Türkiye.
- [6] Anadolu Üniversitesi. Hava Taşımacılığı. Açıköğretim Fakültesi Yayını, No: 2204, Eskişehir, 2019, 197s. 3.
- [7] Anadolu Üniversitesi. Havayolu Yönetimi. Açıköğretim Fakültesi Yayını, No: 2205, Eskişehir, 2019, 230 s. 4.
- [8] IATA, Global Outlook for Air Transport. IATA Economics Report, 2022.
- [9] The World of Air Transport in 2021. Erişim adresi: <https://www.icao.int/sustainability/WorldofAirTransport/Pages/the-world-of-air-transport-in-2021.aspx> (03.05.2023)
- [10] Barnhart, C., Belobaba, P., Odoni, A.R. Applications of Operations Research in the Air Transport Industry. Transportation Science. 2003, 37(4), 368-391.
- [11] Ticarete Olanak Sağlama: Aviation: Benefits Beyond Borders. Erişim adresi: <https://aviationbenefits.org/economic-growth/enabling-trade/> (26.04.2023)
- [12] Turizm Kolaylaştırıcı: Aviation: Benefits Beyond Borders. Erişim adresi: <https://aviationbenefits.org/social-development/tourism-enabler/> (26.04.2023)
- [13] İstihdamın Desteklenmesi: Aviation: Benefits Beyond Borders. Erişim adresi: <https://aviationbenefits.org/economic-growth/supporting-employment/> (26.04.2023)
- [14] Toplumun Yaşam Çizgisi: Aviation: Benefits Beyond Borders. Erişim adresi: <https://aviationbenefits.org/social-development/community-lifeline/> (02.05.2023)
- [15] Hızlı Afet Müdahalesi: Aviation: Benefits Beyond Borders. Erişim adresi: <https://aviationbenefits.org/social-development/rapid-disaster-response/> (02.05.2023)
- [16] Anadolu Üniversitesi. Havayolu İşletmelerinde Operasyonel Planlama. Açıköğretim Fakültesi Yayını, No: 2649, Eskişehir, 2019, 238 s. 2.
- [17] Dünya Hava Taşımacılığı İstatistikleri. Erişim adresi: <https://www.iata.org/en/publications/store/world-air-transport-statistics/> (24.04.2023)

- [18] Jin, F., Li, Y., Sun, S., Li, H. Forecasting Air Passenger Demand with a New Hybrid Ensemble Approach. *Journal of Air Transport Management*. 2020, 83.
- [19] IATA, 9.11, Fact Sheet. Erişim adresi: <https://www.iata.org/contentassets/49a331cdfb85447cac12894e01aabb5c/fact-sheet-iata-9-11.pdf> (15.12.2023)
- [20] Erim, T. Ekonomik Krizler Ve Hava Taşımacılığına Etkileri: Türk Hava Taşımacılığı Örneği. Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, İktisat Anabilim Dalı, İstanbul, 2012, 140 s. (Doktora Tezi).
- [21] Tün, S. Y. Küresel Ekonomik Kriz Döneminde (2008) Türkiye'deki Havayolu İşletmelerinin Uyguladığı Pazarlama Stratejileri. Anadolu Üniversitesi Sosyal Bilimler Enstitüsü, Sivil Havacılık Yönetimi Anabilim Dalı, Eskişehir, 2013, 152 s. (Yüksek Lisans Tezi)
- [22] IATA, Annual Report, 2009.
- [23] WHO, SARS. Erişim adresi: https://www.who.int/health-topics/severe-acute-respiratory-syndrome#tab=tab_1 (25.05.2023)
- [24] Heiets, I., Xie, Y. The Impact of the COVID-19 Pandemic on the Aviation Industry. *Journal of Aviation*, 2021, 5(2), 111-126.
- [25] ICAO Newsroom, 2020. Erişim adresi: <https://www.icao.int/Newsroom/Pages/2020-passenger-totals-drop-60-percent-as-COVID19-assault-on-international-mobility-continues.aspx> (24.05.2023)
- [26] Orhan, İ., Kapanoğlu, M., Karakoç, H. Havayolu Operasyonlarında Planlama ve Çözümleme. Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi. 2010, 16, 2, 181-191.
- [27] Ünal, Y.Z., Sevkli, M., Uysal, Ö., Türkyılmaz, A. A New Approach to Fleet Assignment and Aircraft Routing Problems. *Transportation Research Procedia*. 2021, 59, 67–75.
- [28] Ba-Fail, A.O., Abed, S.Y., Jasimuddin, S.M. An Econometric Analysis of International Air Travel Demand in Saudi Arabia. *Journal of Air Transport Management*. 2001, 7, 143-148.
- [29] Erdem, I. Ülkemizdeki Havalimanlarının Yolcu ve Uçak Taleplerinin Çok Yönlü Değerlendirilmesi. Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, Ulaştırma Anabilim Dalı, İzmir, 2012, 100 s. (Yüksek Lisans Tezi).
- [30] Önder, E., Kuzu, S. Forecasting Air Traffic Volumes Using Smoothing Techniques. *Journal of Aeronautics & Space Technologies*. 2014, 7(1), 65-85.
- [31] Ozan, C., Başkan, Ö., Haldenbilen, S., Ceylan, H. Yurtiçi Hava Taşımacılığı Talebinin Modellenmesi ve Senaryolar Altında Değerlendirilmesi. Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi. 2014, 20(9), 319-323.

- [32] Gürler, H. Türkiye'deki Havalimanlarının Etkinlik Tahmini: Veri Zarflama Analizi ve Yapay Sinir Ağlarının Birlikte Kullanımı. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İşletme Mühendisliği Anabilim Dalı, İstanbul, 2015, 112 s. (Yüksek Lisans Tezi).
- [33] Srisaeng, P., Baxter, G., Richardson, S., Wild, G. A Forecasting Tool for Predicting Australia's Domestic Airline Passenger Demand Using a Genetic Algorithm. *Journal of Aerospace Technology and Management*. 2015, 7(4), 476-489.
- [34] Küçükyılmaz, A., Durak, M., Özdemir, E., Kiracı, K., Tanrıverdi, G. Eskişehir İlinde Havayolu Yolcu Potansiyelinin Belirlenmesi Üzerine Bir Karar Ağacı Uygulaması. *Anadolu Üniversitesi Bilim ve Teknoloji Dergisi B*. 2016, 5(1), 22-33.
- [35] Phyoe, S.M., Guo, R., Zhong, Z.W. An Air Traffic Forecasting Study and Simulation. *Matter: International Journal of Science and Technology*. 2016, 2(3), 55-69.
- [36] Aladağ, A.O. Havayolları İkrım Sektöründe Orta ve Uzun Vadeli Talep Analizi. İstanbul Teknik Üniversitesi, Sosyal Bilimler Enstitüsü, İktisat Anabilim Dalı, İstanbul, 2016, 117 s. (Yüksek Lisans Tezi).
- [37] İlgün, D. Hava Kargoculuğunda Pazar Payı Tahmini. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, İstanbul, 2016, 95 s. (Yüksek Lisans Tezi).
- [38] Koç, İ. Türkiye'de İç Hatlarda Havayolu Yolcu Taleplerinin Yapay Sinir Ağları Kullanarak Tahmini. İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, İstanbul, 2017, 125 s. (Yüksek Lisans Tezi).
- [39] Dantas, T., Oliveira, F., Repolho, H. Air Transportation Demand Forecast Through Bagging Holt Winters Methods. *Journal of Air Transport Management*. 2017, 59, 116-123.
- [40] Efendigil, T., Eminler, Ö. Havacılık Sektöründe Talep Tahmininin Önemi: Yolcu Talebi Üzerine Bir Tahmin Modeli. *Tarım ve Gıda Değer Zincirlerinde Yöneylem Araştırmaları ve Endüstri Mühendisliği*. 2017, 12 (Özel Sayı), 14-30.
- [41] Kalathilparmbil, Ç., Şahin, Ö. Türkiye'deki Hava Taşımacılığı Üzerine Bir Tahminleme Çalışması. *Anemon Muş Alparslan Üniversitesi Sosyal Bilimler Dergisi*. 2019, 7(4), 53-62.
- [42] Yazgan, H.R., Candan, G., Ataman, M. Talep Tahmini ve Dinamik Fiyatlandırma ile Havayolu Bilet Fiyatlarının Belirlenmesi, *İşletme Araştırmaları Dergisi*. 2019, 11 (2), 732-742.
- [43] Wang, H., Gao, X. Oil Price Dynamics and Airline Earnings Predictability. *Journal of Air Transport Management*. 2020, 87.
- [44] Madhavan, M., Sharafuddin, M. A., Piboonrungrroj, P., Yang, C. Short-term Forecasting for Airline Industry: The Case of Indian Air Passenger and Air Cargo. *Global Business Review*. 2020, 1-35.

- [45] Al-Sultan, A.T., Al-Rubkhi, A., Alsaber, A., Pan, J. Forecasting Air Passenger Traffic Volume: Evaluating Time Series Models in Long-Term Forecasting of Kuwait Air Passenger Data. *Advances and Applications in Statistics*. 2021, 70(1), 69-89.
- [46] Imanaka, K., Sakama, C. Predicting Air Ticket Demand using Deep Neural Networks. *IEEE International Conference on Big Data (Big Data)*. 2021, 2901-2908.
- [47] Arı, D. Yapay Sinir Ağı İle Havalimanı Yolcu Sayısı Tahmini ve Bazı Tahminleme Yöntemleri ile Karşılaştırmalı Analiz. *Manisa Celal Bayar Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Manisa, 2023, 221 s. (Yüksek Lisans Tezi)*.
- [48] Günay, F., Bayraktaroğlu, E., Özkul, K. Assessing the Short-term Impacts of COVID-19 Pandemic on Foreign Visitor's Demand for Turkey: A Scenario Analysis. *Journal of Ekonomi*. 2020, 04, 80–85.
- [49] Iacus, S.M., Natale, F., Santamaria, C., Spyros, S., Vespe, M. Estimating and Projecting Air Passenger Traffic During The COVID-19 Coronavirus Outbreak and Its Socio-Economic Impact. *Safety Science*. 2020, 129
- [50] Cheong, M., Chong, U., Nguyen, A., Ang, S., Djojoputro, G., Adiprasetyo, G., Gadong, K. Singapore Airlines: Profit Recovery and Aircraft Allocation Models during the COVID-19 Pandemic. *Proceedings of the 11th Annual International Conference on Industrial Engineering and Operations Management*. 2021.
- [51] Truong, D. Estimating the Impact of COVID-19 on Air Travel in the Medium and Long Term Using Neural Network and Monte Carlo Simulation. *Journal of Air Transport Management*. 2021, 96.
- [52] Li, X., Groot, M., Bäck, T. Using Forecasting to Evaluate the Impact of COVID-19 on Passenger Air Transport Demand. *Decision Sciences*. 2021, 1–16.
- [53] Gudmundsson, S.V., Cattaneo, M., Redondi, R. Forecasting Temporal World Recovery in Air Transport Markets in the Presence of Large Economic Shocks: The Case of COVID-19. *Journal of Air Transport Management*. 2021, 91.
- [54] Alnıpak, S., Apak, S. COVID-19'un Türk Havalimanlarının Verimliliğine Tahmini Etkisi: Malmquist Toplam Faktör Verimlilik Endeksi Uygulaması. *Trakya Üniversitesi Sosyal Bilimler Dergisi*, 2021, 23(2), 911-928.
- [55] Nurmi, N. Forecasting Airport Passenger Traffic in the Era of COVID-19 Pandemic. *Lappeenranta-Lahti University of Technology, School of Business and Management, Finlandiya, 2021, 100 s. (Yüksek Lisans Tezi)*.
- [56] Barczak, A., Dembinska, I., Rozmus, D., Szopik-Depczynska, K. The Impact of COVID-19 Pandemic on Air Transport Passenger Markets-Implications for Selected EU Airports Based on Time Series Models Analysis. *Sustainability*, 2022, 14.
- [57] Rabbouch, H., Saadaoui, H., Saâdaoui, F. VMD-based Multiscaled LSTM-ARIMA to Forecast Post-COVID-19 US Air Traffic. *International Conference on Decision Aid Sciences and Applications*. 2022.

- [58] Sherali, H. D., Bish, E. K., Zhu, X. Airline Fleet Assignment Concepts, Models, and Algorithms. *European Journal of Operational Research*. 2006, 172, 1-30.
- [59] Sarsenov, B. Filo Atama Probleminin İncelenmesi ve Türk Hava Yolları İçin Bir Vaka Çalışması. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, İstanbul, 2011 (Yüksek Lisans Tezi).
- [60] Pilla, V.L., Rosenberger, J.M., Chen, V., Engsuwan, N., Siddappa, S. A Multivariate Adaptive Regression Splines Cutting Plane Approach for Solving a Two-Stage Stochastic Programming Fleet Assignment Model. *European Journal of Operational Research*. 2012, 216, 162-71.
- [61] Li, Y., Tan, N. Study on Fleet Assignment Problem Model and Algorithm. Hindawi Publishing Corporation. 2013.
- [62] Şafak, Ö., Çavuş, Ö., Aktürk, M.S. Multi-Stage Airline Scheduling Problem With Stochastic Passenger Demand and Non-Cruise Times. *Transportation Research Part B*. 2018, 114, 39–67.
- [63] Liu, M., Liang, B., Zheng, F., Chu, F. Stochastic Airline Fleet Assignment with Risk Aversion. *IEEE Transactions on Intelligent Transportation Systems*. 2019, 20, 8.
- [64] Polat, F. Havayolu İşletmelerinde Filo Ataması Optimizasyonu İçin Hibrit Model Önerisi: Türk Hava Yolları Örneği.
- [65] İnanç, Y. Havayolu Taşımacılığında Yapay Sinir Ağı Yaklaşımı: Türk Hava Yolları Örneği. Çanakkale Onsekiz Mart Üniversitesi, Lisansüstü Eğitim Enstitüsü, Uluslararası Ticaret ve Lojistik Anabilim Dalı, Çanakkale, 2022 (Yüksek Lisans Tezi).
- [66] Liu, M., Ding, Y. Sun, L., Zhang, R., Dong, Y., Zhao, Z., Wang, Y., Liu, C. Green Airline-Fleet Assignment with Uncertain Passenger Demand and Fuel Price. *Sustainability*. 2023, 15, 899.
- [67] Glomb, L., Liers, F., Rösel, F. Optimizing Integrated Aircraft Assignment and Turnaround Handling. *European Journal of Operational Research*. 2023, 310, 1051–1071.
- [68] Özdemir, A., Özdemir, A. Talep Tahminlemede Kullanılan Yöntemlerin Karşılaştırılması: Seramik Ürün Grubu Firma Uygulaması. *Ege Academic Review*. 2006, 6(2), 105-114.
- [69] Göktaş, Ö. Teorik ve Uygulamalı Zaman Serileri Analizi. Beşir Kitabevi, İstanbul, 2005.
- [70] Bozkurt, H. Zaman Serileri Analizi. Ekin Yayınevi, Bursa, Türkiye, 2013, 237.
- [71] Akgül, I. Zaman Serilerinin Analizi ve ARIMA Modelleri. DER Yayınevi, İstanbul, Türkiye, 2003, 251.
- [72] Wen, K., Zhao, G., He, B., Ma, J., Zhang, H. A Decomposition-Based Forecasting Method with Transfer Learning for Railway Short-Term Passenger Flow in Holidays. *Expert Systems with Applications*. 2022, 189.

- [73] Zhang, G. P. Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*. 2003, 50, 159 – 175.
- [74] Kovačić, Z. The Time Series Analysis. University of Belgrade. Faculty of Economics, Belgrade, 1995.
- [75] Silva, I.N., Spatti, D.H., Flauzino, R.A., Liboni, L.H.B., Alves, S.F.R. Artificial Neural Networks. Springer Nature, Switzerland, 2017.
- [76] Efe, Ö., Kaynak, O. Yapay Sinir Ağları ve Uygulamaları. Boğaziçi Üniversitesi, İstanbul, 2000.
- [77] Kızrak, 2019 <https://ayyucekizrak.medium.com/derin-öğrenme-için-aktivasyon-fonksiyonlarının-karşılaştırılması-cee17fd1d9cd> (Erişim tarihi: 10.11.2023)
- [78] Sharma, S., Sharma, S. Activation Functions in Neural Networks. *International Journal of Engineering Applied Sciences and Technology*. 2020, 4, 12.
- [79] Liu, M., Ding, L., Bai, Y. Application of Hybrid Model Based on Empirical Mode Decomposition, Novel Recurrent Neural Networks and the ARIMA to Wind Speed Prediction. *Energy Conversion and Management*. 2021, 233.
- [80] Bianchi, F.M, Maiorino, E., Kampffmeyer, M.C., Rizzi, A., Jenssen, R. Recurrent Neural Networks for Short-Term Load Forecasting: An Overview and Comparative Analysis. Springer Nature, 2017.
- [81] Metin, İ.A., Karasulu, B. İnsan Aktivitelerinin Sınıflandırılmasında Tekrarlayan Sinir Ağı Kullanan Derin Öğrenme Tabanlı Yaklaşım. *Veri Bilim Derg*, 2019, 2(2), 1-10.
- [82] Liu, X., Guo, H. Air Quality Indicators and AQI Prediction Coupling Long-Short Term Memory (LSTM) and Sparrow Search Algorithm (SSA): A Case Study of Shanghai. *Atmospheric Pollution Research*, 2022, 13.
- [83] Eurocontrol. Daily Traffic Variation, Aircraft Operators. <https://www.eurocontrol.int/Economics/DailyTrafficVariation-AOs.html>. (Erişim tarihi: 13.06.2023)
- [84] Pegasus Hava Yolları. Trafik Bilgileri. <https://www.pegasusyatirimciiliskileri.com/tr/operasyonel-ve-finansal-veriler/trafik-bilgileri>. (Erişim tarihi: 13.06.2023)
- [85] Sabiha Gökçen Havalimanı. Uçuş Bilgi Ekranı. <https://www.sabihagokcen.aero/yolcu-ve-ziyaretçiler/yolcu-rehberi/ucus-bilgi-ekrani>. (Erişim tarihi: 12.09.2023)
- [86] Eurocontrol, About us. <https://www.eurocontrol.int/about-us> (Erişim tarihi: 13.06.2023)
- [87] Jupyter Notebook. <https://jupyter.org/>. (Erişim tarihi: 21.10.2023)
- [88] Python. <https://www.python.org/about/> (Erişim tarihi: 21.10.2023)
- [89] Pandas. <https://pandas.pydata.org/> (Erişim tarihi: 21.10.2023)

- [90] Statsmodels. <https://www.statsmodels.org/> (Eriřim tarihi: 21.10.2023)
- [91] Scikit-Learn. <https://scikit-learn.org/> (Eriřim tarihi: 21.10.2023)
- [92] Matplotlib. <https://matplotlib.org/> (Eriřim tarihi: 21.10.2023)
- [93] Numpy. <https://numpy.org/> (Eriřim tarihi: 21.10.2023)
- [94] Keras. <https://keras.io/> (Eriřim tarihi: 21.10.2023)
- [95] Pyramid-arima. <https://pypi.org/project/pmdarima/> (Eriřim tarihi: 21.10.2023)
- [96] LINGO. <https://www.lindo.com/index.php/products/lingo-and-optimization-modeling> (Eriřim tarihi: 21.10.2023)
- [97] Pegasus Hava Yolları Uçuřları. <https://www.flypgs.com/> (Eriřim tarihi: 12.09.2023)
- [98] <https://tr.flightaware.com/> (29.12.2023)

EKLER

EK 5.1. Uzun Kısa Süreli Bellek Python Kodu

```
1 import numpy as np
2 import pandas as pd
3 import matplotlib.pyplot as plt
4 from keras.models import Sequential
5 from keras.layers import Dense, LSTM
6 from keras import metrics
7 from sklearn.preprocessing import MinMaxScaler
8 from sklearn.model_selection import train_test_split
9
10 df = pd.read_csv('Pegasus3m.csv')
11 df.head()
12
13 L = len(df)
14 Y = df.iloc[:,1]
15 Y= np.array(Y)
16 Y= Y.reshape(-1,1)
17 plt.plot(Y)
18 plt.show(block= False)
19
20 X1= Y[0:L-3,:]
21 X2=Y[1:L-2,:]
22 X3=Y[2:L-1,:]
23 Y = Y[3:L,:]
24 X= np.concatenate([X1,X2,X3],axis=1)
25
26 scaler = MinMaxScaler()
27 scaler.fit(X)
28 X = scaler.transform(X)
29 scaler1 = MinMaxScaler()
30 scaler1.fit(Y)
31 Y = scaler1.transform(Y)
32 X= np.reshape(X, (X.shape[0],1,X.shape[1]))
33
34 X_train = X[:697,:,:]
35 X_test = X[697:,:,:]
36 Y_train = Y[:697,:]
37 Y_test = Y[697:,:]
38
39 model = Sequential()
40 model.add(LSTM(520,activation = 'sigmoid',input_shape = (1,3), return_sequences=True))
41 model.add(LSTM(260,activation='sigmoid', return_sequences=False))
42 model.add(Dense(1))
43 model.compile(loss= 'mean_squared_error',optimizer = 'adam', metrics=[metrics.mae])
44 model.fit(X_train,Y_train,epochs=100,verbose=2)
45 Predict = model.predict(X_test)
46
47 Y_train = scaler1.inverse_transform(Y_train)
48 Y_train = pd.DataFrame(Y_train)
49 Y_train.index = pd.to_datetime(df.iloc[3:700,0])
50 Y_test = scaler1.inverse_transform(Y_test)
```

```
51     Y_test = pd.DataFrame(Y_test)
52     Y_test.index = pd.to_datetime(df.iloc[700:,0])
53     Predict = model.predict(X_test)
54     Predict = scaler1.inverse_transform(Predict)
55     Predict = pd.DataFrame(Predict)
56     Predict.index=pd.to_datetime(df.iloc[700:,0])
57     plt.figure(figsize=(15,10))
58     plt.plot(Y_test)
59     plt.plot(Predict)
60     plt.show()
```



EK 5.2. Box-Jenkins Python Kodu

Modelin tanımlanması

```
1  import pandas as pd
2  import numpy as np
3  import matplotlib.pyplot as plt
4  from statsmodels.tsa.stattools import adfuller
5  from statsmodels.graphics.tsaplots import plot_acf, plot_pacf
6
7  df = pd.read_csv("PegasusTrain.csv", index_col="Tarih", parse_dates=True, squeeze=True)
8  df.index = df.index.to_period('D')
9
10 fig, (ax1,ax2) = plt.subplots(2,1,figsize=(12,15))
11 plot_acf(df, lags=50, zero=False, ax=ax1)
12 plot_pacf(df,lags=50, zero=False, ax=ax2)
13 plt.show()
14
15 df_stationary = df.diff().dropna()
16
17 fig, (ax1,ax2) = plt.subplots(2,1,figsize=(12,15))
18 plot_acf(df_stationary, lags=50, zero=False, ax=ax1)
19 plot_pacf(df_stationary,lags=50, zero=False, ax=ax2)
20 plt.show()
21
22 df_seasonal = df_stationary.diff(7).dropna()
23
24 fig, (ax1,ax2) = plt.subplots(2,1,figsize=(12,15))
25
26 plot_acf(df_seasonal, lags=50, zero=False, ax=ax1)
27 plot_pacf(df_seasonal,lags=50, zero=False, ax=ax2)
28 plt.show()
```

Auto.arima ve Teşhis Diyagramları

```
1  import warnings;
2  warnings.simplefilter('ignore')
3  import pandas as pd
4  import matplotlib.pyplot as plt
5  from pandas import DataFrame
6  from pmdarima import auto_arima
7  from statsmodels.tsa.arima.model import ARIMA
8  import pmdarima as pm
9
10 df = pd.read_csv("PegasusTrain.csv", index_col="Tarih", parse_dates=True, squeeze=True)
11
12 modelsecim = pm.auto_arima(df, seasonal=True, m=7,d=1, D=1, max_p=5, max_q=5,
13                             trace=True, error_action="ignore",
14                             suppress_warnings=True)
15 print(modelsecim.summary())
16
17 modelsecim.plot_diagnostics(figsize=(13,10))
18 plt.show()
```

Öngörü

```
1  import warnings
2  from statsmodels.tools.sm_exceptions import ConvergenceWarning
3  warnings.simplefilter('ignore', ConvergenceWarning)
4  import pandas as pd
5  import seaborn as sns
6  import matplotlib.pyplot as plt
7  from pandas import DataFrame
8  from statsmodels.tsa.arima.model import ARIMA
9
10 df = pd.read_csv("Pegasus1m.csv")
11 df= df.set_index(['Tarih'])
12 X = df.values
13 train, test = X[0:700], X[700:len(X)]
14 history = [x for x in train]
15 predictions = list()
16
17 for t in range(len(test)):
18     model = ARIMA(history, order=(2,1,2), seasonal_order=(0,1,1,7))
19     model_fit = model.fit()
20     output = model_fit.forecast()
21     yhat = output[0]
22     predictions.append(yhat)
23     obs = test[t]
24     history.append(obs)
25     print('predicted=%f, expected=%f' % (yhat, obs))
26
27 plt.plot(test)
28 plt.plot(predictions, color='red')
29 plt.show()
```

EK 5.3. Filo Atama Matematiksel Modeli

MODEL:

SETS:

FLIGHT/1..82/: D, M;
AIRCRAFT/1..4/: Cap, S;
LINKS(FLIGHT, AIRCRAFT): X, P;

ENDSETS

MAX = @SUM(FLIGHT(I): @SUM(AIRCRAFT(K) : X(I,K) * P(I,K)));

@FOR(FLIGHT(I): @FOR (AIRCRAFT(K): P(I,K)= M(I) * ((1.07 * D(I)) -
(0.65 * Cap(K))));

@FOR(FLIGHT(I): @SUM(AIRCRAFT(K) : X(I,K))= 1);

@FOR(AIRCRAFT(K) : @SUM(FLIGHT(I) : X(I,K)) <= S(K));

@FOR(FLIGHT(I): @FOR (AIRCRAFT(K): X(I,K) * D(I) <= Cap(K)));

@FOR(LINKS: @BIN(X));

@FOR(LINKS: @FREE(P));

DATA:

D = @OLE('FleetAssignment1.xlsx', 'Demand');

M = @OLE(' FleetAssignment1.xlsx', 'Distance');

Cap = @OLE(' FleetAssignment1.xlsx', 'Capacity');

S = @OLE(' FleetAssignment1.xlsx', 'Inventory');

@OLE('FleetAssignment1.xlsx', 'X') = X;

@OLE('FleetAssignment1.xlsx', 'P') = P;

ENDDATA

END

EK 5.4. 01.06.2023 Tarihli Filo Atamaları

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	1	0	0	0
PC 2028	0	0	1	0
PC 2404	0	0	0	1
PC 2678	0	0	1	0
PC 2746	0	0	1	0
PC 2402	0	0	1	0
PC 2000	0	0	0	1
PC 2770	0	0	0	1
PC 2080	0	0	0	1
PC 2180	0	0	1	0
PC 2380	0	1	0	0
PC 4051	0	0	1	0
PC 2860	0	0	1	0
PC 2430	0	0	0	1
PC 2490	0	1	0	0
PC 2590	0	0	0	1
PC 2004	0	0	1	0
PC 2662	0	0	0	1
PC 2790	0	0	0	1
PC 2700	0	0	0	1
PC 2150	0	0	1	0
PC 2284	0	0	0	1
PC 2814	0	1	0	0
PC 2184	0	0	1	0
PC 2006	0	0	1	0
PC 2082	0	0	1	0
PC 2792	0	0	1	0
PC 2244	0	0	1	0
PC 2732	0	0	1	0
PC 2008	0	0	1	0
PC 2086	0	0	1	0
PC 2664	0	0	1	0
PC 2816	0	0	0	1
PC 2188	0	0	1	0
PC 2734	0	0	1	0
PC 2010	0	0	1	0
PC 2822	0	1	0	0
PC 2666	0	0	1	0
PC 2194	0	0	1	0
PC 2248	0	0	0	1
PC 2286	0	0	1	0
PC 2370	0	0	0	1
PC 2088	0	0	1	0
PC 2824	0	1	0	0
PC 2016	0	0	0	1

PC 2570	0	0	0	1
PC 2668	0	0	0	1
PC 2092	0	0	1	0
PC 2502	1	0	0	0
PC 2204	0	0	1	0
PC 2384	0	0	0	1
PC 2818	0	1	0	0
PC 2094	0	0	1	0
PC 2554	0	1	0	0
PC 2292	0	0	1	0
PC 2532	0	1	0	0
PC 2670	0	0	1	0
PC 2218	1	0	0	0
PC 2258	0	0	1	0
PC 2944	0	0	0	1
PC 2072	0	0	1	0
PC 2862	0	0	1	0
PC 2420	0	0	0	1
PC 2022	0	0	0	1
PC 2294	0	0	0	1
PC 2096	0	0	1	0
PC 2752	0	0	1	0
PC 2408	0	0	0	1
PC 2672	1	0	0	0
PC 2740	0	0	1	0
PC 2794	0	0	1	0
PC 2830	0	0	0	1
PC 2024	0	0	1	0
PC 2706	0	0	1	0
PC 2208	0	0	0	1
PC 2030	0	0	1	0
PC 2676	0	0	1	0
PC 2026	0	0	1	0
PC 2748	0	0	1	0
PC 2212	0	0	1	0
PC 2264	0	0	1	0
PC 2698	0	0	1	0

EK 5.5. 01.06.2023 Tarihli Modelin Filo Atamalarının Kazanç Değerleri

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	56947	60457	58351	33547
PC 2028	27897	30344	28876	11582
PC 2404	86340	90562	88029	58195
PC 2678	14672	16412	15368	3070
PC 2746	15646	18659	16851	-4439
PC 2402	55334	59556	57023	27189
PC 2000	48999	51446	49978	32684
PC 2770	103861	108687	105792	71686
PC 2080	64590	68100	65994	41190
PC 2180	24169	25861	24846	12891
PC 2380	60825	65851	62835	27317
PC 4051	18983	21387	19945	2961
PC 2860	19276	22991	20762	-5489
PC 2430	98523	103881	100667	62806
PC 2490	55234	60748	57440	18477
PC 2590	121021	126779	123324	82639
PC 2004	19294	21741	20273	2979
PC 2662	35542	37283	36238	23940
PC 2790	51909	54902	53106	31954
PC 2700	48551	50877	49482	33049
PC 2150	64475	68755	66187	35940
PC 2284	43587	45991	44549	27565
PC 2814	20975	25392	22742	-8470
PC 2184	19768	21460	20445	8491
PC 2006	21025	23473	22004	4710
PC 2082	32896	36406	34300	9496
PC 2792	18176	21169	19373	-1779
PC 2244	23782	26132	24722	8117
PC 2732	25492	28505	26697	5407
PC 2008	21838	24285	22817	5523
PC 2086	47876	51386	49280	24476
PC 2664	24624	26365	25321	13022
PC 2816	87900	92316	89666	58455
PC 2188	13415	15107	14092	2138
PC 2734	41027	44039	42232	20942
PC 2010	37700	40147	38679	21385
PC 2822	62199	66616	63966	32754
PC 2666	14446	16187	15143	2844
PC 2194	23832	25524	24509	12555
PC 2248	50461	52810	51400	34796
PC 2286	10311	12715	11273	-5711
PC 2370	91399	96785	93553	55486
PC 2088	49952	53462	51356	26552
PC 2824	58806	63223	60573	29361
PC 2016	53668	56116	54647	37353

PC 2570	74551	78621	76179	47413
PC 2668	29078	30818	29774	17475
PC 2092	52415	55925	53819	29015
PC 2502	99209	105512	101730	57186
PC 2204	23060	24751	23736	11782
PC 2384	93088	98114	95098	59580
PC 2818	39691	44108	41458	10246
PC 2094	31155	34665	32559	7755
PC 2554	42900	48077	44971	8385
PC 2292	35394	37797	36355	19371
PC 2532	35731	40298	37558	5278
PC 2670	21563	23304	22259	9961
PC 2218	13528	15220	14205	2251
PC 2258	21162	23512	22102	5497
PC 2944	13790	14604	14115	8362
PC 2072	32885	35776	34042	13613
PC 2862	24210	27924	25695	-555
PC 2420	87974	92703	89866	56449
PC 2022	46688	49136	47667	30373
PC 2294	47531	49934	48492	31508
PC 2096	53729	57239	55133	30329
PC 2752	18018	21420	19379	-4667
PC 2408	70045	74267	71734	41900
PC 2672	27207	28947	27903	15605
PC 2740	11753	14765	12958	-8332
PC 2794	42923	45916	44120	22968
PC 2830	89393	93809	91159	59948
PC 2024	13280	15728	14259	-3035
PC 2706	28307	30632	29237	12804
PC 2208	33444	35136	34121	22166
PC 2030	11965	14412	12944	-4350
PC 2676	10784	12524	11480	-819
PC 2026	10988	13435	11967	-5327
PC 2748	23410	26423	24615	3325
PC 2212	15632	17324	16309	4354
PC 2264	29680	32030	30620	14015
PC 2698	22942	24683	23639	11340

EK 5.6. 02.06.2023 Tarihli Filo Atamaları

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	1	0	0	0
PC 2028	0	0	1	0
PC 2404	0	0	0	1
PC 2678	0	0	0	1
PC 2746	0	0	1	0
PC 2402	1	0	0	0
PC 2000	0	0	0	1
PC 2770	0	1	0	0
PC 2080	0	0	1	0
PC 2180	0	0	1	0
PC 2380	0	1	0	0
PC 4051	0	0	1	0
PC 2860	0	0	1	0
PC 2430	0	0	0	1
PC 2490	0	0	0	1
PC 2590	0	0	0	1
PC 2004	0	0	1	0
PC 2662	0	0	1	0
PC 2790	0	0	1	0
PC 2700	0	0	1	0
PC 2150	0	0	1	0
PC 2284	0	0	0	1
PC 2814	0	0	0	1
PC 2184	0	0	1	0
PC 2006	0	0	0	1
PC 2082	0	0	1	0
PC 2792	0	0	1	0
PC 2244	0	0	0	1
PC 2732	0	0	1	0
PC 2008	0	0	1	0
PC 2086	0	0	0	1
PC 2664	0	0	1	0
PC 2816	0	0	1	0
PC 2188	0	0	0	1
PC 2734	0	0	1	0
PC 2010	0	0	1	0
PC 2822	0	1	0	0
PC 2666	0	0	0	1
PC 2194	0	0	1	0
PC 2248	0	0	1	0
PC 2286	0	0	0	1
PC 2370	0	1	0	0
PC 2088	0	0	0	1
PC 2824	0	0	0	1

PC 2016	1	0	0	0
PC 2570	0	0	0	1
PC 2668	0	0	0	1
PC 2092	0	0	1	0
PC 2502	0	1	0	0
PC 2204	0	0	1	0
PC 2384	0	1	0	0
PC 2818	0	0	0	1
PC 2094	0	0	0	1
PC 2554	0	1	0	0
PC 2292	0	0	1	0
PC 2532	0	0	0	1
PC 2670	0	0	1	0
PC 2218	0	0	1	0
PC 2258	0	0	0	1
PC 2944	0	0	1	0
PC 2072	0	0	1	0
PC 2862	0	0	1	0
PC 2420	0	1	0	0
PC 2022	0	0	1	0
PC 2294	0	0	1	0
PC 2096	0	0	1	0
PC 2752	0	0	0	1
PC 2408	0	0	0	1
PC 2672	0	0	1	0
PC 2740	0	0	1	0
PC 2794	0	0	1	0
PC 2830	0	0	1	0
PC 2024	0	0	0	1
PC 2706	0	0	1	0
PC 2208	0	0	0	1
PC 2030	0	0	1	0
PC 2676	0	0	1	0
PC 2026	0	0	1	0
PC 2748	0	0	0	1
PC 2212	0	0	0	1
PC 2264	0	0	1	0
PC 2698	0	0	0	1

EK 5.7. 02.06.2023 Tarihli Modelin Filo Atamalarının Kazanç Değerleri

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	56925	60435	58329	33525
PC 2028	28187	30634	29166	11872
PC 2404	103427	107649	105116	75282
PC 2678	40128	41868	40824	28526
PC 2746	19875	22888	21080	-210
PC 2402	68659	72881	70348	40514
PC 2000	59070	61518	60049	42755
PC 2770	35781	40607	37711	3606
PC 2080	53179	56689	54583	29779
PC 2180	15054	16745	15730	3776
PC 2380	44859	49885	46869	11352
PC 4051	34943	37347	35905	18921
PC 2860	57126	60841	58612	32361
PC 2430	139821	145179	141964	104103
PC 2490	119197	124711	121403	82440
PC 2590	131236	136993	133539	92853
PC 2004	35850	38297	36829	19535
PC 2662	16202	17942	16898	4599
PC 2790	25347	28340	26544	5392
PC 2700	18142	20467	19072	2639
PC 2150	46672	50953	48384	18137
PC 2284	52608	55011	53569	36585
PC 2814	111677	116094	113444	82232
PC 2184	16360	18051	17036	5082
PC 2006	40880	43328	41859	24565
PC 2082	37083	40593	38487	13683
PC 2792	20799	23792	21996	844
PC 2244	59792	62142	60732	44127
PC 2732	32166	35178	33371	12081
PC 2008	25962	28409	26941	9647
PC 2086	68733	72243	70137	45333
PC 2664	23291	25032	23987	11689
PC 2816	51543	55960	53310	22098
PC 2188	37097	38789	37774	25820
PC 2734	33033	36046	34238	12948
PC 2010	32869	35317	33848	16554
PC 2822	52025	56442	53792	22580
PC 2666	29636	31376	30332	18033
PC 2194	13264	14956	13941	1986
PC 2248	28621	30971	29561	12956
PC 2286	58814	61217	59775	42791
PC 2370	37934	43320	40088	2021
PC 2088	82665	86175	84069	59265
PC 2824	111110	115527	112877	81665

PC 2016	38876	41323	39855	22561
PC 2570	98411	102481	100039	71273
PC 2668	39918	41658	40614	28315
PC 2092	33438	36948	34842	10038
PC 2502	53133	59437	55655	11111
PC 2204	14286	15978	14963	3009
PC 2384	57063	62089	59074	23556
PC 2818	112745	117162	114512	83300
PC 2094	67063	70573	68467	43663
PC 2554	52360	57537	54431	17845
PC 2292	30189	32592	31150	14166
PC 2532	118831	123399	120658	88379
PC 2670	20089	21829	20785	8486
PC 2218	25033	26724	25709	13755
PC 2258	56116	58466	57056	40451
PC 2944	5489	6304	5815	62
PC 2072	28623	31513	29779	9350
PC 2862	49227	52942	50713	24462
PC 2420	36592	41321	38483	5067
PC 2022	34401	36848	35380	18086
PC 2294	34634	37038	35596	18612
PC 2096	53238	56748	54642	29838
PC 2752	85957	89360	87318	63272
PC 2408	85955	90176	87643	57810
PC 2672	26223	27963	26919	14620
PC 2740	44941	47954	46146	24856
PC 2794	39717	42711	40915	19762
PC 2830	41261	45677	43027	11816
PC 2024	54407	56854	55385	38092
PC 2706	19119	21444	20049	3617
PC 2208	28867	30558	29543	17589
PC 2030	24956	27403	25935	8641
PC 2676	19744	21485	20441	8142
PC 2026	17203	19651	18182	888
PC 2748	72715	75727	73920	52630
PC 2212	29957	31649	30634	18680
PC 2264	21174	23523	22113	5509
PC 2698	40983	42724	41679	29381

EK 5.8. 03.06.2023 Tarihli Filo Atamaları

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	0	0	1	0
PC 2028	0	0	1	0
PC 2404	0	0	1	0
PC 2678	1	0	0	0
PC 2746	0	0	0	1
PC 2402	0	0	0	1
PC 2000	0	0	0	1
PC 2770	0	0	0	1
PC 2080	0	0	1	0
PC 2180	0	0	0	1
PC 2380	0	0	0	1
PC 4051	0	0	1	0
PC 2860	0	0	0	1
PC 2430	0	0	0	1
PC 2490	0	0	0	1
PC 2590	0	0	1	0
PC 2004	0	0	0	1
PC 2662	0	0	0	1
PC 2790	0	0	1	0
PC 2700	0	0	1	0
PC 2150	0	0	1	0
PC 2284	0	0	1	0
PC 2814	0	1	0	0
PC 2184	0	0	0	1
PC 2006	0	0	1	0
PC 2082	0	0	0	1
PC 2792	0	0	1	0
PC 2244	0	0	1	0
PC 2732	0	0	1	0
PC 2008	0	0	0	1
PC 2086	0	0	1	0
PC 2664	0	0	1	0
PC 2816	1	0	0	0
PC 2188	0	0	0	1
PC 2734	0	0	1	0
PC 2010	0	0	1	0
PC 2822	0	0	0	1
PC 2666	0	0	1	0
PC 2194	0	0	0	1
PC 2248	0	0	0	1
PC 2286	0	0	1	0
PC 2370	0	1	0	0
PC 2088	0	0	1	0
PC 2824	0	0	0	1

PC 2016	0	0	1	0
PC 2570	0	0	1	0
PC 2668	0	0	1	0
PC 2092	0	0	1	0
PC 2502	0	1	0	0
PC 2204	0	0	0	1
PC 2384	0	1	0	0
PC 2818	0	1	0	0
PC 2094	0	0	1	0
PC 2554	0	1	0	0
PC 2292	0	0	0	1
PC 2532	0	1	0	0
PC 2670	0	0	1	0
PC 2218	0	0	1	0
PC 2258	0	0	1	0
PC 2944	0	0	1	0
PC 2072	0	0	1	0
PC 2862	0	0	0	1
PC 2420	0	1	0	0
PC 2022	0	0	0	1
PC 2294	0	0	1	0
PC 2096	0	0	1	0
PC 2752	0	0	1	0
PC 2408	0	0	1	0
PC 2672	0	0	1	0
PC 2740	0	0	1	0
PC 2794	1	0	0	0
PC 2830	0	0	0	1
PC 2024	0	0	1	0
PC 2706	0	0	1	0
PC 2208	0	0	1	0
PC 2030	0	0	1	0
PC 2676	0	0	0	1
PC 2026	0	0	1	0
PC 2748	0	0	1	0
PC 2212	0	0	0	1
PC 2264	0	0	0	1
PC 2698	0	0	0	1

EK 5.9. 03.06.2023 Tarihli Modelin Filo Atamalarının Kazanç Değerleri

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	36876	40386	38280	13476
PC 2028	22161	24608	23140	5846
PC 2404	35367	39589	37056	7222
PC 2678	27722	29463	28418	16120
PC 2746	60614	63626	61819	40529
PC 2402	104223	108445	105912	76078
PC 2000	46102	48550	47081	29787
PC 2770	113392	118219	115323	81217
PC 2080	51918	55428	53322	28518
PC 2180	29261	30953	29938	17983
PC 2380	112927	117953	114937	79419
PC 4051	25131	27534	26092	9108
PC 2860	79644	83359	81130	54879
PC 2430	110222	115579	112365	74504
PC 2490	123561	129075	125767	86804
PC 2590	87521	93278	89824	49138
PC 2004	54176	56623	55155	37861
PC 2662	46215	47955	46911	34612
PC 2790	43541	46534	44738	23586
PC 2700	27057	29383	27987	11555
PC 2150	55238	59518	56950	26703
PC 2284	34215	36618	35176	18192
PC 2814	49997	54414	51764	20552
PC 2184	43970	45662	44647	32692
PC 2006	28490	30937	29468	12175
PC 2082	71338	74848	72742	47938
PC 2792	24863	27856	26060	4908
PC 2244	24995	27344	25935	9330
PC 2732	32076	35089	33281	11991
PC 2008	42655	45103	43634	26340
PC 2086	34221	37731	35625	10821
PC 2664	20416	22157	21112	8814
PC 2816	70500	74916	72266	41055
PC 2188	29119	30811	29796	17842
PC 2734	28132	31145	29337	8047
PC 2010	22964	25411	23942	6649
PC 2822	105854	110271	107621	76409
PC 2666	19644	21384	20340	8041
PC 2194	35689	37380	36365	24411
PC 2248	41411	43760	42351	25746
PC 2286	29359	31763	30321	13337
PC 2370	47091	52478	49246	11179
PC 2088	46587	50097	47991	23187
PC 2824	111333	115750	113100	81888

PC 2016	29422	31869	30401	13107
PC 2570	51370	55440	52998	24232
PC 2668	15144	16884	15840	3541
PC 2092	28365	31875	29769	4965
PC 2502	56886	63189	59407	14863
PC 2204	29624	31316	30301	18347
PC 2384	42382	47408	44393	8875
PC 2818	55430	59847	57197	25985
PC 2094	40821	44331	42225	17421
PC 2554	70934	76111	73004	36419
PC 2292	60213	62617	61175	44191
PC 2532	59409	63977	61237	28957
PC 2670	23761	25501	24457	12158
PC 2218	25318	27010	25995	14041
PC 2258	27515	29865	28455	11850
PC 2944	10138	10952	10463	4710
PC 2072	16994	19885	18150	-2279
PC 2862	77232	80946	78718	52467
PC 2420	55282	60011	57174	23757
PC 2022	63429	65876	64407	47114
PC 2294	33913	36316	34874	17890
PC 2096	54191	57701	55595	30791
PC 2752	28211	31614	29572	5526
PC 2408	52787	57009	54475	24642
PC 2672	22578	24318	23274	10975
PC 2740	46146	49159	47351	26061
PC 2794	47354	50347	48551	27399
PC 2830	79880	84297	81647	50435
PC 2024	30147	32595	31126	13832
PC 2706	19328	21653	20258	3825
PC 2208	17426	19117	18102	6148
PC 2030	25759	28206	26738	9444
PC 2676	30378	32118	31074	18776
PC 2026	34143	36591	35122	17828
PC 2748	37498	40510	38703	17413
PC 2212	36563	38255	37240	25286
PC 2264	52470	54819	53409	36805
PC 2698	39752	41492	40448	28149

EK 5.10. 04.06.2023 Tarihli Filo Atamaları

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	0	0	0	1
PC 2028	0	0	0	1
PC 2404	0	0	0	1
PC 2678	0	0	1	0
PC 2746	0	0	0	1
PC 2402	0	0	1	0
PC 2000	0	0	1	0
PC 2770	0	1	0	0
PC 2080	0	0	0	1
PC 2180	0	0	1	0
PC 2380	0	1	0	0
PC 4051	0	0	0	1
PC 2860	0	0	1	0
PC 2430	0	1	0	0
PC 2490	0	0	0	1
PC 2590	0	1	0	0
PC 2004	0	0	1	0
PC 2662	0	0	0	1
PC 2790	0	0	1	0
PC 2700	0	0	1	0
PC 2150	0	0	1	0
PC 2284	0	0	1	0
PC 2814	0	1	0	0
PC 2184	0	0	0	1
PC 2006	0	0	0	1
PC 2082	0	0	1	0
PC 2792	0	0	1	0
PC 2244	0	0	1	0
PC 2732	0	0	1	0
PC 2008	0	0	1	0
PC 2086	0	0	0	1
PC 2664	0	0	1	0
PC 2816	0	0	1	0
PC 2188	0	0	0	1
PC 2734	0	0	1	0
PC 2010	0	0	1	0
PC 2822	0	0	1	0
PC 2666	0	0	1	0
PC 2194	0	0	1	0
PC 2248	0	0	0	1
PC 2286	0	0	0	1
PC 2370	0	1	0	0
PC 2088	0	0	1	0
PC 2824	0	0	1	0

PC 2016	0	0	1	0
PC 2570	0	0	1	0
PC 2668	0	0	0	1
PC 2092	0	0	0	1
PC 2502	0	0	1	0
PC 2204	0	0	0	1
PC 2384	0	1	0	0
PC 2818	0	0	0	1
PC 2094	0	0	1	0
PC 2554	0	0	0	1
PC 2292	0	0	1	0
PC 2532	0	0	0	1
PC 2670	0	0	1	0
PC 2218	0	0	0	1
PC 2258	0	0	1	0
PC 2944	0	0	0	1
PC 2072	0	0	1	0
PC 2862	0	0	0	1
PC 2420	0	0	0	1
PC 2022	0	0	1	0
PC 2294	0	0	1	0
PC 2096	0	0	1	0
PC 2752	0	0	0	1
PC 2408	0	0	1	0
PC 2672	0	0	1	0
PC 2740	0	0	1	0
PC 2794	0	0	0	1
PC 2830	0	1	0	0
PC 2024	0	0	1	0
PC 2706	0	0	1	0
PC 2208	0	0	1	0
PC 2030	0	0	0	1
PC 2676	0	0	1	0
PC 2026	0	0	1	0
PC 2748	0	0	1	0
PC 2212	0	0	1	0
PC 2264	0	0	0	1
PC 2698	0	0	0	1

EK 5.11. 04.06.2023 Tarihli Modelin Filo Atamalarının Kazanç Değerleri

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	82385	85895	83789	58985
PC 2028	56532	58979	57511	40217
PC 2404	89335	93556	91023	61190
PC 2678	16771	18512	17467	5169
PC 2746	66173	69186	67378	46088
PC 2402	52111	56332	53799	23966
PC 2000	18677	21124	19656	2362
PC 2770	48501	53327	50432	16326
PC 2080	74243	77753	75647	50843
PC 2180	25273	26964	25949	13995
PC 2380	63988	69014	65998	30480
PC 4051	55436	57840	56398	39414
PC 2860	25047	28762	26533	282
PC 2430	60072	65430	62215	24355
PC 2490	103384	108897	105589	66626
PC 2590	62667	68425	64970	24285
PC 2004	28121	30568	29100	11806
PC 2662	30840	32581	31536	19238
PC 2790	36110	39103	37308	16155
PC 2700	25944	28270	26875	10442
PC 2150	57342	61622	59054	28807
PC 2284	16038	18441	16999	16
PC 2814	58622	63039	60389	29177
PC 2184	33079	34771	33756	21801
PC 2006	59385	61832	60364	43070
PC 2082	54189	57699	55593	30789
PC 2792	32202	35195	33399	12247
PC 2244	16171	18520	17111	506
PC 2732	34657	37670	35862	14572
PC 2008	18808	21256	19787	2493
PC 2086	76673	80183	78077	53273
PC 2664	10725	12465	11421	-878
PC 2816	67439	71856	69206	37994
PC 2188	43838	45530	44515	32561
PC 2734	22538	25550	23743	2453
PC 2010	16632	19079	17611	317
PC 2822	58188	62605	59955	28743
PC 2666	10954	12694	11650	-649
PC 2194	23815	25507	24492	12538
PC 2248	45778	48128	46718	30113
PC 2286	55974	58378	56936	39952
PC 2370	48750	54137	50905	12838
PC 2088	24249	27759	25653	849
PC 2824	32461	36878	34228	3016

PC 2016	32422	34869	33401	16107
PC 2570	24529	28599	26157	-2609
PC 2668	37748	39488	38444	26145
PC 2092	58706	62216	60110	35306
PC 2502	95445	101749	97967	53423
PC 2204	41231	42923	41908	29954
PC 2384	69822	74848	71832	36314
PC 2818	72232	76648	73998	42787
PC 2094	29592	33102	30996	6192
PC 2554	121904	127081	123974	87389
PC 2292	25787	28191	26749	9765
PC 2532	102398	106966	104226	71946
PC 2670	17145	18885	17841	5543
PC 2218	32882	34573	33558	21604
PC 2258	31334	33684	32274	15669
PC 2944	21545	22359	21870	16117
PC 2072	33043	35934	34200	13771
PC 2862	79196	82911	80682	54431
PC 2420	112973	117702	114865	81448
PC 2022	30823	33270	31802	14508
PC 2294	15715	18119	16677	-307
PC 2096	26430	29940	27834	3030
PC 2752	55630	59033	56991	32945
PC 2408	55519	59741	57208	27374
PC 2672	25809	27549	26505	14206
PC 2740	39708	42720	40913	19623
PC 2794	68479	71472	69676	48524
PC 2830	49989	54406	51755	20544
PC 2024	22453	24900	23432	6138
PC 2706	28856	31181	29786	13353
PC 2208	14879	16571	15556	3602
PC 2030	44692	47140	45671	28377
PC 2676	20491	22232	21187	8889
PC 2026	18955	21403	19934	2640
PC 2748	39437	42450	40642	19352
PC 2212	22372	24064	23049	11095
PC 2264	60070	62420	61010	44405
PC 2698	28784	30525	29480	17182

EK 5.12. 05.06.2023 Tarihli Filo Atamaları

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	0	0	0	1
PC 2028	0	0	1	0
PC 2404	0	0	1	0
PC 2678	0	0	0	1
PC 2746	0	0	1	0
PC 2402	0	0	0	1
PC 2000	0	0	0	1
PC 2770	0	0	0	1
PC 2080	0	0	0	1
PC 2180	0	0	0	1
PC 2380	0	1	0	0
PC 4051	0	0	0	1
PC 2860	0	0	1	0
PC 2430	0	1	0	0
PC 2490	0	0	0	1
PC 2590	0	0	0	1
PC 2004	0	0	1	0
PC 2662	0	0	1	0
PC 2790	0	0	1	0
PC 2700	0	0	0	1
PC 2150	0	0	0	1
PC 2284	0	0	0	1
PC 2814	0	0	0	1
PC 2184	0	0	1	0
PC 2006	0	0	1	0
PC 2082	0	0	1	0
PC 2792	0	0	1	0
PC 2244	0	0	1	0
PC 2732	0	0	1	0
PC 2008	0	0	1	0
PC 2086	1	0	0	0
PC 2664	0	0	0	1
PC 2816	0	1	0	0
PC 2188	0	0	1	0
PC 2734	0	0	1	0
PC 2010	0	0	1	0
PC 2822	0	1	0	0
PC 2666	0	0	1	0
PC 2194	0	0	1	0
PC 2248	0	0	0	1
PC 2286	0	0	1	0
PC 2370	0	1	0	0
PC 2088	0	0	0	1
PC 2824	0	0	0	1

PC 2016	0	0	0	1
PC 2570	0	0	1	0
PC 2668	0	0	0	1
PC 2092	0	0	1	0
PC 2502	0	0	0	1
PC 2204	0	0	1	0
PC 2384	0	1	0	0
PC 2818	1	0	0	0
PC 2094	0	0	1	0
PC 2554	0	1	0	0
PC 2292	0	0	1	0
PC 2532	0	1	0	0
PC 2670	0	0	0	1
PC 2218	0	0	1	0
PC 2258	0	0	0	1
PC 2944	0	0	0	1
PC 2072	0	0	1	0
PC 2862	0	0	1	0
PC 2420	0	0	0	1
PC 2022	0	0	0	1
PC 2294	0	0	0	1
PC 2096	0	0	1	0
PC 2752	0	0	1	0
PC 2408	0	0	1	0
PC 2672	0	0	1	0
PC 2740	0	0	1	0
PC 2794	0	0	0	1
PC 2830	0	0	1	0
PC 2024	0	0	0	1
PC 2706	1	0	0	0
PC 2208	0	0	1	0
PC 2030	0	0	1	0
PC 2676	0	0	0	1
PC 2026	0	0	0	1
PC 2748	0	0	1	0
PC 2212	0	0	1	0
PC 2264	0	0	1	0
PC 2698	0	0	1	0

EK 5.13. 05.06.2023 Tarihli Modelin Filo Atamalarının Kazanç Değerleri

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	63875	67385	65279	40475
PC 2028	20248	22695	21227	3933
PC 2404	53588	57810	55276	25443
PC 2678	29510	31250	30206	17907
PC 2746	44538	47551	45743	24453
PC 2402	107577	111799	109266	79432
PC 2000	55082	57529	56061	38767
PC 2770	112421	117247	114351	80246
PC 2080	61132	64642	62536	37732
PC 2180	28513	30205	29190	17236
PC 2380	42066	47092	44077	8559
PC 4051	58987	61391	59949	42965
PC 2860	37713	41428	39199	12948
PC 2430	66702	72060	68845	30985
PC 2490	100554	106067	102759	63796
PC 2590	103411	109169	105714	65029
PC 2004	34331	36779	35310	18016
PC 2662	17412	19152	18108	5809
PC 2790	23230	26223	24427	3275
PC 2700	45906	48231	46836	30403
PC 2150	95808	100089	97521	67273
PC 2284	40674	43078	41636	24652
PC 2814	91382	95799	93149	61937
PC 2184	9452	11144	10129	-1825
PC 2006	18002	20449	18981	1687
PC 2082	42979	46489	44383	19579
PC 2792	44318	47311	45515	24363
PC 2244	28960	31310	29900	13295
PC 2732	15863	18876	17068	-4222
PC 2008	35397	37844	36376	19082
PC 2086	56447	59957	57851	33047
PC 2664	32813	34553	33509	21210
PC 2816	22967	27384	24734	-6478
PC 2188	20369	22061	21046	9092
PC 2734	23718	26731	24923	3633
PC 2010	37550	39997	38529	21235
PC 2822	48193	52610	49959	18748
PC 2666	15841	17582	16537	4239
PC 2194	22161	23852	22837	10883
PC 2248	40133	42483	41073	24468
PC 2286	15437	17840	16398	-586
PC 2370	38892	44278	41046	2979
PC 2088	60783	64293	62187	37383
PC 2824	81067	85483	82833	51622

PC 2016	52484	54931	53463	36169
PC 2570	46419	50489	48047	19281
PC 2668	37930	39670	38626	26327
PC 2092	18816	22326	20220	-4584
PC 2502	145393	151697	147915	103371
PC 2204	8874	10566	9551	-2403
PC 2384	47476	52502	49486	13968
PC 2818	69419	73836	71186	39974
PC 2094	20652	24162	22056	-2748
PC 2554	50748	55926	52819	16233
PC 2292	12156	14559	13117	-3867
PC 2532	32339	36907	34166	1886
PC 2670	39605	41345	40301	28002
PC 2218	8101	9792	8777	-3177
PC 2258	52142	54492	53082	36477
PC 2944	17528	18343	17854	12101
PC 2072	40059	42950	41215	20786
PC 2862	44264	47979	45750	19499
PC 2420	110442	115171	112333	78917
PC 2022	45558	48005	46537	29243
PC 2294	60300	62703	61261	44277
PC 2096	29885	33395	31289	6485
PC 2752	33305	36708	34666	10620
PC 2408	38935	43157	40624	10790
PC 2672	16947	18687	17643	5344
PC 2740	37217	40230	38422	17132
PC 2794	65392	68385	66589	45437
PC 2830	62059	66476	63826	32614
PC 2024	57417	59864	58396	41102
PC 2706	36989	39315	37919	21487
PC 2208	15290	16982	15967	4013
PC 2030	35297	37744	36276	18982
PC 2676	30801	32541	31497	19198
PC 2026	41821	44268	42800	25506
PC 2748	23464	26477	24669	3379
PC 2212	18442	20134	19119	7165
PC 2264	17663	20013	18603	1998
PC 2698	21816	23557	22513	10214

EK 5.14. 06.06.2023 Tarihli Filo Atamaları

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	0	0	1	0
PC 2028	0	0	1	0
PC 2404	0	0	1	0
PC 2678	1	0	0	0
PC 2746	0	0	1	0
PC 2402	0	0	1	0
PC 2000	0	0	1	0
PC 2770	0	0	1	0
PC 2080	0	0	1	0
PC 2180	0	0	0	1
PC 2380	0	1	0	0
PC 4051	0	0	1	0
PC 2860	0	0	1	0
PC 2430	0	1	0	0
PC 2490	0	1	0	0
PC 2590	0	0	0	1
PC 2004	0	0	1	0
PC 2662	1	0	0	0
PC 2790	0	0	1	0
PC 2700	0	0	1	0
PC 2150	0	0	1	0
PC 2284	0	0	0	1
PC 2814	0	0	1	0
PC 2184	1	0	0	0
PC 2006	0	0	1	0
PC 2082	0	0	1	0
PC 2792	0	0	1	0
PC 2244	0	0	0	1
PC 2732	0	0	1	0
PC 2008	0	0	1	0
PC 2086	1	0	0	0
PC 2664	1	0	0	0
PC 2816	0	0	1	0
PC 2188	0	0	0	1
PC 2734	0	0	0	1
PC 2010	0	0	1	0
PC 2822	0	0	1	0
PC 2666	0	0	1	0
PC 2194	0	0	0	1
PC 2248	1	0	0	0
PC 2286	0	0	1	0
PC 2370	0	1	0	0
PC 2088	0	0	1	0
PC 2824	0	0	1	0

PC 2016	0	0	1	0
PC 2570	0	0	1	0
PC 2668	1	0	0	0
PC 2092	0	0	1	0
PC 2502	0	1	0	0
PC 2204	0	0	0	1
PC 2384	0	1	0	0
PC 2818	1	0	0	0
PC 2094	0	0	1	0
PC 2554	0	1	0	0
PC 2292	0	0	1	0
PC 2532	0	1	0	0
PC 2670	1	0	0	0
PC 2218	1	0	0	0
PC 2258	0	0	1	0
PC 2944	0	0	0	1
PC 2072	0	0	1	0
PC 2862	0	0	1	0
PC 2420	0	0	0	1
PC 2022	0	0	1	0
PC 2294	0	0	0	1
PC 2096	1	0	0	0
PC 2752	0	0	1	0
PC 2408	0	0	1	0
PC 2672	1	0	0	0
PC 2740	0	0	1	0
PC 2794	0	0	1	0
PC 2830	0	0	1	0
PC 2024	0	0	1	0
PC 2706	0	0	0	1
PC 2208	1	0	0	0
PC 2030	0	0	1	0
PC 2676	1	0	0	0
PC 2026	0	0	1	0
PC 2748	0	0	1	0
PC 2212	1	0	0	0
PC 2264	0	0	1	0
PC 2698	1	0	0	0

EK 5.15. 06.06.2023 Tarihli Modelin Filo Atamalarının Kazanç Değerleri

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	16701	20211	18105	-6699
PC 2028	33481	35929	34460	17166
PC 2404	16243	20465	17932	-11902
PC 2678	24712	26453	25408	13110
PC 2746	31027	34040	32232	10942
PC 2402	59033	63255	60722	30888
PC 2000	11601	14048	12580	-4714
PC 2770	71952	76778	73882	39777
PC 2080	26848	30358	28252	3448
PC 2180	16720	18412	17397	5443
PC 2380	39171	44197	41181	5663
PC 4051	30591	32994	31552	14568
PC 2860	42223	45938	43709	17458
PC 2430	71831	77189	73974	36114
PC 2490	67051	72565	69257	30294
PC 2590	105266	111023	107569	66883
PC 2004	35944	38392	36923	19629
PC 2662	14630	16370	15326	3028
PC 2790	41276	44269	42474	21321
PC 2700	33676	36002	34607	18174
PC 2150	62931	67211	64643	34396
PC 2284	41271	43675	42233	25249
PC 2814	48014	52430	49780	18569
PC 2184	21454	23146	22131	10177
PC 2006	35970	38417	36949	19655
PC 2082	51517	55027	52921	28117
PC 2792	20253	23246	21450	298
PC 2244	40513	42863	41453	24848
PC 2732	45597	48610	46802	25512
PC 2008	25221	27668	26200	8906
PC 2086	56225	59735	57629	32825
PC 2664	10746	12486	11442	-857
PC 2816	42804	47221	44571	13359
PC 2188	18288	19980	18965	7011
PC 2734	66059	69071	67264	45974
PC 2010	16306	18754	17285	-9
PC 2822	26921	31337	28687	-2524
PC 2666	25341	27081	26037	13738
PC 2194	27767	29459	28444	16490
PC 2248	37901	40251	38841	22236
PC 2286	31044	33448	32006	15022
PC 2370	44458	49845	46613	8546
PC 2088	47455	50965	48859	24055
PC 2824	21020	25437	22787	-8425

PC 2016	8911	11358	9890	-7404
PC 2570	29477	33548	31105	2340
PC 2668	8980	10720	9676	-2623
PC 2092	52192	55702	53596	28792
PC 2502	92081	98385	94603	50059
PC 2204	23609	25301	24286	12332
PC 2384	58367	63393	60378	24860
PC 2818	70412	74829	72179	40967
PC 2094	30564	34074	31968	7164
PC 2554	72741	77918	74811	38226
PC 2292	31441	33844	32402	15418
PC 2532	16216	20784	18043	-14236
PC 2670	8470	10210	9166	-3133
PC 2218	25041	26733	25718	13764
PC 2258	30102	32452	31042	14437
PC 2944	11896	12710	12221	6468
PC 2072	18690	21581	19846	-583
PC 2862	24113	27827	25599	-652
PC 2420	112468	117197	114359	80943
PC 2022	24578	27025	25557	8263
PC 2294	40714	43117	41675	24691
PC 2096	56922	60432	58326	33522
PC 2752	30629	34032	31990	7944
PC 2408	19087	23309	20776	-9058
PC 2672	27209	28949	27905	15606
PC 2740	12442	15455	13647	-7643
PC 2794	14394	17387	15591	-5561
PC 2830	23600	28017	25367	-5845
PC 2024	36903	39351	37882	20588
PC 2706	38604	40929	39534	23101
PC 2208	23078	24770	23755	11801
PC 2030	12270	14717	13249	-4045
PC 2676	16243	17984	16939	4641
PC 2026	26515	28963	27494	10200
PC 2748	12511	15524	13717	-7574
PC 2212	17694	19385	18370	6416
PC 2264	27475	29825	28415	11810
PC 2698	22004	23744	22700	10401

EK 5.16. 07.06.2023 Tarihli Filo Atamaları

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	0	0	1	0
PC 2028	1	0	0	0
PC 2404	0	0	1	0
PC 2678	0	0	0	1
PC 2746	0	0	0	1
PC 2402	0	0	1	0
PC 2000	0	0	1	0
PC 2770	0	1	0	0
PC 2080	0	0	1	0
PC 2180	1	0	0	0
PC 2380	0	1	0	0
PC 4051	0	0	1	0
PC 2860	0	0	1	0
PC 2430	0	1	0	0
PC 2490	0	1	0	0
PC 2590	0	0	1	0
PC 2004	0	0	1	0
PC 2662	1	0	0	0
PC 2790	0	0	1	0
PC 2700	0	0	1	0
PC 2150	0	0	1	0
PC 2284	0	0	0	1
PC 2814	1	0	0	0
PC 2184	1	0	0	0
PC 2006	0	0	0	1
PC 2082	0	0	1	0
PC 2792	0	0	0	1
PC 2244	0	0	1	0
PC 2732	0	0	1	0
PC 2008	0	0	1	0
PC 2086	0	0	0	1
PC 2664	0	0	1	0
PC 2816	0	0	1	0
PC 2188	1	0	0	0
PC 2734	0	0	1	0
PC 2010	0	0	1	0
PC 2822	0	0	1	0
PC 2666	1	0	0	0
PC 2194	0	0	0	1
PC 2248	0	0	1	0
PC 2286	0	0	1	0
PC 2370	0	1	0	0
PC 2088	0	0	1	0
PC 2824	0	0	0	1

PC 2016	0	0	1	0
PC 2570	0	0	1	0
PC 2668	0	0	1	0
PC 2092	0	0	1	0
PC 2502	0	1	0	0
PC 2204	1	0	0	0
PC 2384	0	1	0	0
PC 2818	0	0	0	1
PC 2094	0	0	1	0
PC 2554	0	1	0	0
PC 2292	0	0	1	0
PC 2532	0	0	1	0
PC 2670	0	0	1	0
PC 2218	0	0	0	1
PC 2258	0	0	0	1
PC 2944	1	0	0	0
PC 2072	0	0	1	0
PC 2862	0	0	1	0
PC 2420	0	0	1	0
PC 2022	0	0	1	0
PC 2294	0	0	0	1
PC 2096	0	0	1	0
PC 2752	0	0	1	0
PC 2408	0	0	0	1
PC 2672	0	0	0	1
PC 2740	0	0	1	0
PC 2794	0	0	1	0
PC 2830	0	0	1	0
PC 2024	0	0	1	0
PC 2706	0	0	0	1
PC 2208	1	0	0	0
PC 2030	0	0	1	0
PC 2676	0	0	1	0
PC 2026	0	0	0	1
PC 2748	0	0	1	0
PC 2212	1	0	0	0
PC 2264	0	0	1	0
PC 2698	0	0	0	1

EK 5.17. 07.06.2023 Tarihli Modelin Filo Atamalarının Kazanç Değerleri

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	51479	54989	52883	28079
PC 2028	38839	41286	39818	22524
PC 2404	50476	54698	52165	22331
PC 2678	28907	30647	29603	17304
PC 2746	57624	60637	58829	37539
PC 2402	12267	16489	13956	-15878
PC 2000	16562	19010	17541	247
PC 2770	62402	67228	64332	30227
PC 2080	26705	30215	28109	3305
PC 2180	25952	27643	26628	14674
PC 2380	63477	68503	65487	29969
PC 4051	11102	13505	12063	-4920
PC 2860	48341	52055	49827	23576
PC 2430	31629	36987	33772	-4089
PC 2490	67386	72899	69591	30628
PC 2590	87294	93052	89597	48912
PC 2004	23936	26383	24915	7621
PC 2662	27553	29293	28249	15950
PC 2790	34277	37270	35475	14322
PC 2700	24051	26376	24981	8548
PC 2150	54302	58583	56014	25767
PC 2284	42748	45152	43710	26726
PC 2814	70148	74565	71915	40703
PC 2184	20542	22233	21218	9264
PC 2006	45477	47924	46456	29162
PC 2082	50129	53639	51533	26729
PC 2792	50399	53392	51596	30444
PC 2244	24376	26726	25316	8711
PC 2732	27046	30059	28251	6961
PC 2008	21241	23688	22220	4926
PC 2086	69476	72986	70880	46076
PC 2664	26710	28450	27406	15107
PC 2816	22578	26994	24344	-6867
PC 2188	26223	27915	26900	14946
PC 2734	37239	40252	38444	17154
PC 2010	11582	14029	12561	-4733
PC 2822	13649	18066	15416	-15796
PC 2666	15972	17713	16668	4370
PC 2194	31182	32874	31859	19904
PC 2248	19888	22238	20828	4223
PC 2286	11512	13915	12473	-4510
PC 2370	60394	65781	62549	24481
PC 2088	42670	46180	44074	19270
PC 2824	76034	80450	77800	46589

PC 2016	12843	15291	13822	-3472
PC 2570	57571	61642	59199	30433
PC 2668	25352	27093	26049	13750
PC 2092	43672	47182	45076	20272
PC 2502	59686	65989	62207	17663
PC 2204	10759	12451	11436	-519
PC 2384	68277	73303	70287	34769
PC 2818	83957	88374	85723	54512
PC 2094	51286	54796	52690	27886
PC 2554	27266	32443	29336	-7249
PC 2292	7967	10370	8928	-8055
PC 2532	29939	34507	31767	-513
PC 2670	13597	15338	14294	1995
PC 2218	27909	29601	28586	16631
PC 2258	41387	43737	42327	25722
PC 2944	5088	5903	5414	-339
PC 2072	42795	45686	43951	23522
PC 2862	37390	41105	38876	12625
PC 2420	38356	43085	40247	6831
PC 2022	17745	20192	18724	1430
PC 2294	42538	44942	43500	26516
PC 2096	52226	55736	53630	28826
PC 2752	34061	37464	35422	11376
PC 2408	70086	74307	71774	41941
PC 2672	30610	32351	31306	19008
PC 2740	43046	46059	44251	22961
PC 2794	13977	16970	15174	-5978
PC 2830	48667	53084	50434	19222
PC 2024	18358	20805	19337	2043
PC 2706	44145	46471	45076	28643
PC 2208	24356	26048	25033	13078
PC 2030	21595	24042	22574	5280
PC 2676	7456	9196	8152	-4147
PC 2026	47955	50403	48934	31640
PC 2748	37429	40442	38634	17344
PC 2212	19550	21241	20226	8272
PC 2264	26384	28734	27324	10719
PC 2698	28993	30733	29689	17390

EK 5.18. Havayolu Filo Atamaları

Uçuş No	Uçuş Kodu	Filo Tipi	Uçuş No	Uçuş Kodu	Filo Tipi
1	PC 2098	A321-200 NEO	42	PC 2370	A320-200 NEO
2	PC 2028	A320-200 NEO	43	PC 2088	B737-800
3	PC 2404	A320-200 NEO	44	PC 2824	B737-800
4	PC 2678	A320-200 NEO	45	PC 2016	B737-800
5	PC 2746	A320-200 NEO	46	PC 2570	A320-200 NEO
6	PC 2402	A321-200 NEO	47	PC 2668	A320-200 NEO
7	PC 2000	A320-200 NEO	48	PC 2092	A321-200 NEO
8	PC 2770	A320-200 NEO	49	PC 2502	A320-200 NEO
9	PC 2080	A321-200 NEO	50	PC 2204	A321-200 NEO
10	PC 2180	A321-200 NEO	51	PC 2384	A321-200 NEO
11	PC 2380	A320-200 NEO	52	PC 2818	A321-200 NEO
12	PC 4051	A320-200 NEO	53	PC 2094	A321-200 NEO
13	PC 2860	A321-200 NEO	54	PC 2554	A321-200 NEO
14	PC 2430	A321-200 NEO	55	PC 2292	A321-200 NEO
15	PC 2490	B737-800	56	PC 2532	A321-200 NEO
16	PC 2590	A320-200 NEO	57	PC 2670	A320-200 NEO
17	PC 2004	A321-200 NEO	58	PC 2218	A321-200 NEO
18	PC 2662	A320-200 NEO	59	PC 2258	A321-200 NEO
19	PC 2790	A320-200 NEO	60	PC 2944	A320-200 NEO
20	PC 2700	B737-800	61	PC 2072	A321-200 NEO
21	PC 2150	A320-200 NEO	62	PC 2862	A320-200 NEO
22	PC 2284	A320-200 NEO	63	PC 2420	A320-200 NEO
23	PC 2814	A320-200 NEO	64	PC 2022	A321-200 NEO
24	PC 2184	A320-200 NEO	65	PC 2294	A321-200 NEO
25	PC 2006	A321-200 NEO	66	PC 2096	A321-200 NEO
26	PC 2082	A321-200 NEO	67	PC 2752	A320-200 NEO
27	PC 2792	A321-200 NEO	68	PC 2408	A320-200 NEO
28	PC 2244	B737-800	69	PC 2672	B737-800
29	PC 2732	A320-200 NEO	70	PC 2740	B737-800
30	PC 2008	A321-200 NEO	71	PC 2794	A320-200 NEO
31	PC 2086	A320-200 NEO	72	PC 2830	A320-200 NEO
32	PC 2664	B737-800	73	PC 2024	A321-200 NEO
33	PC 2816	A320-200 NEO	74	PC 2706	A321-200 NEO
34	PC 2188	B737-800	75	PC 2208	A320-200 NEO
35	PC 2734	A320-200 NEO	76	PC 2030	A320-200 NEO
36	PC 2010	B737-800	77	PC 2676	A320-200 NEO
37	PC 2822	B737-800	78	PC 2026	A320-200 NEO
38	PC 2666	B737-800	79	PC 2748	A320-200 NEO
39	PC 2194	B737-800	80	PC 2212	A320-200 NEO
40	PC 2248	B737-800	81	PC 2264	A321-200 NEO
41	PC 2286	B737-800	82	PC 2698	A320-200 NEO

EK 5.19. 01.06.2023 Tarihli Havayolunun Filo Atamalarının Kazanç Değerleri

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	56947	60457	58351	33547
PC 2028	27897	30344	28876	11582
PC 2404	86340	90562	88029	58195
PC 2678	14672	16412	15368	3070
PC 2746	15646	18659	16851	-4439
PC 2402	55334	59556	57023	27189
PC 2000	48999	51446	49978	32684
PC 2770	103861	108687	105792	71686
PC 2080	64590	68100	65994	41190
PC 2180	24169	25861	24846	12891
PC 2380	60825	65851	62835	27317
PC 4051	18983	21387	19945	2961
PC 2860	19276	22991	20762	-5489
PC 2430	98523	103881	100667	62806
PC 2490	55234	60748	57440	18477
PC 2590	121021	126779	123324	82639
PC 2004	19294	21741	20273	2979
PC 2662	35542	37283	36238	23940
PC 2790	51909	54902	53106	31954
PC 2700	48551	50877	49482	33049
PC 2150	64475	68755	66187	35940
PC 2284	43587	45991	44549	27565
PC 2814	20975	25392	22742	-8470
PC 2184	19768	21460	20445	8491
PC 2006	21025	23473	22004	4710
PC 2082	32896	36406	34300	9496
PC 2792	18176	21169	19373	-1779
PC 2244	23782	26132	24722	8117
PC 2732	25492	28505	26697	5407
PC 2008	21838	24285	22817	5523
PC 2086	47876	51386	49280	24476
PC 2664	24624	26365	25321	13022
PC 2816	87900	92316	89666	58455
PC 2188	13415	15107	14092	2138
PC 2734	41027	44039	42232	20942
PC 2010	37700	40147	38679	21385
PC 2822	62199	66616	63966	32754
PC 2666	14446	16187	15143	2844
PC 2194	23832	25524	24509	12555
PC 2248	50461	52810	51400	34796
PC 2286	10311	12715	11273	-5711
PC 2370	91399	96785	93553	55486
PC 2088	49952	53462	51356	26552

PC 2824	58806	63223	60573	29361
PC 2016	53668	56116	54647	37353
PC 2570	74551	78621	76179	47413
PC 2668	29078	30818	29774	17475
PC 2092	52415	55925	53819	29015
PC 2502	99209	105512	101730	57186
PC 2204	23060	24751	23736	11782
PC 2384	93088	98114	95098	59580
PC 2818	39691	44108	41458	10246
PC 2094	31155	34665	32559	7755
PC 2554	42900	48077	44971	8385
PC 2292	35394	37797	36355	19371
PC 2532	35731	40298	37558	5278
PC 2670	21563	23304	22259	9961
PC 2218	13528	15220	14205	2251
PC 2258	21162	23512	22102	5497
PC 2944	13790	14604	14115	8362
PC 2072	32885	35776	34042	13613
PC 2862	24210	27924	25695	-555
PC 2420	87974	92703	89866	56449
PC 2022	46688	49136	47667	30373
PC 2294	47531	49934	48492	31508
PC 2096	53729	57239	55133	30329
PC 2752	18018	21420	19379	-4667
PC 2408	70045	74267	71734	41900
PC 2672	27207	28947	27903	15605
PC 2740	11753	14765	12958	-8332
PC 2794	42923	45916	44120	22968
PC 2830	89393	93809	91159	59948
PC 2024	13280	15728	14259	-3035
PC 2706	28307	30632	29237	12804
PC 2208	33444	35136	34121	22166
PC 2030	11965	14412	12944	-4350
PC 2676	10784	12524	11480	-819
PC 2026	10988	13435	11967	-5327
PC 2748	23410	26423	24615	3325
PC 2212	15632	17324	16309	4354
PC 2264	29680	32030	30620	14015
PC 2698	22942	24683	23639	11340

EK 5.20. 02.06.2023 Tarihli Havayolunun Filo Atamalarının Kazanç Değerleri

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	56925	60435	58329	33525
PC 2028	28187	30634	29166	11872
PC 2404	103427	107649	105116	75282
PC 2678	40128	41868	40824	28526
PC 2746	19875	22888	21080	-210
PC 2402	68659	72881	70348	40514
PC 2000	59070	61518	60049	42755
PC 2770	35781	40607	37711	3606
PC 2080	53179	56689	54583	29779
PC 2180	15054	16745	15730	3776
PC 2380	44859	49885	46869	11352
PC 4051	34943	37347	35905	18921
PC 2860	57126	60841	58612	32361
PC 2430	139821	145179	141964	104103
PC 2490	119197	124711	121403	82440
PC 2590	131236	136993	133539	92853
PC 2004	35850	38297	36829	19535
PC 2662	16202	17942	16898	4599
PC 2790	25347	28340	26544	5392
PC 2700	18142	20467	19072	2639
PC 2150	46672	50953	48384	18137
PC 2284	52608	55011	53569	36585
PC 2814	111677	116094	113444	82232
PC 2184	16360	18051	17036	5082
PC 2006	40880	43328	41859	24565
PC 2082	37083	40593	38487	13683
PC 2792	20799	23792	21996	844
PC 2244	59792	62142	60732	44127
PC 2732	32166	35178	33371	12081
PC 2008	25962	28409	26941	9647
PC 2086	68733	72243	70137	45333
PC 2664	23291	25032	23987	11689
PC 2816	51543	55960	53310	22098
PC 2188	37097	38789	37774	25820
PC 2734	33033	36046	34238	12948
PC 2010	32869	35317	33848	16554
PC 2822	52025	56442	53792	22580
PC 2666	29636	31376	30332	18033
PC 2194	13264	14956	13941	1986
PC 2248	28621	30971	29561	12956
PC 2286	58814	61217	59775	42791
PC 2370	37934	43320	40088	2021
PC 2088	82665	86175	84069	59265

PC 2824	111110	115527	112877	81665
PC 2016	38876	41323	39855	22561
PC 2570	98411	102481	100039	71273
PC 2668	39918	41658	40614	28315
PC 2092	33438	36948	34842	10038
PC 2502	53133	59437	55655	11111
PC 2204	14286	15978	14963	3009
PC 2384	57063	62089	59074	23556
PC 2818	112745	117162	114512	83300
PC 2094	67063	70573	68467	43663
PC 2554	52360	57537	54431	17845
PC 2292	30189	32592	31150	14166
PC 2532	118831	123399	120658	88379
PC 2670	20089	21829	20785	8486
PC 2218	25033	26724	25709	13755
PC 2258	56116	58466	57056	40451
PC 2944	5489	6304	5815	62
PC 2072	28623	31513	29779	9350
PC 2862	49227	52942	50713	24462
PC 2420	36592	41321	38483	5067
PC 2022	34401	36848	35380	18086
PC 2294	34634	37038	35596	18612
PC 2096	53238	56748	54642	29838
PC 2752	85957	89360	87318	63272
PC 2408	85955	90176	87643	57810
PC 2672	26223	27963	26919	14620
PC 2740	44941	47954	46146	24856
PC 2794	39717	42711	40915	19762
PC 2830	41261	45677	43027	11816
PC 2024	54407	56854	55385	38092
PC 2706	19119	21444	20049	3617
PC 2208	28867	30558	29543	17589
PC 2030	24956	27403	25935	8641
PC 2676	19744	21485	20441	8142
PC 2026	17203	19651	18182	888
PC 2748	72715	75727	73920	52630
PC 2212	29957	31649	30634	18680
PC 2264	21174	23523	22113	5509
PC 2698	40983	42724	41679	29381

EK 5.21. 03.06.2023 Tarihli Havayolunun Filo Atamalarının Kazanç Değerleri

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	36876	40386	38280	13476
PC 2028	22161	24608	23140	5846
PC 2404	35367	39589	37056	7222
PC 2678	27722	29463	28418	16120
PC 2746	60614	63626	61819	40529
PC 2402	104223	108445	105912	76078
PC 2000	46102	48550	47081	29787
PC 2770	113392	118219	115323	81217
PC 2080	51918	55428	53322	28518
PC 2180	29261	30953	29938	17983
PC 2380	112927	117953	114937	79419
PC 4051	25131	27534	26092	9108
PC 2860	79644	83359	81130	54879
PC 2430	110222	115579	112365	74504
PC 2490	123561	129075	125767	86804
PC 2590	87521	93278	89824	49138
PC 2004	54176	56623	55155	37861
PC 2662	46215	47955	46911	34612
PC 2790	43541	46534	44738	23586
PC 2700	27057	29383	27987	11555
PC 2150	55238	59518	56950	26703
PC 2284	34215	36618	35176	18192
PC 2814	49997	54414	51764	20552
PC 2184	43970	45662	44647	32692
PC 2006	28490	30937	29468	12175
PC 2082	71338	74848	72742	47938
PC 2792	24863	27856	26060	4908
PC 2244	24995	27344	25935	9330
PC 2732	32076	35089	33281	11991
PC 2008	42655	45103	43634	26340
PC 2086	34221	37731	35625	10821
PC 2664	20416	22157	21112	8814
PC 2816	70500	74916	72266	41055
PC 2188	29119	30811	29796	17842
PC 2734	28132	31145	29337	8047
PC 2010	22964	25411	23942	6649
PC 2822	105854	110271	107621	76409
PC 2666	19644	21384	20340	8041
PC 2194	35689	37380	36365	24411
PC 2248	41411	43760	42351	25746
PC 2286	29359	31763	30321	13337
PC 2370	47091	52478	49246	11179
PC 2088	46587	50097	47991	23187

PC 2824	111333	115750	113100	81888
PC 2016	29422	31869	30401	13107
PC 2570	51370	55440	52998	24232
PC 2668	15144	16884	15840	3541
PC 2092	28365	31875	29769	4965
PC 2502	56886	63189	59407	14863
PC 2204	29624	31316	30301	18347
PC 2384	42382	47408	44393	8875
PC 2818	55430	59847	57197	25985
PC 2094	40821	44331	42225	17421
PC 2554	70934	76111	73004	36419
PC 2292	60213	62617	61175	44191
PC 2532	59409	63977	61237	28957
PC 2670	23761	25501	24457	12158
PC 2218	25318	27010	25995	14041
PC 2258	27515	29865	28455	11850
PC 2944	10138	10952	10463	4710
PC 2072	16994	19885	18150	-2279
PC 2862	77232	80946	78718	52467
PC 2420	55282	60011	57174	23757
PC 2022	63429	65876	64407	47114
PC 2294	33913	36316	34874	17890
PC 2096	54191	57701	55595	30791
PC 2752	28211	31614	29572	5526
PC 2408	52787	57009	54475	24642
PC 2672	22578	24318	23274	10975
PC 2740	46146	49159	47351	26061
PC 2794	47354	50347	48551	27399
PC 2830	79880	84297	81647	50435
PC 2024	30147	32595	31126	13832
PC 2706	19328	21653	20258	3825
PC 2208	17426	19117	18102	6148
PC 2030	25759	28206	26738	9444
PC 2676	30378	32118	31074	18776
PC 2026	34143	36591	35122	17828
PC 2748	37498	40510	38703	17413
PC 2212	36563	38255	37240	25286
PC 2264	52470	54819	53409	36805
PC 2698	39752	41492	40448	28149

EK 5.22. 04.06.2023 Tarihli Havayolunun Filo Atamalarının Kazanç Değerleri

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	82385	85895	83789	58985
PC 2028	56532	58979	57511	40217
PC 2404	89335	93556	91023	61190
PC 2678	16771	18512	17467	5169
PC 2746	66173	69186	67378	46088
PC 2402	52111	56332	53799	23966
PC 2000	18677	21124	19656	2362
PC 2770	48501	53327	50432	16326
PC 2080	74243	77753	75647	50843
PC 2180	25273	26964	25949	13995
PC 2380	63988	69014	65998	30480
PC 4051	55436	57840	56398	39414
PC 2860	25047	28762	26533	282
PC 2430	60072	65430	62215	24355
PC 2490	103384	108897	105589	66626
PC 2590	62667	68425	64970	24285
PC 2004	28121	30568	29100	11806
PC 2662	30840	32581	31536	19238
PC 2790	36110	39103	37308	16155
PC 2700	25944	28270	26875	10442
PC 2150	57342	61622	59054	28807
PC 2284	16038	18441	16999	16
PC 2814	58622	63039	60389	29177
PC 2184	33079	34771	33756	21801
PC 2006	59385	61832	60364	43070
PC 2082	54189	57699	55593	30789
PC 2792	32202	35195	33399	12247
PC 2244	16171	18520	17111	506
PC 2732	34657	37670	35862	14572
PC 2008	18808	21256	19787	2493
PC 2086	76673	80183	78077	53273
PC 2664	10725	12465	11421	-878
PC 2816	67439	71856	69206	37994
PC 2188	43838	45530	44515	32561
PC 2734	22538	25550	23743	2453
PC 2010	16632	19079	17611	317
PC 2822	58188	62605	59955	28743
PC 2666	10954	12694	11650	-649
PC 2194	23815	25507	24492	12538
PC 2248	45778	48128	46718	30113
PC 2286	55974	58378	56936	39952
PC 2370	48750	54137	50905	12838
PC 2088	24249	27759	25653	849

PC 2824	32461	36878	34228	3016
PC 2016	32422	34869	33401	16107
PC 2570	24529	28599	26157	-2609
PC 2668	37748	39488	38444	26145
PC 2092	58706	62216	60110	35306
PC 2502	95445	101749	97967	53423
PC 2204	41231	42923	41908	29954
PC 2384	69822	74848	71832	36314
PC 2818	72232	76648	73998	42787
PC 2094	29592	33102	30996	6192
PC 2554	121904	127081	123974	87389
PC 2292	25787	28191	26749	9765
PC 2532	102398	106966	104226	71946
PC 2670	17145	18885	17841	5543
PC 2218	32882	34573	33558	21604
PC 2258	31334	33684	32274	15669
PC 2944	21545	22359	21870	16117
PC 2072	33043	35934	34200	13771
PC 2862	79196	82911	80682	54431
PC 2420	112973	117702	114865	81448
PC 2022	30823	33270	31802	14508
PC 2294	15715	18119	16677	-307
PC 2096	26430	29940	27834	3030
PC 2752	55630	59033	56991	32945
PC 2408	55519	59741	57208	27374
PC 2672	25809	27549	26505	14206
PC 2740	39708	42720	40913	19623
PC 2794	68479	71472	69676	48524
PC 2830	49989	54406	51755	20544
PC 2024	22453	24900	23432	6138
PC 2706	28856	31181	29786	13353
PC 2208	14879	16571	15556	3602
PC 2030	44692	47140	45671	28377
PC 2676	20491	22232	21187	8889
PC 2026	18955	21403	19934	2640
PC 2748	39437	42450	40642	19352
PC 2212	22372	24064	23049	11095
PC 2264	60070	62420	61010	44405
PC 2698	28784	30525	29480	17182

EK 5.23. 05.06.2023 Tarihli Havayolunun Filo Atamalarının Kazanç Değerleri

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	63875	67385	65279	40475
PC 2028	20248	22695	21227	3933
PC 2404	53588	57810	55276	25443
PC 2678	29510	31250	30206	17907
PC 2746	44538	47551	45743	24453
PC 2402	107577	111799	109266	79432
PC 2000	55082	57529	56061	38767
PC 2770	112421	117247	114351	80246
PC 2080	61132	64642	62536	37732
PC 2180	28513	30205	29190	17236
PC 2380	42066	47092	44077	8559
PC 4051	58987	61391	59949	42965
PC 2860	37713	41428	39199	12948
PC 2430	66702	72060	68845	30985
PC 2490	100554	106067	102759	63796
PC 2590	103411	109169	105714	65029
PC 2004	34331	36779	35310	18016
PC 2662	17412	19152	18108	5809
PC 2790	23230	26223	24427	3275
PC 2700	45906	48231	46836	30403
PC 2150	95808	100089	97521	67273
PC 2284	40674	43078	41636	24652
PC 2814	91382	95799	93149	61937
PC 2184	9452	11144	10129	-1825
PC 2006	18002	20449	18981	1687
PC 2082	42979	46489	44383	19579
PC 2792	44318	47311	45515	24363
PC 2244	28960	31310	29900	13295
PC 2732	15863	18876	17068	-4222
PC 2008	35397	37844	36376	19082
PC 2086	56447	59957	57851	33047
PC 2664	32813	34553	33509	21210
PC 2816	22967	27384	24734	-6478
PC 2188	20369	22061	21046	9092
PC 2734	23718	26731	24923	3633
PC 2010	37550	39997	38529	21235
PC 2822	48193	52610	49959	18748
PC 2666	15841	17582	16537	4239
PC 2194	22161	23852	22837	10883
PC 2248	40133	42483	41073	24468
PC 2286	15437	17840	16398	-586
PC 2370	38892	44278	41046	2979
PC 2088	60783	64293	62187	37383

PC 2824	81067	85483	82833	51622
PC 2016	52484	54931	53463	36169
PC 2570	46419	50489	48047	19281
PC 2668	37930	39670	38626	26327
PC 2092	18816	22326	20220	-4584
PC 2502	145393	151697	147915	103371
PC 2204	8874	10566	9551	-2403
PC 2384	47476	52502	49486	13968
PC 2818	69419	73836	71186	39974
PC 2094	20652	24162	22056	-2748
PC 2554	50748	55926	52819	16233
PC 2292	12156	14559	13117	-3867
PC 2532	32339	36907	34166	1886
PC 2670	39605	41345	40301	28002
PC 2218	8101	9792	8777	-3177
PC 2258	52142	54492	53082	36477
PC 2944	17528	18343	17854	12101
PC 2072	40059	42950	41215	20786
PC 2862	44264	47979	45750	19499
PC 2420	110442	115171	112333	78917
PC 2022	45558	48005	46537	29243
PC 2294	60300	62703	61261	44277
PC 2096	29885	33395	31289	6485
PC 2752	33305	36708	34666	10620
PC 2408	38935	43157	40624	10790
PC 2672	16947	18687	17643	5344
PC 2740	37217	40230	38422	17132
PC 2794	65392	68385	66589	45437
PC 2830	62059	66476	63826	32614
PC 2024	57417	59864	58396	41102
PC 2706	36989	39315	37919	21487
PC 2208	15290	16982	15967	4013
PC 2030	35297	37744	36276	18982
PC 2676	30801	32541	31497	19198
PC 2026	41821	44268	42800	25506
PC 2748	23464	26477	24669	3379
PC 2212	18442	20134	19119	7165
PC 2264	17663	20013	18603	1998
PC 2698	21816	23557	22513	10214

EK 5.24. 06.06.2023 Tarihli Havayolunun Filo Atamalarının Kazanç Değerleri

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	16701	20211	18105	-6699
PC 2028	33481	35929	34460	17166
PC 2404	16243	20465	17932	-11902
PC 2678	24712	26453	25408	13110
PC 2746	31027	34040	32232	10942
PC 2402	59033	63255	60722	30888
PC 2000	11601	14048	12580	-4714
PC 2770	71952	76778	73882	39777
PC 2080	26848	30358	28252	3448
PC 2180	16720	18412	17397	5443
PC 2380	39171	44197	41181	5663
PC 4051	30591	32994	31552	14568
PC 2860	42223	45938	43709	17458
PC 2430	71831	77189	73974	36114
PC 2490	67051	72565	69257	30294
PC 2590	105266	111023	107569	66883
PC 2004	35944	38392	36923	19629
PC 2662	14630	16370	15326	3028
PC 2790	41276	44269	42474	21321
PC 2700	33676	36002	34607	18174
PC 2150	62931	67211	64643	34396
PC 2284	41271	43675	42233	25249
PC 2814	48014	52430	49780	18569
PC 2184	21454	23146	22131	10177
PC 2006	35970	38417	36949	19655
PC 2082	51517	55027	52921	28117
PC 2792	20253	23246	21450	298
PC 2244	40513	42863	41453	24848
PC 2732	45597	48610	46802	25512
PC 2008	25221	27668	26200	8906
PC 2086	56225	59735	57629	32825
PC 2664	10746	12486	11442	-857
PC 2816	42804	47221	44571	13359
PC 2188	18288	19980	18965	7011
PC 2734	66059	69071	67264	45974
PC 2010	16306	18754	17285	-9
PC 2822	26921	31337	28687	-2524
PC 2666	25341	27081	26037	13738
PC 2194	27767	29459	28444	16490
PC 2248	37901	40251	38841	22236
PC 2286	31044	33448	32006	15022
PC 2370	44458	49845	46613	8546
PC 2088	47455	50965	48859	24055

PC 2824	21020	25437	22787	-8425
PC 2016	8911	11358	9890	-7404
PC 2570	29477	33548	31105	2340
PC 2668	8980	10720	9676	-2623
PC 2092	52192	55702	53596	28792
PC 2502	92081	98385	94603	50059
PC 2204	23609	25301	24286	12332
PC 2384	58367	63393	60378	24860
PC 2818	70412	74829	72179	40967
PC 2094	30564	34074	31968	7164
PC 2554	72741	77918	74811	38226
PC 2292	31441	33844	32402	15418
PC 2532	16216	20784	18043	-14236
PC 2670	8470	10210	9166	-3133
PC 2218	25041	26733	25718	13764
PC 2258	30102	32452	31042	14437
PC 2944	11896	12710	12221	6468
PC 2072	18690	21581	19846	-583
PC 2862	24113	27827	25599	-652
PC 2420	112468	117197	114359	80943
PC 2022	24578	27025	25557	8263
PC 2294	40714	43117	41675	24691
PC 2096	56922	60432	58326	33522
PC 2752	30629	34032	31990	7944
PC 2408	19087	23309	20776	-9058
PC 2672	27209	28949	27905	15606
PC 2740	12442	15455	13647	-7643
PC 2794	14394	17387	15591	-5561
PC 2830	23600	28017	25367	-5845
PC 2024	36903	39351	37882	20588
PC 2706	38604	40929	39534	23101
PC 2208	23078	24770	23755	11801
PC 2030	12270	14717	13249	-4045
PC 2676	16243	17984	16939	4641
PC 2026	26515	28963	27494	10200
PC 2748	12511	15524	13717	-7574
PC 2212	17694	19385	18370	6416
PC 2264	27475	29825	28415	11810
PC 2698	22004	23744	22700	10401

EK 5.25. 07.06.2023 Tarihli Havayolunun Filo Atamalarının Kazanç Değerleri

Uçuş Kodu	B737-800	A320-200 CEO	A320-200 NEO	A321-200 NEO
PC 2098	51479	54989	52883	28079
PC 2028	38839	41286	39818	22524
PC 2404	50476	54698	52165	22331
PC 2678	28907	30647	29603	17304
PC 2746	57624	60637	58829	37539
PC 2402	12267	16489	13956	-15878
PC 2000	16562	19010	17541	247
PC 2770	62402	67228	64332	30227
PC 2080	26705	30215	28109	3305
PC 2180	25952	27643	26628	14674
PC 2380	63477	68503	65487	29969
PC 4051	11102	13505	12063	-4920
PC 2860	48341	52055	49827	23576
PC 2430	31629	36987	33772	-4089
PC 2490	67386	72899	69591	30628
PC 2590	87294	93052	89597	48912
PC 2004	23936	26383	24915	7621
PC 2662	27553	29293	28249	15950
PC 2790	34277	37270	35475	14322
PC 2700	24051	26376	24981	8548
PC 2150	54302	58583	56014	25767
PC 2284	42748	45152	43710	26726
PC 2814	70148	74565	71915	40703
PC 2184	20542	22233	21218	9264
PC 2006	45477	47924	46456	29162
PC 2082	50129	53639	51533	26729
PC 2792	50399	53392	51596	30444
PC 2244	24376	26726	25316	8711
PC 2732	27046	30059	28251	6961
PC 2008	21241	23688	22220	4926
PC 2086	69476	72986	70880	46076
PC 2664	26710	28450	27406	15107
PC 2816	22578	26994	24344	-6867
PC 2188	26223	27915	26900	14946
PC 2734	37239	40252	38444	17154
PC 2010	11582	14029	12561	-4733
PC 2822	13649	18066	15416	-15796
PC 2666	15972	17713	16668	4370
PC 2194	31182	32874	31859	19904
PC 2248	19888	22238	20828	4223
PC 2286	11512	13915	12473	-4510
PC 2370	60394	65781	62549	24481
PC 2088	42670	46180	44074	19270

PC 2824	76034	80450	77800	46589
PC 2016	12843	15291	13822	-3472
PC 2570	57571	61642	59199	30433
PC 2668	25352	27093	26049	13750
PC 2092	43672	47182	45076	20272
PC 2502	59686	65989	62207	17663
PC 2204	10759	12451	11436	-519
PC 2384	68277	73303	70287	34769
PC 2818	83957	88374	85723	54512
PC 2094	51286	54796	52690	27886
PC 2554	27266	32443	29336	-7249
PC 2292	7967	10370	8928	-8055
PC 2532	29939	34507	31767	-513
PC 2670	13597	15338	14294	1995
PC 2218	27909	29601	28586	16631
PC 2258	41387	43737	42327	25722
PC 2944	5088	5903	5414	-339
PC 2072	42795	45686	43951	23522
PC 2862	37390	41105	38876	12625
PC 2420	38356	43085	40247	6831
PC 2022	17745	20192	18724	1430
PC 2294	42538	44942	43500	26516
PC 2096	52226	55736	53630	28826
PC 2752	34061	37464	35422	11376
PC 2408	70086	74307	71774	41941
PC 2672	30610	32351	31306	19008
PC 2740	43046	46059	44251	22961
PC 2794	13977	16970	15174	-5978
PC 2830	48667	53084	50434	19222
PC 2024	18358	20805	19337	2043
PC 2706	44145	46471	45076	28643
PC 2208	24356	26048	25033	13078
PC 2030	21595	24042	22574	5280
PC 2676	7456	9196	8152	-4147
PC 2026	47955	50403	48934	31640
PC 2748	37429	40442	38634	17344
PC 2212	19550	21241	20226	8272
PC 2264	26384	28734	27324	10719
PC 2698	28993	30733	29689	17390