



**YAPAY SİNİR AĞLARI VE ARİMA HİBRİT ZAMAN
SERİSİ MODELİ İLE HAVAYOLU REZERVASYONU
TAHMİNİ**

Alaa ABUSHUKUR

**2022
YÜKSEK LİSANS TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI**

**Tez Danışmanı
Dr. Öğr. Üyesi Yusuf KURTGÖZ**

**YAPAY SİNİR AĞLARI VE ARİMA HİBRİT ZAMAN SERİSİ MODELİ İLE
HAVAYOLU REZERVASYONU TAHMİNİ**

Alaa ABUSHUKUR

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Endüstri Mühendisliği Anabilim Dalında
Yüksek Lisans Tezi
Olarak Hazırlanmıştır**

**Tez Danışmanı
Dr. Öğr. Üyesi Yusuf KURTGÖZ**

**KARABÜK
Haziran 2022**

Alaa ABUSHUKUR tarafından hazırlanan “YAPAY SİNİR AĞLARI VE ARİMA HİBRİT ZAMAN SERİSİ MODELİ İLE HAVAYOLU REZERVASYONU TAHMİNİ” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Dr. Öğr. Üyesi Yusuf KURTGÖZ
Tez Danışmanı, Endüstri Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Endüstri Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 28/06/2022

<u>Ünvanı, Adı SOYADI (Kurumu)</u>	<u>İmzası</u>
Başkan : Dr. Öğr. Üyesi Tuğba TUNACAN (BAİBU)Online.....
Üye : Dr. Öğr. Üyesi Yusuf KURTGÖZ (KBÜ)
Üye : Dr. Öğr. Üyesi Selçuk ÖZCAN (KBÜ)

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Yüksek Lisans derecesini onamıştır.

Prof. Dr. Hasan SOLMAZ
Lisansüstü Eğitim Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Alaa ABUSHUKUR

ÖZET

Yüksek Lisans Tezi

YAPAY SİNİR AĞLARI VE ARİMA HİBRİT ZAMAN SERİSİ MODELİ İLE HAVAYOLU REZERVASYONU TAHMİNİ

Alaa ABUSHUKUR

**Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Endüstri Mühendisliği Anabilim Dalı**

Tez Danışmanı:

Dr. Öğr. Üyesi Yusuf KURTGÖZ

Haziran 2022, 55 sayfa

Bu çalışmada, bir havayolunun uçuş planındaki envanter ataması için zaman serisi analizi ile uçuş gününde beklenen toplam rezervasyon öngörülmüştür. Yapay sinir ağları ve otoregresif bütünleşik hareketli ortalama süreci (ARİMA) yöntemleri uygulanmıştır. Yapay sinir ağları doğrusal olmayan veriler üzerinde ileri performans gösterdiği halde lineer verilerin ilişkisini yakalamakta ARİMA modeli daha iyi sonuçlar vermektedir. Dolayısı ile her iki yöntemin avantajlarını bir araya getiren yapay sinir ağları ve ARİMA modellerinin sonuçlarını birlikte dikkate alan hibrit model geliştirilmiştir. Sonuç olarak çalışma kapsamında ele alınan rota için yolcu ve kargo rezervasyonu tahmin edilip uçuş çizelgelemesinde yapılan kapasite ataması değerlendirilmiştir.

Anahtar Sözcükler : Hibrit zaman serisi modelleri, Havayolu rezervasyon tahmini,
ARIMA, NAR, Havayolu envanter ataması.

Bilim Kodu : 90619

ABSTRACT

M. Sc. Thesis

AIRLINE RESERVATION FORECAST WITH ARTIFICIAL NEURAL NETWORKS AND ARIMA HYBRID TIME SERIES MODEL

Alaa ABUSHUKUR

**Karabük University
Institute of Graduate Programs
Department of Industrial Engineering**

Thesis Advisor:

Assist. Prof. Dr. Yusuf KURTGÖZ

June 2022, 55 pages

In this study, the total expected reservation on the day of the flight is predicted by time series analysis for the inventory assignment of an airline's flight plans. Artificial neural networks and autoregressive integrated moving average process (ARIMA) methods have been applied. Although artificial neural networks have advanced performance on non-linear data, the ARIMA model gives better results in capturing the relationship of linear data. Therefore, a hybrid model has been developed that combines the advantages of both methods, considering the results of artificial neural networks and ARIMA models the passenger and cargo reservation for the route considered within the scope of the study was estimated and the capacity assignment made in the flight schedule was evaluated.

Key Word : Hybrid Time Series Models, Airline Reservation Forecast, ARIMA,
NAR, Airline Envanter Management

Science Code : 90619

TEŐEKKÜR

Bu tez alıőması yřrřtřlmesi ve tamamlanmasında yardım ve ilgisini hibir Őekilde esirgemeyen, deęerli deneyimleri ile beni yřnlendiren ve bilgilendirmeleriyle bilimsel temeller iŐıęında danıŐmanlık yapan sayın hocam Dr. Yusuf KURTGÖZ'e sonsuz teŐekkřrlerimi sunarım. Dualarını hibir zaman esirgemeyen anneme, zorlanıp vazgemeyi dřŐřndřęřmde beni motive ederek yolun sonuna kadar destekleyen aileme olan minnettarlıęımı ifade etmeye dřnyanın třm dilleri yetersiz kalır.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELELER DİZİNİ	xii
SİMGELER VE KISALTMALAR DİZİNİ	xiii
BÖLÜM 1	1
GİRİŞ	1
BÖLÜM 2	4
LİTERATÜR TARAMASI.....	4
2.1. GELİR YÖNETİMİNDE TAHMİN	5
2.2. ENVANTER YÖNETİMİ.....	6
2.2. KÂR MAKSİMİZASYONU.....	7
BÖLÜM 3	9
HAVAYOLU REZERVASYON TAHMİNİ	9
3.1. BİREYSEL VE GRUP REZERVASYONU.....	10
3.2. MÜŞTERİ DAVRANIŞI	12
3.3. HAVAYOLU REZERVASYONU GELİŞİMİ.....	13
3.4. HAVAYOLU REZERVASYON SÜRECİ.....	14
3.4.1. Rezervasyon Aşaması.....	17
3.4.2. İptal Aşaması	17
3.4.3. Boarding Aşaması.....	18
BÖLÜM 4	19
ZAMAN SERİSİ ANALİZİ.....	19
4.1. ZAMAN SERİLERİ KALIPLARI.....	20

	<u>Sayfa</u>
4.1.1. Trend.....	20
4.1.2. Mevsimsellik.....	21
4.1.3. Konjonktürel	21
4.1.4. Rassallık.....	22
4.2. ARİMA MODELLERİ.....	22
4.2. BOX-JENKINS PROSEDÜRÜ	23
4.3. YAPAY SİNİR AĞLARI.....	24
4.3.1. Nöron Yapısı.....	25
4.3.2. Ağları Yapısı.....	25
4.3.3. Aktivasyon Fonksiyonları.....	26
4.3.4. Sinir Ağları Özellikleri	28
4.3.5. Geri ve İleri Beslemeli Yapay Sinir Ağı.....	29
BÖLÜM 5	30
ARIMA-YSA HİBRİT MODELİ	30
5.1. ZHANG HİBRİT MODELİ	31
BÖLÜM 6	32
UYGULAMA	32
6.1. KULLANILAN VERİSETİ	32
6.2. ARİMA MODELİ UYGULAMASI	33
6.3. YAPAY SİNİR AĞLARI UYGULAMASI.....	39
6.4. ARIMA-YSA HİBRİT MODELİ	44
BÖLÜM 7	48
SONUÇ VE DEĞERLENDİRME.....	48
KAYNAKLAR	51
ÖZGEÇMİŞ	55

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Uçak bileti, gelir, maliyet ve kâr arasındaki doğrusal olmayan ilişki.....	8
Şekil 3.1. Havayolu rezervasyon sistemi.....	14
Şekil 3.2. Havayolu rezervasyon süreci	16
Şekil 4.1. Trend zaman serisi örnekleri.....	21
Şekil 4.2. Box-Jenkins prosedürü.....	24
Şekil 4.3. Tek gizli katmana sahip çok katmanlı ileri beslemeli sinir ağı mimarisi.	26
Şekil 4.4. Hiperbolik tanjant & sigmoid fonksiyonları [38].....	27
Şekil 4.5. Geri beslemeli yapay sinir ağı yapısı	29
Şekil 6.1. Haftalık yolcu ve kargo rezervasyon serisi	33
Şekil 6.2. Yolcu ve kargo verilerin ACF ve PACF grafikleri	34
Şekil 6.3. Yolcu ve kargo artık değerlerinin ACF ve PACF grafikleri	36
Şekil 6.4. Yolcu serisi artık değerleri analizi	37
Şekil 6.5. Kargo serisi artık değerleri analizi	38
Şekil 6.6. Yolcu ve kargo rezervasyonu zaman serilerin arima modeli tahmini.....	39
Şekil 6.7. Yolcu ve kargo serisi için NN eğitim performansı	41
Şekil 6.8. Yolcu ve ve kargo serisi NN eğitim hatası.....	41
Şekil 6.9. Kargo serisi regresyon değerleri	42
Şekil 6.10 Yolcu serisi regresyon değerleri.....	43
Şekil 6.11. Yolcu serisi regresyon değerleri.....	44
Şekil 6.12. ARIMA modelleri artık değerleri.....	45
Şekil 6.13. ARIMA-NAR modelleri hata otokorelasyon grafiği	46
Şekil 6.14. ARIMA-NAR hibrit artık değer zaman serisi sonucu.....	47
Şekil 7.1. Geçekleşen kargo ve yolcu rezervasyonu ile hibrit tahmin değerleri	49

ÇİZELGELELER DİZİNİ

Sayfa

Çizelge 1.1. Litratürde geçen havayolu sektöründe bazı tahmin modelleri.	2
Çizelge 2.1. Bilinen bazı uçak kapasiteleri.	7
Çizelge 4.1. Aktivasyon fonksiyonları.	27
Çizelge 6.1. Yolcu serisinin ARİMA (2,2,1) modeli tahmin parametreleri.	34
Çizelge 6.2. Kargo veri serisi ARİMA (2,2,1) modeli tahmin parametreleri.	35
Çizelge 6.3. Yolcu veri serisinin ARİMA (2,2,1) modeli.	35
Çizelge 6.4. Kargo verisi ARİMA (2,2,1) Ljung-Box chi-square değerleri.	36
Çizelge 6.5. Farklı gecikme ve nöron sayısı ile ağ performansı.	40
Çizelge 7.1. Tüm modellerinin tahmin performanslarının karşılaştırılması.	48

SİMGELER VE KISALTMALAR DİZİNİ

ARIMA	: Autoregressive Integration Moving Average
ACF	: Auto-Correlation Function
PACF	: Partial Auto-Correlation Function
TBG	: Toplam Beklenen Gelir
YSA	: Yapay Sinir Ağları
NN	: Neural Network
NAR	: Nonlinear Autoregressive
CAP	: Capacity
TCAP	: Total Capacity
PNR	: Passenger Name Record (Yolcu İsim Kaydı)
CRS	: Central reservation systems (Merkezi Rezervasyon Sistemi)
GDS	: Global distribution system (Küresel Dağıtım Sistemi)
ATPCO	: The Airline Tariff Publishing Company
MSE	: Mean squared error (Ortalama Kare Hata)
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
DCS	: Kalkış Kontrol Sistemi (Departure Control System)

BÖLÜM 1

GİRİŞ

Literatüre bakıldığında havayolu sektöründe yapılan tahmin modellerinin genel anlamı ile çeşitli parametreleri kullanarak farklı modelleme yöntemleri ile geliştirildiğini görebiliriz. Özellikle havayolu gelir yönetim tahmini üzerinde yapılan çalışmaların çeşitli boyutlar aldığı gözlemlenmektedir. Toplam talep açısından Biederman [1], havalimanları ile ilgili altyapı yatırımlarında uzun vadeli yolcu tahminlerinin esas değişken olduğunu öne sürmüştür. Duncanson ve arkadaşları [2] üstel düzleştirme yöntemini kullanarak kısa vadeli havayolu rezervasyon tahmini yapmışlardır. Balli vd [3] çalışmalarında Hongkong havaalanı için yolcu ve kargo tahmini ARIMA modeli ile yapmışlardır. Benzer dinamik fiyatlandırma ve envanter yönetimi gibi gelir yönetimi problemleri kapsamında yolcu tahmini için duyarlı modelleme ihtiyacını vurgulayan çalışmalar sık görülmektedir.

Sa [4] gelir yönetimi tahminini regresyon modelini ARIMA modeli ile karşılaştırarak geliştirmiştir. Weatherfords vd [5] havayolu envanter yönetimi doğrultusunda yapay sinir ağları ile rezervasyon tahminlemesi yapmıştır. Ostaijen ve arkadaşları [6] rezervasyon tahmini çalışmasında markov modelinin toplamsal klasik yöntemden daha güvenilir olduğunu göstererek uçuş rezervasyonlarının dağılımını ve belirsizliği hakkında bilgi sağlamaya çalışmışlardır. Zenkert [7] no show (biletli yanmış yolcu) tahmini doğrultusunda yapay sinir ağları ve karar ağacı gibi farklı tahmin yöntemlerine başvurmuştur.

Zaman serisi tahmini modelleri üzerinde Bekin [8] Türkiye pazarı için bazı gıda ürünlerinin fiyatlarını zaman serisi modeli ve yapay sinir ağları modellerini karşılaştırarak tahmin etmiştir. ARIMA ve yapay sinir ağları modellerinin birbirine yakın sonuçlar verdiğini gözlemiştir. Hibrit modeller kapsamında Erturan [9] verilerin doğrusal ve doğrusal olmayan bileşenleri dikkate alan optimize edilmiş

ARIMA ve yapay sinir ağların hibrit modelleme ile finansal parametreler öngörerek hibrit modellerin başarısını öne sürmüştür.

Durdu [10] su kalitesi problemine ait zaman serisi analizi ve tahmininde aynı hibrit modeli kullanarak daha güvenli bir model elde ettiğini açıklamıştır.

Çizelge 1.1. Litratürde geçen havayolu sektöründe bazı tahmin modelleri.

No	Yazar	Yöntem	Açıklama
1	A.V. Duncanson	Üstel Düzleştirme	Kısa Vadeli Havayolu Trafik Sayısı Tahmini Yapılmıştır.
2	J. Sa	ARIMA	Rezervasyon Tahmini
3	L.R.Weatherfords	Neural Networks	Gelir Tahmini İçin Yapay Sinir Ağları Modeli Geliştirilmiştir.
4	K. Littlewood	Pick-Up	Rezervasyon Günlerindeki Artışların Dağılımı Tahmin Edilmiştir.
5	Kayla M. Monahan	ARIMA	Zaman serisi analizi ile uçak talep tahmini
6	P. Harris And G. Marucci	Regresyon (İleri Model)	Kısa Vadeli Tahmin Dış Faktör Etkisi Ve Rassal Hataları Kapsayan Modeldir.
7	M. Ben-Akiva	Regresyon modeli	Geçmiş ve güncel verileri ile birleşik rezervasyon tahmin modeli geliştirilmiştir.
8	Yavuz vd	Monte Carlo simulation	Overbooking politikası belirlemede olasılık tahmini ile kapasite üzeri rezervasyon modeli
9	Michae H. Reyes	Q-forecasting	Havayolu Gelir Yönetimi için Hibrit Tahmin

Literatürde geçen ülke veya havaalanı odaklı yolcu sayısı tahmininden ziyade bu çalışma havayolu yönetiminde talep tahmini sabit şartlar altında belli bir mevsimde

planlanmış bir yolculuğa beklenen rezervasyonları zaman serisi analizinin geleneksel ARİMA ve yapay sinir ağı ile birlikte ikisini bir arada kullanan hibrit bir model geliştirilerek belli bir uçuş için önceden atanmış kapasiteyi güncelleme kararı değerlendirilmiştir. Kısaca tahmin edilen talebe göre uçak seçimi yapılmıştır. Düşük talep beklendiği durumda tahsis edilen kapasite doluluk oranına göre esnek envanter ataması yapılmıştır. Havayollarının gelir yönetiminin temel faaliyetlerinden olan envanter ataması, karın en büyüklenmesinde önemli ve direkt bir etki göstermektedir. Verimli envanter atamaları mevcut kaynakların kullanımını en üst seviyeye yükselterek daha iyi bir gelir yönetimine yol açmaktadır.

Havayolu sektöründe yaşanan rekabet üstün fiyat tekliflerinde bulunmayı gerektirmektedir. Esnek fiyatlandırma yaparak düşük talep durumlarında cazip fiyat sunarak atanmış kapasiteyi değerlendirmektedir. Aksi durumlarda talebin kapasiteyi aşması beklendiğinde fiyat tarifesi yükseltilerek gelir ve kâr seviyeleri artırılmaktadır. Gelir yönetiminin bahsi geçen fiyatlandırması ve envanter yönetimi gelecekte beklenen talep tahminine bağlı olup, ikisine yapılabilecek düzenlemelere yön vermektedir. Bu çalışmada beklenen talep öngörüsü için rezervasyon verilerinin kullanılması önerilmektedir. Farklı tahmin modelleri geliştirilerek belli bir seferin uçuş gününde beklenen kümülatif talebi hem kargo hem de yolcu bakımından hesaplanmıştır. Ele alınan güzergah için gerçekleşmiş talep miktarının beklenen tahmin rakamlarına göre doluluk oranı parametresini kullanarak kapasite değiştirme kararı sonuçlandırılmıştır.

İlerleyen bölümde havayolu endüstrisi ile ilgili literatür taraması yapılmıştır. Havayolu gelir yönetimi mahiyeti ve amaçlarına değinilmiştir. Gelir yönetiminin kapsamında yer alan fiyat, talep ve kâr gibi esas fonksiyonların birbiriyle ilişkisini ve gelir yönetiminin temeli oluşturan kâr maksimizasyonu ve envanter yönetiminin talep ve rezervasyon tahmini ile bağlantısı ele alınmıştır.

BÖLÜM 2

LİTERATÜR TARAMASI

Havayolu şirketleri, beklentileri gittikçe yükselen müşterilere rekabetçi tekliflerde bulunmak için gelişmiş karar verme araçlarına diğer sektörlere kıyasla daha çok gereksinim duyar, dolayısıyla fiyatlandırma ve gelir yönetimi gelişmiş endüstrilere örnek olarak gösterilir. Havayolları gelecekteki talebin tahmin edilmesi, envanter yönetimi ve rakip şirketlerin piyasadaki fiyatlarının takip edilerek bu fiyatlara karşılık verilmesi amacıyla sofistike sistemlerin geliştirilmesi için büyük yatırımlar gerçekleştirir. Bu yatırımlar rekabet avantajı ve daha yüksek verim arayışı konusunda havayolu şirketlerine oldukça katkı sağlar.

Gelir yönetimi genel anlam ile endüstrilerin doğru envanter birimini doğru müşteri tipine doğru zamanda ve doğru fiyata satmasına çalışan bir yöntemdir [11]. Geliri en üst düzeye çıkarmak hedefi ile dinamik fiyatlandırma ve kapasite kontrolünde gelir yönetimi teknikleri uygulanır. Geleneksel kapasite kontrol teknikleri, havayollarının müşterilere yalnızca belirli uçuşlar yani kalkış ve varış tarih ve saatleri sabit olan uçuşlar ile kısıtlı iken gelir yönetimi bir yolcunun uçuş saatini bilet rezervasyonu sırasında değil, daha sonra öğreneceği esnek ürünler de sunabilir.

Farklı bir deyiş ile gelir yönetimi, müşterilerin yapabileceği maksimum ödemedeki potansiyel varyasyonlarından hareket ile rezervasyon fiyatlarını güncel tutmaktır. Tüm müşteriler belli bir ürüne aynı değeri verip benzer satın alma davranışı sergiliyorsa, varyasyonlardan yararlanma potansiyeli daha az olacaktır. Dolayısıyla, gelir yönetimi herhangi bir alanda uygulanabilirliği için müşteri kitlesinde heterojenlik olması gerekir. Havayolu ve otelcilik sektörlerinde bu özellik bulunmaktadır, müşterilerin hizmete ne zaman ihtiyacı olacağı ve programlarının ne kadar esnek olduğuna bağlı olarak esnek fiyatlandırma söz konusudur. Gelir yönetimini uygulamak için firmanın fiyatları kontrol etme gücüne sahip olması gerekir. Ayrıca bazı sektörlerde firmalar

belirli düzenlemelerle kısıtlı kalabilir ve zaman içinde fiyatlarını deęiřtirme imkânı olmayabilir.

Havayolu gelir yönetimi, mikro pazar düzeyindeki tüketici davranışını tahmin edip envanter kullanımını optimize eden fiyat esnekliğine dayalı kârı en üst seviyeye çıkartmaya yönelik analitik süreçlerdir. Gelir yönetimi, düşük talepli uçuřlarda yolcu sayısını, yüksek talepli uçuřlarda ise bilet fiyatını artırarak gelir maksimizasyonunu amaçlar. Dolayısıyla yolculuklara tahsis edilecek envanter miktarını belirlemek için geleceęe dönük talep yoğunluğu hakkında kestirim yapmak ve beklenen rezervasyon ile ilgili olabildiğince net bilgi sağlanması etkin gelir yönetiminin olmazsa olmazıdır.

Kâr maksimizasyonu için optimum koltuk sayısı tahsisi ve ona baęlı olarak piyasa şartlarına uygun bir fiyat teklifi sunmak gerekir, bu yüzden ileriye dönük talep tahminlerinde bulunmak için daha çok güvenilir tahmin modelleri geliştirme süreci havayolu yönetiminde kritik bir yer işgal eder. Rezervasyon tahmin güvenilirliği ve gelir seviyesi doğrudan ilişkililerdir. Tahmin doğruluğunun havayolu řirketleri gelirleri üzerindeki etkisini ele alan çalışma [3] tahmin doğruluğunda %10'luk iyileşme olduęu takdirde yıllık havayolu řirketleri gelirinde %0,5 - %3'lük bir artışa yol açabildiğini göstermiştir.

2.1. GELİR YÖNETİMİNDE TAHMİN

Gelir yönetimi için rezervasyon tahmini, havayolunda yapılan çeřitli tahmin problemlerinden bir tanesidir. Talep ve rezervasyonun baęlı olduęu deęiřkenlerin karmaşıklığından dolayı gelir yönetimi için güvenilir ve yüksek doğruluęa sahip bir tahmin modeli geliřtirmek oldukça güçtür. Havayolu yönetimi dięer tahminlerden daha zor olarak kabul edilebilir. Havayolu talebi tahminleri kısa ve uzun vadeli olarak ikiye ayrılmaktadır. Kısa vadeli olanlar genellikle kargo yükleme planlaması, ikram hazırlıkları ve uçak çizelgelemesi gibi taktik operasyonel kararları desteklemek için yapılmaktadır [12]. Uzun vadeli tahminler ise rota planlaması, altyapı geliştirme ve uçak ve ekipman tedariki gibi stratejik kararların alımı doğrultusunda geliştirilmektedir.

Geleneksel zaman serisi tahmin problemlerinin periyodunun aksine rezervasyon tahmin periyodu iki aşamadan oluşmaktadır. Rezervasyonun gerçekleştiği geçmiş süre ilaveten uçuş zamanına kadar kalan süreyi ele almaktadır. Bu özelliği gelir yönetimi tahminini zorlaştırmaktadır. Çoğunlukla gelir yönetimi bağlamında amaçlanan tahmin uçuş kalkışından önceki kalan günler boyunca beklenen rezervasyon öngörüsüdür. Tahmin gününden uçuş gününe kadar olan zaman aralığına tahmin ufku (horizon) denir. Doğal olarak yapılan her tahmin problemine ait bir tahmin ufku vardır. Tahmin periyodu ufkun tahminin yapıldığı belli bir dilimini göstermektedir. Rezervasyonların tahmin gününe kadar gerçekleştiği zaman dilimi rezervasyon aralığı olarak adlandırılır.

Havayolu rezervasyon süreci, talebi etkileyen birbiriyle ilişkili bir takım değişkenlerin bir sonucu olarak yüksek bir karmaşıklığa sahiptir. Talep tahminini etkileyen her faktör tahmin modelinin geliştirilmesinde ayrı bir zorluk oluşturmaktadır. Talebi olabildiğince doğru tahmin etmek adına mevsimsellik, fiyatlandırma, grup rezervasyonları, no show ve iptaller gibi gerçek rezervasyon sayılarını etkileyen faktörlerin tahmin modelinde dikkate alınması gerekmektedir. İdeal bir tahmin modelinin tüm bu dinamik yönleri yansıtması beklenir fakat modelin artan karmaşıklığı, aşırı hesaplama süresi ve bu yönleri yakalamak için gereken veri miktarı nedeniyle böyle ideal bir model geliştirilmesi pratik olarak imkansızdır.

2.2. ENVANTER YÖNETİMİ

Bir havayolu, hizmet vereceği rotalara karar verdikten sonra, gelir yönetiminin bir sonraki önemli adımını mevcut filo kapasitelerini verimli bir şekilde atamasıdır. Bir havayolunun filusunda farklı tipte uçaklar olduğu göz önüne alındığında, her bir rotada hangi tip uçakların uçacağına karar vermelidir. Her uçak tipinin bir seyir hızı, maksimum menzili, çeşitli oturma konfigürasyonu, motorlardan gelen gürültü seviyeleri ve gereken minimum pist uzunluğu gibi konfor ve teknik karakteristikleri vardır [13].

Yolculuğun süresi, kalkış ve varış havalimanlarındaki pist uzunluğu bir uçağın belirli bir yolculuğa atama kısıtı olarak değerlendirilebilir. Uçaktaki koltuk konfigürasyonu

veya koltuk sayısı, havayolu kâr maksimizasyonu hedefleri için çok önemlidir. Uçak kapasitesi, belirli bir uçuşa kaç yolcunun binebileceğini doğrudan belirlediği için uçuştan elde edilen potansiyel gelirlere bir üst sınır oluşturur. Ayrıca, belirli bir uçuşta kullanılan uçak tipi, uçuş işletme maliyetine büyük ölçüde tesir eder [13].

Çizelge 2.1. Bilinen bazı uçak kapasiteleri.

Uçak	Yolcu kapasitesi
Airbus A333-300	440
A340-500	372
A350-900	350
Boeing 777-200	400
A340-600	380
Boeing 777-300	550
Boeing 747-400	416
Boeing 747-8	700
Airbus A380-800	853

2.2. KÂR MAKSİMİZASYONU


Havayolları, diğer tüm endüstriler gibi vizyonu ışığında stratejik hedeflerine ulaşmaya çalışmaktadır. Dolayısı ile pazarda iyi bir konuma haiz olup gerektiği rekabet gücüne sahip olmak için devamlılığını korumalıdır. Geleneksel uzun vadeli maliyetleri en aza indirmek için iş sözleşmelerinin yürürlüğe girmesi, yakıt tasarruflu, uçak satın alma kararları ve işgücü kullanımını optimum noktaya getirmeye çalışmalıdır [14]. Fakat son zamanlarda, havayolları, her uçuşta hangi uçağın çalışacağı, ne kadar ücret alınacağı, uçuşun her sınıfına kaç yer ayrılacağı gibi etkisi daha kısa vadeli maliyetler ile ilgilenmeye başlamıştır.

Talep eğrisi, doğası gereği stokastik özelliğe sahip olduğundan, havayolu işletmeleri sık olarak kısa vadedeki beklenen toplam kârı maksimize etmeyi göz önüne alır. İlk olarak, toplam beklenen gelir fonksiyonu her sınıfın bilet ücreti, tahsis edilen koltuk sayısı ile birlikte söz konusu koltukların satış olasılık dağılımından oluşur.

Diyelim ki d tarihinde hareket eden c sınıfındaki f uçuşu için fiyat tarifesi F_{cfd} olsun f uçuşuna tahsis edilen yer miktarı CAP_{cfd} olmalıdır, q koltuk satma olasılığı $P_{cfd}(q)$ olur. Havayolunun beklenen toplam geliri, ödenen ücretler ile satılan beklenen alan sayısının çarpımı olduğuna göre yıllık tüm uçuşlardan toplam beklenen gelir TBG:

$$TBG = \sum_{c=1}^c \sum_{f=1}^f \sum_{d=1}^d (F_{cfd} * \sum_q^{CAP_{cfd}} P_{cfd}(q) * q) \quad (2.1)$$

Havayolu gelir yönetiminde kâr maksimizasyonu sürecini iki ana kısıt ile karşılayabiliriz. Birincisi uçuş kapasitesidir, d tarihinde hareket eden a uçuşlarındaki f uçaklarının toplam izin verilen kapasitesi ile sınırlıdır, $tcap_{afd}$. İkinci kısıt ise her uçuşun ayrı talep karakteristikleri ve olasılıkları olmasıdır [15]. Öyle ki bir havayolu şirketi, belirli bir uçuş için ne kadar talep alınacağını asla kesin olarak bilemez. Dolayısıyla farklı ücretlerde satılacak en uygun koltuk sayısını saptamak için talebin belirli bir olasılık dağılımı varsayılmalıdır. Şekil 2.1, toplam yolcu sayısına göre gelir, maliyet, kâr ve bilet ücreti arasındaki ilişkileri göstermektedir.



Şekil 2.1. Uçak bileti, gelir, maliyet ve kâr arasındaki doğrusal olmayan ilişki [16].

BÖLÜM 3

HAVAYOLU REZERVASYON TAHMİNİ

Bugünün iş süreçleri, dünün planına ve yarının beklentilerine dayanmaktadır. Bu nedenle, havayolu tahmini, gelecekte oluşabilecek talebi ölçmeye çalışır. Yolcu beklentilerine dayalı olarak tutar veya koltuk sayısı şeklinde gelir tahmini yapılmaktadır. Tahmin, bir plan değildir, ancak yönetim, tahmini gelecekteki iş planlaması için bir araç olarak kullanır. Bu nedenle tahmin, geçmiş periyotların talebi ve bir gelecek dönemin olası talebine göre yapılmaktadır. Talep ve gelir tahmini, havayolu gelir yönetimi uzmanlarının temel rollerinden biridir. Fiyat gelir yöneticileri teklifi yaparken, tur operatörlerinin talep ettiği tarihlerde belirli güzergah için koltuk tahsislerini oluşturur ve fiyat teklifinde bulunur.

Tahmin analizi bir havayolu şirketi eğilimlerine göre bir dönemden diğerine ve bir rotadan başkasına değişebilir. Üstelik her firma hizmet verdiği uçak tiplerine ve hizmet kalitesine göre kendi tahmin analizi seçimini yapar [17]. Bununla birlikte, mevsimsellik, resmi tatiller, ekonomik dalgalanmalar, siyasi konular ve rekabet şartları gibi kontrolsüz faktörler, analizin sonucunu sürekli olarak etkileyip günlük tahminlerini değiştirmeye yol açar. Rezervasyon tahmin modeli, koltuk envanter kontrolünde ve dolayısıyla gelir yönetimi sürecinde merkezi bir rol oynar. Teorik olarak %100 doğru bir tahmin, maksimum gelir rakamına ulaşmayı sağlamaktadır. Benzer şekilde tahmin doğruluğu düştükçe ulaşılabilir maksimum gelirden bir sapma olacaktır. Tahmin doğruluğu ve havayolu gelirleri üzerindeki etkisi üzerine yapılan çalışmalar, tahmin doğruluğunda %10'luk bir iyileşmenin yıllık yolcu gelirinde %0,5 ila %3'lük bir artışa yol açabileceğini göstermiştir [3].

Bir gelir yönetimi tahmini kalitesi havayolu için son derece önemlidir. Ancak, gelir yönetimi tahmini fiyat indirimleri, özel etkinlikler, yolcuların iptal edilmiş veya gecikme gibi birçok faktörden etkilenen rezervasyon sürecinin dinamikleri ve

karmaşıklıđından kaynaklanmaktadır. Sonu olarak, tek bir deęer olarak ifade edilen gelecekteki talep tahmininin oęunlukla sađlıklı olması beklenmemektedir.

Doęru bir model geliřtirmek iin sadece gerekleřmiř deęerlere yaklařık gelecek talebi tahmin etmek ile kısıtlı kalmayıp aynı zamanda rezervasyonların dađılımlı da ele alınmalıdır [18]. Bylece gelecekteki rezervasyonların dađılımlı hakkında ek bilgi sađlar ve en nemlisi, fiyatlandırma, koltuk tahsisi ve rezervasyon limitlerinin stokastik optimizasyonunu desteklemektedir.

te yandan frekans, kapasite, mevcut cretler veya kalkıř saatleri gibi arz kořullarındaki deęiřikliklere talebin tepkisini tahmin etmeye de ihtiya vardır. Havayolunun kendisi veya rakipleri tarafından arz kořullarında zerinde deęiřiklikler yapabilmektedir. Her halkrda, bir havayolu, talebin farklı deęiřikliklerin etkisi altında nasıl bir tepkisi olacađını tahmin edebilecek bir konumda olmalıdır. Benzer Őekilde bir havayolu, yeni bir rota zerinde faaliyet deęerlendirirken hedeflenen rota iin talep tahmini yapması gerekmektedir. zelikle daha nce havayolu hizmeti almamıř rotaların tahmini olduka zordur ve yksek hata riski gsterebilmektedir.

Havayolu sektrnde yapılan nemli tahminlerden detaylı veya ayrıřtırılmıř olarak bilinen tahmin modelleridir. Belirli bir uuřtaki yolcu trafięi, hem seyahat amacı hem de hizmet gereksinimleri ile ilgili farklı pazar sınıflandırmaları ile oluřturulmaktadır. Ayrıca her pazar farklı talep esnekliklerine ve byme oranlarına sahip olduđundan eřitli kriterlere gre kategorize edilebilmektedir [4]. Sonu olarak, toplam trafięi tahmin etmek yerine, her bir pazar segmentinin tahminlerini bir araya getirerek daha doęru tahminlerin elde edilmesi amalanmaktadır. Bazı havayolları halihazırda, iřletme ve iřletme dıřı olmak zere tahmin iin iki pazar segmenti yaklařımını uygulamakta veya cret sınıflarına dayalı olarak daha fazla segment tasarlamaktadır.

3.1. BİREYSEL VE GRUP REZERVASYONU

Gelir ynetimi sisteminde bireysel ve grup rezervasyonları ayrı deęerlendirilmektedir. Grup rezervasyonları, oęunlukla havayolları tarafından iyi bilinen tur operatrleri tarafından yapılan rezervasyonlardır. Grup rezervasyonlarının toplam net

rezervasyonlar üzerinde önemli bir etkisi olabilmektedir. Genel olarak rezervasyon süreci başından itibaren grup rezervasyonları yapılmaktadır. Bunun sebebi grup rezervasyonlarının yüksek iptal oranına sahip olmasıdır. Rezervasyon verilerinde grup rezervasyonlarının bu özelliğinden hareketle grup rezervasyonları bireysel rezervasyonlar verisinden ayrı olarak ele alındığında daha yüksek performanslı bir tahmin modeli elde edilmektedir.

Grup rezervasyonları bireysel rezervasyonlardan farklı şekilde oluşturulur. Bireysel müşteri online başlangıç fiyatı alabilir, seyahat tarihini veya rotasını istediği zaman değiştirebilir üstelik ödeme iadesi talep edebilir. Grup rezervasyonları için havayolu, kabul edilen seviyede koltuk sayısı için kesinleştirilmemiş rezervasyon sağlar. Bu nedenle, havayolu katı ödeme koşulları ile indirilmiş fiyat teklifinde bulunabilir. Grup ve bireysel rezervasyonları arasındaki temel fark, bireysel rezervasyonlarda, yolcu rezervasyon anında veya birkaç gün içinde satın alması gerekmesidir [19]. Ancak grup rezervasyonlarında tur operatörleri neredeyse bir yıl önce rezervasyon yaparlar ve kalkıştan 24 saat öncesine kadar bilet bilgilerini değiştirebilirler. Grup rezervasyonu, bir uçuş online görüldükten hemen sonra istenen sayıda yer tahsisi yapılması anlamına gelir.

Acenteler, rezervasyonu erken yaptıkça sık talep gören uçuş planlarında bile daha iyi bir fiyat ile makul sayıda koltuk rezerve edebilir. Çoğu havayollarında grup rezervasyonu doğrudan yapılan bireysel rezervasyonlar gibi çevrimiçi ortamda yapılmamaktadır. İlk başta yolcu sayısı, varış yeri ve tarihi bilgilerini kapsayan taleplerini gönderip havayolunun yanıtını bekler. Grup rezervasyonu, grubun uçak kapasitesini aşmadığı sürece gruptaki tüm yolcuların birlikte seyahat edeceğini garanti eder. Grup rezervasyonu her zaman daha uygun fiyatlı olmayabilir, ancak fiyat bir kez kesinleştirdikten sonra rezervasyon tarihinden uçuş gününe kadar sabit kalır [20].

Örneğin diyelim ki bugün 11 ay sonraki uçuş için bireysel bilet fiyatı x 'tir. Havayolları uçuş günü yaklaştıkça o koltuğu en az $3x$ kadar satabilecektir, bu nedenle 20 kişilik bir grup $2x$ değerinde bir fiyat alacak. Bugünün güncel fiyatı, gelecek beklentisi değerlendirilmesine dayalıdır. Ancak 50 koltuklu bir grup, o uçağın toplam koltuklarının doluluk oranı nedeniyle $3x$ kadar olabilir. Grup rezervasyonlarında,

grubun yolcu isimlerini hemen vermesi gerekmez, sadece bilet kesmeden önce vermesi gerekir. Bu nedenle, grup organizatörleri ilk olarak tahmini koltuk sayısını kalkıştan aylar önce bloke edebilir.

3.2. MÜŞTERİ DAVRANIŞI

Havayolu sektörü hizmete dayalı bir sektördür. Günümüzün rekabete dayalı piyasasında mevcut müşterileri elde tutmak ve yeni müşteriler kazanmak, havayollarının en büyük endişelerinden biridir. Dolayısıyla verilen hizmet çeşitliliğini arttırmak ve üstün katma değer sağlamak zorundadır. Bir müşterinin herhangi bir havayolu hizmeti satın alma kararı, büyük ölçüde muhtemel müşteri davranışsal niyetlerine bağlıdır. Bu bağlamda genellikle grup rezervasyonlarının planlanan uçuş saatinden aylar önce yapılmış olması nedeniyle, pazar rekabeti, aynı tur için müşterilerin önüne serdiği farklı havayolu alternatiflerden seçme kararı verilen hizmet kalitesine bağlıdır. Tekrarlayan müşteriler için ise geçmiş deneyimler, gelecekteki satın alma kararında önemli bir motivasyon unsuru olarak değerlendirilir.

Mevcut müşterilerin bağlanması başarılı olabilmek üzere, havayolu işletmeleri tarafından, sunduğu hizmet kalitesini belirleyen gelecekte olası tekrar hizmet satın alımları ve müşteri davranışları hesaba katılmalıdır. Ayrıca yolcu demografisi ve analizi, havayolu şirketinin faaliyet gösterdiği pazarı ve hedef aldığı müşteri kitlesini anlamaya olanak sağlar. Havayolları, mevcut ve potansiyel müşterileri hakkında bilgi edinmek için pazar araştırması yaparken temel amacı, müşteri ihtiyaçları ile değişen talepleri geliştiği anda ve mümkünse gelişmeden önce müşteri beklentilerini karşılayacak hizmet ve ürünlerini tasarlamaktır. O yüzden, havayolları, müşterinin kim olduğu, onlarla neden uçtuğu, yaş grubu, cinsiyeti, sosyal statüsü, geliri gibi bilgileri elde edip analiz etmelidir [13].

Üstelik, farklı varış noktalarında olabilecek herhangi bir trend, festival veya yaklaşan herhangi bir aktivite olup olmadığı hakkında bilgi sahibi olmalıdır. Bu tarz yolcu destinasyon analizi verilen hizmeti kişiselleştirmeye yarayan bilgileri sağlar ve uyumlu ürün tasarımında yardımcı olur. Öte yandan bir havayolu, yolcuların aktarmalı ve aktarmasız rota seçeneklerini nasıl ve neden tercih ettiğini öğrenmesi gerekir. Çünkü

yolcular fiyata, uçuş ve transit süresine ve uçuş sıklığına bağlı olarak rota seçerler. Bilet ücreti ve uçuş süresi, uçuş seçiminde temel unsurlardır [21].

İnsanlar, kendi tutumları, sosyal yaşam tarzı ve destinasyon çekiciliğinden kaynaklanan farklı nedenlerle bir destinasyona yönelebilir. Destinasyon seçimi üzerindeki davranışsal faktörler genellikle yolculuğun zamanına bağlı olarak değişkenlik gösterebilir. Destinasyon noktası hava durumu ve yolculuk vaktindeki hava şartları varış yeri seçiminde duygusal bir rolü vardır. Son olarak, insanlar güvenlik ve siyasi istikrar bahsi geçen tüm faktörlerden daha önemlidir. Müşterilerin davranışçı yaklaşımı, bir destinasyon hakkında karar vermeden önce bazı seçenekleri ortadan kaldırır. Destinasyon, kişinin içsel ve dışsal davranışsal faktörleri açısından uygunsa, diğer faktörleri etkileyip müşteri kararını kesinleştirir.

3.3. HAVAYOLU REZERVASYONU GELİŞİMİ

Havayolu endüstrisi ikinci dünya savaşından sonra hava hızlı bir büyüme göstermiştir. Bu nedenle, havayolu çalışanları ve yöneticileri için fazla ve düşük rezervasyon seviyelerinden dolayı rezervasyon yönetimi süreci zorlu çabalara neden olmuştur. O sırada Amerikan Airlines başkanı ve IBM'in kıdemli bir satış yetkilisi, bir gün kendi bireysel seyahatlerinde birlikte uçarken bir araya geldi ve uçuş rezervasyonlarını işlemek ve yönetmek için otomatik bir sistem önerdiler. Görüşmelerinin ardından bu iki şirket, Yolcu Adı Kaydı (PNR) sistemi oluşturma fikriyle havayolu endüstrisi tarihinde önemli bir ilerleme kaydettiler.

Sonrasında 1960 yılında, iki IBM 7090 bilgisayarına American airlines tarafından (Sabre) adlandırılan tam işlevsel yarı otomatik iş araştırma ortamı kurulmuştur. 60'lı yıllarda diğer havayolları da kendi sistemlerini geliştirdiler, sonrasında Müşteri Rezervasyon Sisteminin (CRS) geliştirilmesi ile ileri rezervasyon sistemlerinin verimliliği artış göstermiştir. Sabre, havayolu rezervasyon sistemlerine öncülük ederek, CRS teknolojisi günümüzün Küresel Dağıtım Sistemine (GDS) yol açmıştır [22].

Bugün Amadeus, Travelport ve Sabre olmak üzere dünyada üç büyük GDS vardır. 400'den fazla havayolu, ürünlerini çevrimiçi satış kanallarında bir araya getiren GDS'ler üzerinden çalışmaktadır. Bununla birlikte, Resmi Havayolu Rehberi (OAG), havayolu tarifeleri, kargo ve havacılık analitiği hakkında veri sağlayan bir hava yolculuğu referansı (ATPCO) Havayolu Tarife Yayıncılık Şirketlerine bağlı olarak ortaya çıkmıştır. (Altexsoft 2019.) Aşağıdaki şekil, bir seyahat acentesinin bireysel uçuş, tarife ve fiyat taleplerine yönelik sonuçlar üretmek için GDS'nin üç kaynağı nasıl birleştirdiğini göstermektedir.



Şekil 3.1. Havayolu rezervasyon sistemi.

3.4. HAVAYOLU REZERVASYON SÜRECİ

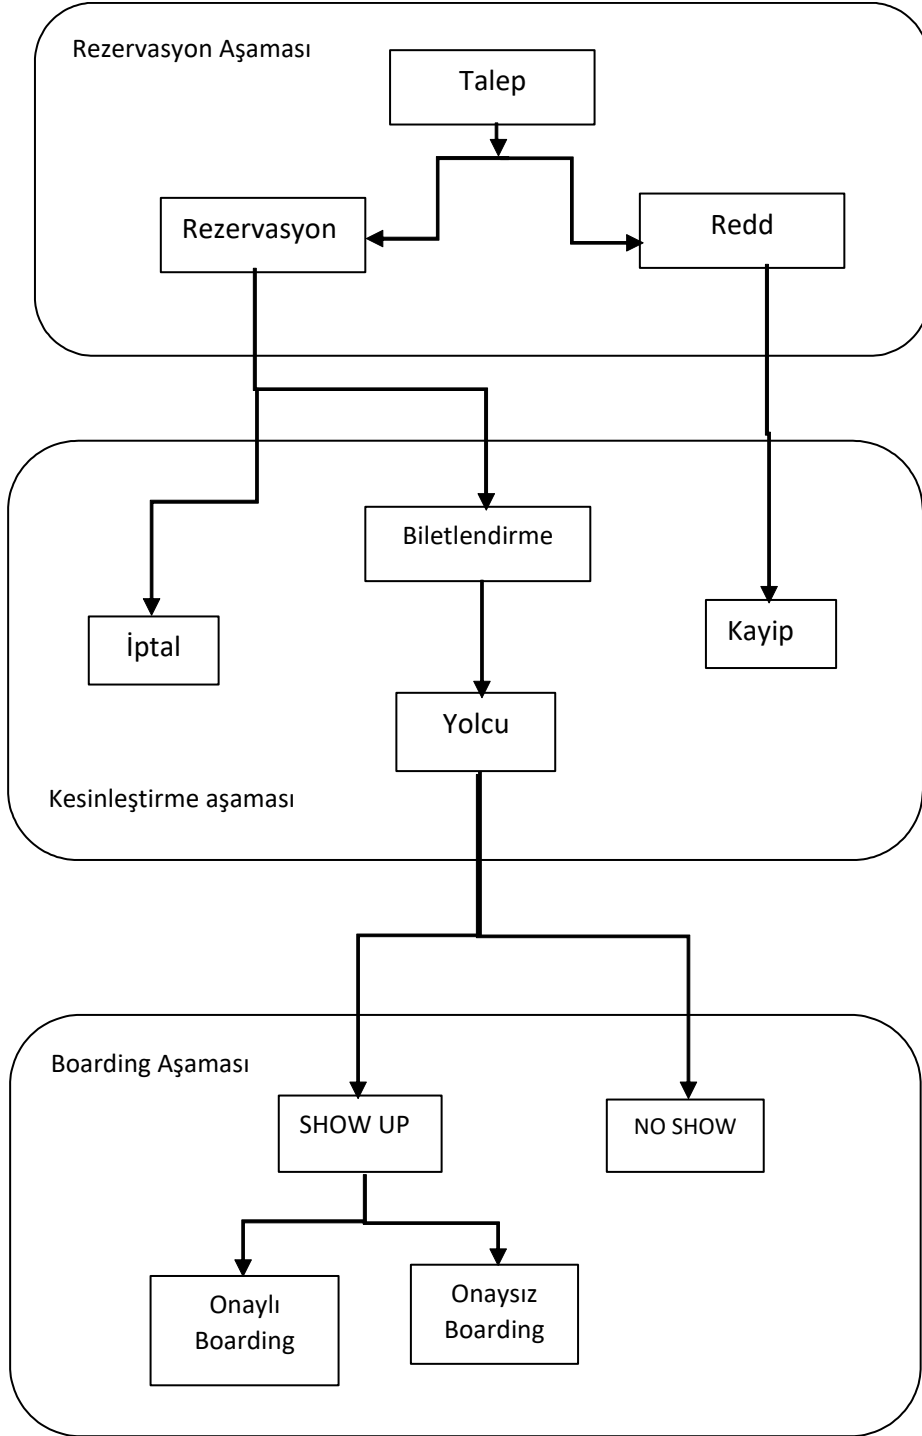
Geleneksel bir havayolu rezervasyon süreci üç aşamadan oluşur, ilk başlangıçtaki müşterinin isteğini yansıtan kalış ve varış detaylarını kapsayan rezervasyon oluşturma aşamasıdır. Sonrasında ise çeşitli neden ile muhtemel iptalin olabildiği kesinleştirme aşaması ile karşılanmaktadır. Son olarak müşterinin havaalanına gelmek ile yolcu niteliği aldığı (check in) uçağa binme aşamasıdır. Rezervasyon aşamasında olası yolcu bir satın alma kararı ile istediği rota için olabilecek havayollarını karşılaştırarak tercih ettiği firmaya bilet talebinde bulunur ve havayolu bu talebi karşılamaya çalışır. İptal aşamasında belli şartlar altında uçuştan önceki süre içinde iptal edilebilir. Rezervasyon işleminin son kısmı, uçuş günü havalimanında gerçekleşen uçağa binme aşamasıdır. Havayolları tüketiciye bir hizmet pazarlar, belirli bir zamanda A noktasından B

noktasına uçması planlanan bir uçak ile havayolu ulaşım hizmeti sağlamaktadır. Bu hizmet yemek, içecek ve eğlence gibi ilaveler ile lüksleştirilebilir.

Ürün envanteri, ilgili havayollarının genel filo büyüklüğü ve her uçağın kapasitesi ile sınırlıdır. Bununla birlikte hizmet, satın alma koşulları ve hizmet olanakları bazında farklı seviyelerde fiyatlandırılabilir ve sonuç olarak farklı hizmet seçenekleri olarak pazarlanabilir. Ayrıca, satılmayan ürün veya rezerve olmayan koltuk, kalkış tarihi yaklaştıkça planlanan kalkıştan hemen önce maksimuma ulaşır, çünkü bu son dakikada rezervasyon yapan yolcuların çoğu, uçuşta koltuk almak için normal ücretten fazlasını ödemeye hazırdır. Uçuşun kalkış tarihinden önce satılmayan koltuk değerini kaybeder. Bu riski en aza indirmek için havayolları artan talebi teşvik etmeyi amaçlayan fiyatlandırma ve pazarlama planlarına büyük yatırım yapar. Rezervasyon aşamasında, hizmet talebi havayolunun rezervasyon sistemine girer.

Bir talep, genellikle, belirli bir tarihte bir başlangıç şehir ile bir hedef şehir arasında hava yolculuğu hizmetleri için bir seyahat acentesine veya havayolu rezervasyon acentesine yapılan çağrı şeklini alır. Talep kabul edildikten sonra rezervasyon yapılır ve verilen uçuş ve ücret sınıfındaki müsait yerlerin envanteri azaltılır. Belli bir uçağın boşluk oranı ve satılabilir koltuk sayısı arasındaki farkı, havayolu şirketinin aşırı rezervasyon (overbooking) yapmasından anlaşılmaktadır. Havayolu rezervasyonu olan bazı yolcuların hareket günü gelmeyeceği beklentisi ile tahsis edilen uçağın fiziksel koltuk sayısından daha fazla yer ayırıp satabilmektedir [14].

Kesinleştirme aşaması, rezervasyon sonrasında başlar ve biniş noktasına kadar devam eder. Bu aşamada açık veya örtülü olarak devam eden iptal riski vardır. Yolcunun bir rezervasyonu iptal etmesi veya başka bir sınıfa veya başka bir uçuşa yeniden rezervasyon yapması durumunda açık bir iptal gerçekleşmektedir. Yolcunun kısıtlamalara uymaması nedeni gibi çeşitli sebepler ile rezervasyon iptali havayolu tarafından yapıldığında örtük iptal adlandırılmaktadır. Rezervasyon iptali ve sebepleri üzerinde çeşitli çalışmalar vardır. Farklı yöntemler ile beklenen iptal tahminleri yapılmış bulunmaktadır. Bu çalışma kapsamında geliştirilen modellerin verilerinde yalnız kesinleştirilmiş rezervasyon dahil edilmiştir.



Şekil 3.2. . Havayolu rezervasyon süreci.

3.4.1. Rezervasyon Aşaması

Bu aşamada potansiyel müşteri bireysel bir şekilde yada acente üzerinde gereksinimine göre istediği zaman ve rota için pazar araştırması yapar. Muhtemel alternatifleri geliştirir ve kendi belirlediği bir anahtar kritere göre değerlendirme yapar sonunda istediği yolculuğa en uygun havayolu seçimini yapar ve rezervasyonu oluşturur. Rezervasyon yaparken gidiş ve dönüş hizmeti sağlanabildiği için talepler genellikle potansiyel bir yolcu tarafından istenen hareket tarihinden günler ve haftalar önce yapılabildiği gibi uçuş gününde havaalanında rezervasyon yapılabilir [20]. Uçuş kalkış gününde havalimanına gelen ve belli bir yolculuk için son dakikada rezervasyon yapabilen yolcu go-show yolcusu olarak bilinir. İsteddiği uçuş ve ücrette yer varsa rezervasyon yapılır. Bu yüzden havayolu şirketleri, rezervasyonu olan bazı yolcular kalkış gününde gelip biletlerinden faydalanmayabileceğini göz önüne alır ve fiili fiziksel koltuk sayısından daha fazla rezervasyon açabilir. Dolayısıyla bir uçak için satılabilecek rezervasyon sayısı ve uçağın fiziksel kapasitesi arasındaki farkı anlamak önemlidir.

3.4.2. İptal Aşaması

Havayolu şirketleri, gelir yönetimi tahmini yaparken rezervasyon yapıldıktan sonra olası iptal durumlarını göz önünde bulundurması gerekmektedir. Gelecekte olabilecek iptaller hakkında bir fikir sahibi olmak, gereken hazırlıkları yerine getirmeye yardımcı olarak daha başarılı bir gelir yönetimi gerçekleştirmektedir. Yolcu, uçuşun kalkmasına günler veya haftalar kala rezervasyonu iptal edebilir. Rezervasyon iptali yolculuk planındaki değişiklik nedeniyle meydana gelebildiği gibi yolcunun rezervasyon için belirtilen şart ve kısıtlamalarına uymaması nedeniyle kesin iptal durumu olabilir [23].

Grup rezervasyonu iptali ise tur operatörü tarafından önceden rezerve edilen tüm koltuklar her zaman satılmayabilir. Gereken minimum koltuk sayısı satılmazsa tüm grup rezervasyonu tamamen iptal edilebilir. Satılan koltuk sayısı gereken minimuma yakın olduğu durumlarda grup biletlerinin düzenlenmesi için sınır grup sayısı üzerinde düzenleme yapılmaktadır.

3.4.3. Boarding Aşaması

Uçak kalkış günü öncesinde rezervasyon iptal edilmemesi durumunda müşteri kalkış gününde havaalanında gerçekleşen rezervasyon sürecinde yolcu uçağa binerek üçüncü adımı tamamlar. Yolcu, kalkış gününde havalimanına belirlenen minimum süreden önce show up yapar ve check in işlemini gerçekleştirir. Uçakta yeterli müsait koltuk olması durumunda yolcunun uçağa binmesine izin verilir. Böylece müşteri planlanan uçuş ve belirlenen zaman ve tarife ile yolculuk yapar. Öte yandan, uçuşa fazladan rezervasyon yapıldığı için uçağın kapasitesinden daha fazla yolcu gelmesi ile aşırı satış durumu (oversold) olabilir [24]. Bu durumda, bazı yolcuların uçağa girişi engellenerek boarding reddi yapılır. Boarding reddi gönüllü olduğu durumlarda yolcunun belli tazminat karşılığında yolculuktan vazgeçmesi sağlanır. Aksi takdirde, reddedilen boarding gönüllü bir şekilde gerçekleşmez ise havayolu yolcunun uçağa binmesine izin vermediğinden havayolunun politikalarına göre yolcuya tazminat verilir.

Check in işlemi havayolunun kalkış kontrol sistemi (DCS) üzerinden yürütülmektedir. Otomatik check-in kioskları, havalimanı acentelerinin yazılımı, bagaj teslimi ve kontrolü gibi CRS ve havalimanı cihazlarında birleşik olarak yönetilmektedir. DCS, biletin onaylanmasıyla başlayan tüm check-in ve uçağa biniş prosedürlerini işler. Ayrıca bu sistem, gümrük girişleri ve sınır güvenliği rezervasyonu ile uçak ağırlık optimizasyonu ve kargo elleçleme işlemlerinden sorumludur. Yolcuların, check-in sırasında PNR adlarını vererek CRS sisteminde kayıtları ile eşleştirilmesi ve koltuklara atanması, çevrimiçi ve çevrimdışı olarak farklı şekiller ile gerçekleştirilebilmektedir [25].

Havayoluna göre değişmek ile birlikte online check-in genellikle uçuştan 48 saat önce yapılır. Yolcu, bir havayolu web sitesinde veya mobil uygulamasında bir e-biletten ayrıntıları girer ve koltuk seçimi yapar. Bir kullanıcı seçmezse, sistem rastgele ücretsiz bir tane atar ve elektronik bir biniş kartı verir. Aynı prensip check-in kioskları için de geçerlidir. Havaalanında geleneksel check-in işleminde ise yolcu check-in kontuarındaki acenteye bir bilet ibraz eder ve bilgilerin girişini sağlar.

BÖLÜM 4

ZAMAN SERİSİ ANALİZİ

Zaman serileri ardışık artışları süresince bir değişkenin değerlerinin bir kümesidir. Bu artışlar seriden seriye değişebilmektedir. Zaman serileri, eşit zaman aralıklarını temsil eden gözlem değerlerinden oluşur. Zaman serileri, saatlik, günlük, haftalık, aylık, çeyrek ve yıllık oluşturulabilmektedir [26]. Gözlem değerleri derlemesindeki yaklaşım, zaman değişkenini türüne göre adlandırılmasıdır. Herhangi bir t anında gözlenen veri Y_t ile temsil edilir. İstatistiksel ekonometrik modeller değişkenler arası bağımlılığı teorik bir yaklaşım ile ele almaktadır. Ancak kuramsız modeller olarak bilinen zaman serileri, geleneksel modellerden farklı olarak teorik temele gereksinim olmadan değişken motivasyonunun açıklanabilir olmasıdır.

Verinin zaman serisi özelliğine sahip olması için zaman parametresi dikkate alınarak düzenlenmiş olup periyotları aynı aralıklarla olması yeterlidir. Bu sebeple günlük satış verileri, hisse senedi getirileri, aylık enflasyon değerlerinin yanı sıra saatlik periyotlarla ölçülen sıcaklık değerleri de zaman serisi olarak değerlendirilebilir. Zaman serileri, veri değerleri birbiri ile olan ilişkisi sayesinde tahmin edilebilir serilerdir [27]. Literatürde geçmiş ortalama veya haftanın belli bir gününe göre ağırlıklı ortalamalı üstel yumuşatma metodu sıklıkla bulunur, örneğin önümüzdeki Pazartesi için rezervasyon tahminlerini hesaplamak için sadece önceki Pazartesi günlerine ait verileri kullanır. Üstel yumuşatma metodu geçmiş verilerin güçlü periyodik değişkenliği olduğu durumlarda uygundur.

Serinin ortalaması ve varyansının zaman boyunca sabit kalması ve Y_t değişkeninin gecikmeli değerleriyle kovaryansının zaman ile değişmemesi düşük durağanlıklı ya da durağan olmayan seri olarak tanımlanabilir. Dağılımın zaman içerisinde sabit kaldığında durağan seri söz konusudur [27]. Durağan olmayan seriler durağan dışı olarak da adlandırılmaktadır. ARIMA modelleri, fark alma işlemlerini uygulayarak

verilerde durağan olmama durumunu ortadan kaldırabilir. Zaman serisi modelleri ilerleyen bölümlerde detaylı bir şekilde ele alınacaktır.

4.1. ZAMAN SERİLERİ KALIPLARI

Zaman serilerinin seyrinde görülen dalgalanmalar, ekonomik, sosyal ve psikolojik etkenlerin sonucu olarak temel dört unsurdan etkilenmektedir. Söz konusu bu dalgalanmalar zaman serilerin trend, mevsimlik, konjonktürel ve düzensiz (Rassal) olmak üzere çeşitli kalıp şekillerinde olmasını sağlamaktadır [28].

4.1.1. Trend

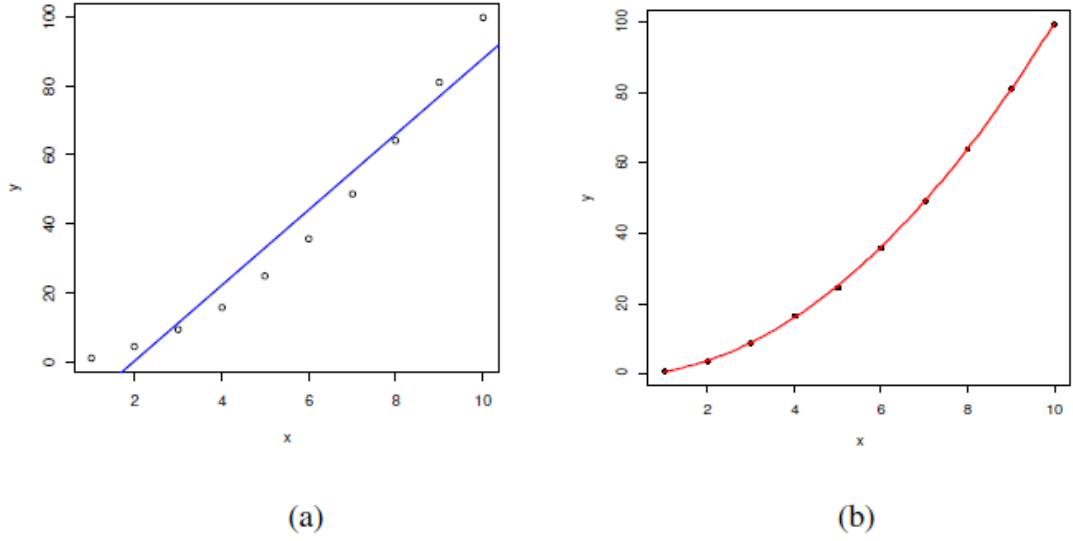
Trend, zaman serilerinde uzun vadede oluşan artış veya azalışlarda oluşan ve zaman serilerin uzun dönem eğilimini gösteren düzenli harekettir. Trend serilerin ortalama düzeyini göstererek büyüme ölçüsü olarak kullanılır. Ekonomik zaman serileri farklı şekillerde bulunabilir. Trend aşağı veya yukarı yönde olabileceği gibi dik veya daha ılımlı, üstel veya yaklaşık biçimde doğrusal olabilir. Artış veya azalışların süreklilik durumuna göre deterministik trend ve stokastik trend olarak adlandırılabilir. Deterministik Trend: Zaman serisinde sürekli artış ya da azalış olma durumunu temsil edip bağımsız değişken olarak denklemde yer almaktadır.

$$Y_t = \beta_0 + \beta_1 t + \varepsilon_t \quad (4.1)$$

Stokastik Trend: Zaman serisinde artış yada azalış sürekliliği olmama durumudur.

$$Y_t = \beta_0 + Y_{t-1} + \varepsilon_t \quad (4.2)$$

Zaman serisinin eğer deterministik trend özeliği varsa model seçiminde doğrusal eğilimin seçilmesi yeterlidir. Seri stokastik trende sahipse analiz doğruluğunu için fark alma, dönüşüm yapma gibi yöntemler ile düzeltme yapılır.



Şekil 4.1. Trend zaman serisi örnekleri.

Genel eğilim yukarı doğru olup lineer değildir. Bu veri kümesi için grafikte (a) doğrusal trendin olmadığı ve (b) eğrisel trende daha uygun olduğu kabul edilmektedir.

4.1.2. Mevsimsellik

Zaman serileri derlendiğinde dönemsel değişimler ile karşılanabilir. Serilerin değerleri bazı aylarda mevsime göre diğer aylardan daha fazla olabilir. Mevsimlerin sebep olduğu değişimler serilerde dalgalanmalar şeklinde yansıtılır ve her mevsim sabit bir döngü ile tekrarlar. Mevsimsel hareketler bu nedenle aylık veride 12, üç aylık veride 4 dalga uzunluğu boyunca süren dönemsel ve devri hareketlerdir [29]. Farklı bir deyiş ile seride birbirini izleyen dönemlerin aynı periyotlarında benzer değerler alırsa seri mevsimseldir, diğer türlü mevsimsel olmayan seri söz konusudur. Serilerin mevsimsellik durumunu değerlendirmek için yeterli sayıda gözlem bulunması gerekmektedir.

4.1.3. Konjonktürel

Konjonktürel dalgalanmalar zaman serilerinin ekonomik koşullarındaki değişimleri gösteren bileşenlerdir [30]. Sektörlerdeki daralmalar veya büyüme hızında meydana gelen değişkenliktir. Bazı dönemlerde yüksek büyüme hızları serilerde devri hareketler oluşturur. Seri değerlerinin yükselme ve alçalma yönünde gösterdiği inişli

ve çıkışlı dalgalı olan hareketlerini ifade etmektedir. Mevsimsel ve konjonktürel arasındaki fark; mevsimsel hareketler dönemlerinde düzenli ve periyodik iken, konjonktürel hareketlerde düzensiz ve periyodik olmayan bir yapıya sahiptir.

4.1.4. Rassallık

Rassal seriler sabit bir ortalama da dalgalanan kalıplar olarak bilinmektedir. Bu tür seriler ortalamaya göre durağan bir yapıya sahiptirler. Rassal serileri oluşturan verilerin belirli bir sistematik yapısı yoktur. Zaman serisindeki tahmin edilemeyen sebeplerden kaynaklanan, düzenli olmayan ve tekrar etmeyen hareketlerdir. Savaş, sel baskını, deprem, darbe gibi sosyal ve doğa olaylarının verileri rassal seriler gösterir.

4.2. ARİMA MODELLERİ

Zaman serisi analizleri, bir zaman serisinde düzensiz dalgalanmaların, neden kaynaklandığını inceleyerek seriyi bileşenlerine ayırıp gelecekte alabileceği değerleri öngörmeyi amaçlar. Verilerin aynı ölçü birimi ile ifade edilmiş olması koşulu ile zaman serisi analizi ile gelecek hakkında öngörüler yaparken gelecek dalgalanmaların serinin geçmiş hareketlerine benzer eğilim göstereceği farz edilir [31]. Kendi geçmiş değerlerinin etkisi altında kalan zaman serileri otoregresif zaman serileri olarak bilinir. Örneğin aylık enflasyon oranları, bir önceki oranından ve bir önceki senenin aynı enflasyon oranından etkilendiği için otoregresiftir. Bir otoregresif zaman serisinin geçmiş gözlem değerleri kullanarak gelecek değer tahminlerinin yapılabileceği hipotezi ile model denklemini aşağıdaki gibidir:

$$Y_t = c + \Phi_1 Y_{t-1} + \Phi_2 Y_{t-2} + \dots + \Phi_p Y_{t-p} + \varepsilon_t \quad (4.3)$$

Denkleminde c , Y_t otoregresif serinin ortalama değerini gösteren sabit terimi, Φ_1 , Φ_2 , ... Φ_p 'ler bilinmeyen otoregresif katsayıları ve ε_t ise hata terimini ifade etmektedir. Bu model bağımlı değişkenin çoklu doğrusal regresyon modeli AR(p) olarak gösterilmektedir [27]. Gecikme sayısını "p" nin değeri korelograma göre saptanır. Model 1. dereceden ise AR(1) olarak şekildeki gibi gösterilecektir:

$$Y_t = c + \theta_1 Y_{t-1} + \varepsilon_t \quad (4.4)$$

Öte yandan Y_t hatanın şimdiki ve geçmiş değerleri ağırlıklı toplamıyla bulan hareketli ortalama modelleri beyaz gürültü serisinin sonlu kümesi olduğu için genellikle durağan olarak değerlendirilir. Geriye doğru kaç hata terimi kullanıldığını belirten MA(q) ifadesi q. dereceden hareketli ortalama serisi olarak kullanılmaktadır eşitlikteki gibi gösterilmektedir.

$$Y_t = c + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_p \varepsilon_t \quad (4.5)$$

ε_t terimi korelasyon olmayan, sıfır ortalamaya ve sabit varyansa sahip rassal hata değerini temsil ederken θ_i bilinmeyen parametreleri ifade etmektedir. ε_t 'nin ağırlıklı ortalaması olan Y_t ortalama zamana bağlı olarak hareket ettiği için hareketli ortalama olarak adlandırılmaktadır. Bazı zaman serilerinin sadece AR ya da MA modelleriyle analiz edilmesi yüksek dereceden modelleme ve fazla sayıda parametre gerektirdiğinden otoregresif ve hareketli ortalama süreçlerinin birlikte kullanıldığı ARMA modelleri geliştirilmektedir. p. dereceden AR ve q. dereceden MA modelini gösteren ARMA (p, q) modeli (1.25) nolu eşitlikte gösterilmiştir [32].

$$Y_t = c + \theta_1 y_{t-1} + \dots + \theta_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_p \varepsilon_{t-p} \quad (4.6)$$

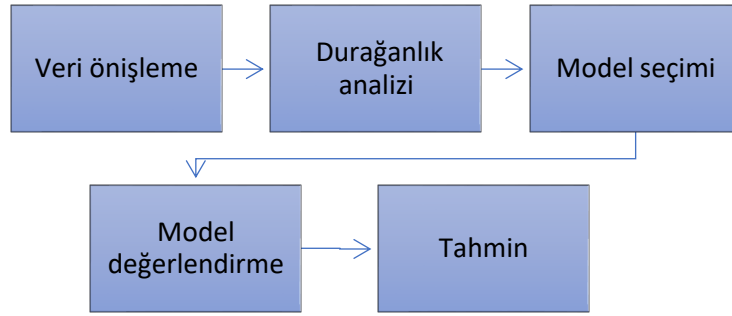
Yalnızca durağan serilere uyan ARMA modelleri, durağan olmayan serilerde kullanılması için fark alma işlemi gerçekleştirilmesi gerekmektedir. Bu durumda d terimi kaç defa fark alındığını gösterip ARIMA(p,d,q) modelleri şeklinde ifade edilmektedir. AR, MA ve ARMA modellerinin durağan zaman serilerine uygulandığı halde pratikte genellikle durağan olmayan serilere uygulanmaktadır[33].

4.2. BOX-JENKINS PROSEDÜRÜ

Tek değişkenli zaman serilerinin tahmininde kullanılan Birleştirilmiş Otoregresif Hareketli Ortalama (autoregressive Integrated Moving Average ARIMA) yöntemi uygulaması için dört adımdan oluşan yaklaşım Box ve Jenkins tarafından ortaya çıkartılmıştır. İlk olarak model seçme aşamasında başlangıç verilerin üzerinde durarak

serinin durağanlık ve mevsimsellik durumu tespit edilir. Bağımlı zaman serilerinin otokorelasyon ve kısmi otokorelasyon fonksiyonlarının grafiklerini kullanarak modelde hangi otoregresif (AR) veya hareketli ortalama (MA) bileşeninin kullanılması gerektiği belirlenmektedir.

Sonraki aşamada mevcut serinin durağanlık ve mevsimsellik durumuna göre geliştirilecek modele gereken fark alma derecesi ve diğer parametreleri tanımlanır. Son olarak tahmin modelini kullanıp tahmin değerlerini elde etmeden önce modelin doğruluk ve yeterlilik kriterleri kontrol edilmelidir.



Şekil 4.2. Box-Jenkins prosedürü.

4.3. YAPAY SİNİR AĞLARI

Yapay sinir ağları, zaman serilerinin doğrusal olmadığı durumların analizi ve tahmininde kullanılan yöntemlerden biridir. Çok çeşitli doğrusal olmayan problemleri modellemek için esnek bilişimsel sistem oluşturur. YSA'ları biyolojik sinir hücrelerinin benzetimine dayanan birden fazla fonksiyonu yüksek doğrulukla tahmin edebilen evrensel yaklaşımçılardır [34].


Verilerden gelen bilgilerin paralel işleme mantığı ile yüksek performans göstermesini sağlamaktadır. YSA modeli geleneksel analizlerin aksine modelin parametreleri deneme yolu ile belirlenebilmektedir.

4.3.1. Nöron Yapısı

Biyolojik sinir ağlarını oluşturan nöronlar arasında binlerce bağlantı ile sinyal akışı iletişimi gerçekleştirilir. Bu sinyaller hücrelerde belli bir değere geldiğinde etkinleşmektedir. Gelişen etki akson adı verilen kısmı aracılığıyla diğer nöronlara iletilmektedir. Akson hücrenin çıktı yolu ve akson dalları sinaps denen kavşaklarıyla diğer nöronların girdi yolları olan dentritlerle birleşirler. Benzer şekilde nöronlar yapay sinir ağlarının yapı taşını oluşturur. Yapay nöron modelinde nöronlar arası her bir bağlantı özel bir katsayı ile ifade edilir. J nöronundan k nöronuna giden bir sinyal için ağırlık değeri W_{jk} şeklinde gösterilir. Biyolojik nöronlardaki sinapsların engelleyici veya destekleyici rolünü ağırlık değerleri almaktadır. Ağırlık değerleri pozitif ve negatif olabilir, pozitif olanlar destekleyici iken negatif değerler engelleyici etki yapmaktadır. Girdiler bir araya gelerek aktivasyon fonksiyonundan geçer ve çıktı değerini oluşturur. Aktivasyon fonksiyonu, nöronun çıktısını kısıtlandırır ve belli bir aralıkta ifade edilmesini sağlamaktadır [35].

4.3.2. Ağları Yapısı

Üç boyutlu olduğundan biyolojik sinir ağları karmaşık bağlantılı mimariye sahiptir. Dolayısıyla yapay sinir ağlarında bağlantıların kurulumunda katmanlar kullanılmaktadır. Genellikle girdi, ara katman ve çıktı katmanı olmak üzere üçe ayrılmaktadır. Girdi katmanı hücreleri gelen veriyi işlemeden önce ara katmana iletir. Katmandaki hücre sayısı giriş değişkenlerine eşit olup her hücre veriyi sonraki katman hücrelerine göndermektedir. Girdi katmanından gelen veri işlendikten sonra çıktı katmanına ara katmandan iletilmektedir. Ara katmandaki hücrelerin ağırlıkları bilinmediği için bu katmana gizli katman adı verilmektedir. İşlenecek veriye göre ideal ara katman sayısı hücre sayısı deneme ile belirlenmektedir. Ara katman nöron sayısının az olması çıktının güvenilirliğini etkilerken fazla olması modelin ezberlemesine sebep olmaktadır. Ara katmanın ilettiği veriden işlenen çıktının dışarı aktarıldığı katman çıktı katmanı olarak bilinmektedir. Katmandaki hücre sayısı modelin değişken sayısına göre belirlenmektedir [36].




Şekil 4.3. Tek gizli katmana sahip çok katmanlı ileri beslemeli sinir ağı mimarisi.

4.3.3. Aktivasyon Fonksiyonları

Hücreye gelen girdi değerini bulmak için çarpım, maksimum, minimum çoğunluk ve kümülatif toplam işlemi ile birleştirme fonksiyonu kullanılmaktadır. Sonrasında net girdiyi işleyerek çıktı değerini sağlayan aktivasyon fonksiyonundan geçer. Ağın tüm hücreleri aynı birleştirme ve aktivasyon fonksiyonu kullanmayabilir. Hücreye uygun olan fonksiyonu belirlerken deneme yolu kullanılır.

Sigmoid fonksiyonu tek kutuplu ismiyle bilinen sigmoid fonksiyonu sık kullanılan aktivasyon fonksiyonlarından biridir. $[0,1]$ aralığında çıktı değeri üretmektedir. Bu özelliği doğrusal olmayan ilişkilerin analizinde avantaj kazandırmaktadır. Kullanılan diğer bir aktivasyon fonksiyonu hiperbolik tanjant sigmoid fonksiyonudur. Logaritmik sigmoid fonksiyonundan farkı aldığı değerlerin $[-1, 1]$ aralığında olmasıdır.



Şekil 4.4. Hiperbolik tanjant & sigmoid fonksiyonları [38].

Son olarak step (Basamak) fonksiyonu, katı sınır fonksiyonu veya eşik değer fonksiyonu olarak da bilinmektedir. Net girdi değeri eşik değerini aşma durumuna bağlı olarak “1” veya “0” çıktı değerini veren fonksiyondur.

Çizelge 4.1. Aktivasyon fonksiyonları.

FONKSİYON	NOTASYON	AÇIKLAMA
DOĞRUSAL	$linear(x)=x$	Doğrusal problemlerin modellemesinde kullanılmaktadır.
STEP (ADIM)	$F(x)=\begin{cases} 0 & x \leq a \\ 1 & x > a \end{cases}$	Eşik değere göre 0 yada 1 değerinde sonuç vermektedir.
SİGMOİD	$sigmoid(x)=\frac{1}{1+EXP(-X)}$	Aktivasyon fonksiyonlarının en kullanışlısı. 0 ila 1 aralığında değer vermektedir.
TANJANT	$tanh(x)=\frac{2}{1+e^{-2x}} - 1$	Sigmoid fonksiyonuna benzer fakat -1 ve 1 aralığında sonuç vermektedir.
EŞİK DEĞER	$F(x)=\begin{cases} 0 & x \leq 0 \\ x & 0 < x < 1 \\ 1 & x \geq 1 \end{cases}$	Toplama fonksiyonu değerine göre 0 , 1 veya arasında bir değer verir

Yapay sinir ađları hata dzeltmeli đrenme ile kendi performansını iyileřtirmektedir. Hebbçi đrenme, rekabete dayalı đrenme, Boltzmann đrenmesi ve geri yayılım algoritmasıyla đrenme olmak zere beř đrenme řekli vardır. Hata dzeltmeli đrenmede, ađda srekli olarak hata hesaplanmakta ve bunlara gre sinaptik ađrılıklar gncellenmektedir. Hebbçi đrenme, birbirine yakın iki nron arasında srekli ateřlenme olduđu durumda arasındaki bađlantıyı gçlendirecek deđiřimler ile geliřme sađlamaktadır [35].


Rekabete dayalı đrenmede nronların her biri ateřleme iin birbirleriyle yarıřmaktadır. Rekabetçi đrenmenin girdi yapısı farklı kmelere sınıflandırarak girmesi gerekmektedir, aksi takdirde birbirleriyle ilgisi olmayan girdi yapıları aynı kmelere girebilmektedir. Boltzmann makinesi olarak bilinen Boltzmann đrenmede ise nronlar, grnr ve gizili olmak zere ikiye ayrılır. Grnr nronlar ađ ile alıřtıđı evre arasında bir arayz sađlarken gizli nronlar serbest alıřırlar.

4.3.4. Sinir Ađları zellikleri

Yapay sinir ađları tanımlanan aktivasyon fonksiyonuna gre dođrusal ve dođrusal olmayan problemlerde kullanılabilirliđi diđer birok modelleme yntemine stn kılmaktadır. Genellemenin zelliđi ile eđitim srecinden gemiř yapay sinir ađlarına nceden okutulmamıř veriler iin bařarılı deđer verebilmektedir. stelik basit matematiksel fonksiyonlardan oluřan yapay sinir hcreleri, birbirleri ile olan bađlantılar ile daha zor karmařık problemlerde yksek performans gstermektedir. Sistematik yapıya sahip olması, hcrelerin birinde problem ıkması durumunda bile zm sađlanmaktadır [39]. Yapay sinir ađlarına eđitilen veri yapısı, kullanılan aktivasyon fonksiyonu ve hcre ađrılıkları ađın đrenme kabiliyetini belirlemektedir. te yandan, yapay sinir ađlarının geleneksel yntemlere gre hata toleransı esnek sayılır. nk veriler ađa dađıtılırken hata deđerleri de ađa dađıtılarak hataların sonuca etkisi dřmektedir [34].

4.3.5. Geri ve İleri Beslemeli Yapay Sinir Ağı

Yapay sinir ağlarının hücreler arası bağlantısına göre ağların ileri beslemeli ve geri beslemeli olarak sınıflandırılabilir. İleri beslemeli yapay sinir ağları, verilerin bir yönde yol alarak girdi katmanından çıktı katmanına iletildiği ağlardır. Hücreler aralarında veya bir önceki hücreler ile bağlantı kurmadığı ağlardır [40]. Geri beslemeli olanlarında ise hücrelerin önceki katman hücreleri ile bağlantısı olup verilerin hem ileri hem de geriye doğru iletildiği ağlardır.



Şekil 4.5. Geri beslemeli yapay sinir ağı yapısı [41].

BÖLÜM 5

ARIMA-YSA HİBRİT MODELİ

Zaman serisi tahmini, verinin zaman ile temel ilişkisini tanımlayan bir model geliştirmek için aynı değişkenin geçmiş gözlemlerinin analiz edildiği önemli bir tahmin alanıdır. Söz konusu bu modellerin geliştirilmesinde izlenecek çeşitli yöntemler mevcuttur. Fakat her zaman problemin karakteristiklerine göre optimum yöntemi belirlemek zordur. Dolayısıyla araştırmacılar birden fazla potansiyel yöntemi uygulayıp en iyi performansa sahip olanı seçerek tahminleri geliştirmektedir. Farklı yöntemlerin birleştirilmesiyle, model seçimi sorunu telafi edilebilmektedir. İkincisi, gerçek zaman serileri nadiren saf lineer veya nonlineer dumunu gösterir. Genellikle hem doğrusal hem de doğrusal olmayan bileşenler içerirler.

Tahminde en önemli ve yaygın olarak kullanılan zaman serisi modellerinden biri, otoregresif entegre hareketli ortalama ARIMA modelidir. Popülarlığı nedeniyle, ARIMA modeli, basit olması ve yaygın kullanımını açıklayan doğru sonuçlar vermesi nedeniyle birçok yeni modelleme yaklaşımını değerlendirmek için bir kıyaslama olarak kullanılmıştır. Birçok çalışma, Box-Jenkins'in önerdiği ARIMA modelini farklı zaman serilerini tahmin etmek için kullanmış ve Markov, rejim v GARCH Gibi farklı modellerle karşılaştırmıştır. Sonuçlar, ARIMA modelleri diğer modellere kıyasla iyi performans göstermektedir. ARIMA modelinin en büyük sınırlaması, modelin önceden varsayılan lineer formudur. Doğrusal modellerin karmaşık gerçek zaman serisi sorununa yaklaşımı her zaman tatmin edici değildir. Gerçek zaman serileri, serilerin ortalamasının ve varyansının fazla mesai ile değiştiği durumlarda oldukça doğrusal olmayan olarak kabul edilir.

Dolayısıyla yalnızca ne ARIMA ne de ANN yönteminin yeterli olması beklenmektedir. Ona göre ARIMA ile YSA modellerini birleştirerek, verilerdeki karmaşık otokorelasyon yapıları daha doğru bir şekilde modellenabilir. Farklı

modellerin bir arada kullanılması her modelin güçlü yönlerinden yararlanma imkanı sağlayarak yüksek performanslı tahmin modelleri elde etmek mümkündür.

5.1. ZHANG HİBRİT MODELİ

Zhang, zaman serisi tahmini için önerdiği ARIMA-ANN hibrit modeline göre zaman serisi verileri doğrusal ve doğrusal olmayan bileşenlerin toplamı olduğu varsayılır.

$$Y_t = L_t + N_t \quad (5.1)$$

Burada L_t lineer olanı ve N_t lineer olmayan bileşeni ifade eder. İlk olarak, verilen zaman serisi verileri ile ARIMA kullanılmış ve doğrusal tahminler elde edilmiştir. Doğrusal bileşenden kalanların yalnızca doğrusal olmayan bir ilişki içerdiği varsayılır. Bu yöntem, doğrusal bileşenden tahmin yapmak için ARIMA ve doğrusal olmayan bileşenden YSA kullanılır. Ardından, bu modeller genel tahmin performansını iyileştirmek için birleştirilir.


Öncelikle verinin bir kısmı üzerinde uygulanan ARIMA modelinden elde edilen artık değerleri serisinin kalan değerleri YSA yöntemi ile tahmin edilir. Böylece verinin artık değerlerinden yola çıkarak tahmini değerler ortaya çıkmaktadır [42]. Literatürde çeşitli hibrit yöntemler önerilmiştir. Ancak doğrusal ve doğrusal olmayan problemlerde kullanılan yöntemleri birleştirerek geliştirilmiş modeller genellikle daha başarılıdır. Verilerdeki olası kararsızlık nedeniyle, hibrit yöntemi kullanmak, istatistiksel çıkarım ve zaman serisi tahmininden gelen model belirsizliğini azaltabilir [43].

BÖLÜM 6

UYGULAMA

6.1. KULLANILAN VERİSETİ

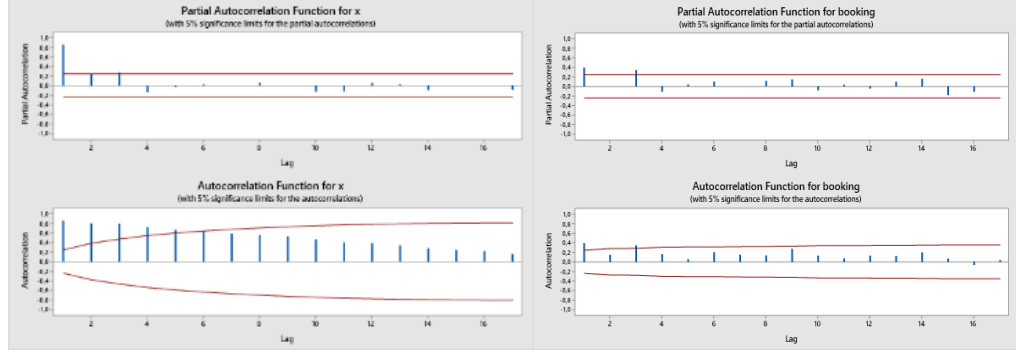
Gelir yönetimi tahmini yapılacak havayolunun belli bir uçuşuna ait rezervasyon verileri kullanılmıştır. Ortadoğu pazar dahilinde gerçekleşecek uçuş için 01.06.2020 gününden itibaren başlayan rezervasyonlar 19.04.2021 gününe kadar gözlemlenmiştir. Haftalık veri toplama notaları esas alınarak toplamda 67 gözlem derlenmiştir. Gözlemlenen haftalık rezervasyonlar şekil 6.1’de görüldüğü üzere 0 ila 10 arasında değişkenlik göstermiştir. 2020 yılı son aylarındaki pandemi kısıtlamalarından kaynaklanan düşük talep ilk altı ay gözlemlerine etkisini fark edip maksimum 5 rezervasyon ile sınırlı kalmıştır. Zaman ilerledikçe ve yolculuk şartları hafifleştikçe veriler bir trend oluşturmaya başlamıştır. Planlanmış 28.06.2021 tarihli kalkış gününe kadar beklenen rezervasyon sayılarını ARİMA, YSA ve hibrit modelleri ile tahmin edilmiştir.



Şekil 6.1. Haftalık yolcu ve kargo rezervasyon serisi.

6.2. ARİMA MODELİ UYGULAMASI

İlk olarak mevcut verinin durağanlık durumu tespit edilir. Bu yüzden ACF ve PACF grafiklerini değerlendirerek verinin durağan hale getirilmesi için fark alınması gerekip gerekmediğine karar verilmektedir. Şekil 6.2 minitab yazılımı ile kısmi otokorelasyon fonksiyonu (PACF) ve Otokorelasyon fonksiyonu (ACF) grafikleri çizdirilmiştir. PACF baktığımızda birinci gecikmeden sonra uzun süreli azalma olmadığı ve üstel düşüşlerden dolayı veride durağanlık yoktur diyebiliriz.



Şekil 6.2. Yolcu ve kargo verilerin ACF ve PACF grafikleri.

İkinci dereceden fark alma işlemi uygulandıktan sonra serimiz durağanlık durumu göstermiştir. Dolayısı ile ARİMA modelinin d parametresi 2 değerine sahip olmuştur. Otoregresyon modeli derecesini gösteren p parametresi ise kısmi otokorelasyon fonksiyonu grafiğini inceleyerek keskin düşmelerin ikinci gecikmeden sonra başladığından 2 olarak belirlenmiştir. Modelin q değeri otokorelasyon fonksiyon grafiğindeki sadece birinci gecikme aşırı değere sahip olduğunu kabul ederek 1 olarak seçilmiştir. Sonuç olarak tahmini ARİMA(p,d,q) modeli değerleri (2,2,1) şeklinde belirlenmiştir. Minitab yazılımı ile ARİMA(2,2,1) modeli oluşturulmuş olup değerlendirme kriterleri hesaplanmıştır.

Çizelge 6.1. Yolcu serisinin ARİMA(2,2,1) modeli tahmin parametreleri.

Type	Coef	SE Coef	T-Value	P-Value
AR 1	-0,377	0,112	-3,37	0,001
AR 2	-0,445	0,114	-3,91	0,000
MA 1	0,9934	0,0304	32,63	0,000
Constant	0,0036	0,0167	0,22	0,529

Benzer şekilde kargo zaman serisinin genel durumuna bakıldığında bir trend söz konusu olduğunu fark edebiliriz. Üstelik ACF ve PACF grafiklerini incelersek verinin durağan hale getirilmesi için fark alınması gerekip gerekmediğine karar verilmektedir. Deneme yanılma yolu ile en iyi modelin (2,2,1) olduğu sonucuna varılmıştır.

Çizelge 6.2. Kargo veri serisi ARİMA(2,2,1) modeli tahmin parametreleri.

Type	Coef	SE Coef	T-Value	P-Value
AR 1	-0,524	0,121	-4,31	0,000
AR 2	-0,409	0,124	-3,29	0,002
MA 1	0,9412	0,0744	12,65	0,000
Constant	1,48	1,22	1,21	0,230

Oluşturduğumuz modelin p değerleri < 0.05 olması modelin kabul edilebilir seviyede olup istatistiki açıdan anlamlı olarak değerlendirilebilmektedir. Çizelge 6.2’de gördüğümüz üzere yapılan birinci AR, ikinci AR ve hareketli ortalama modellerinin p-değerleri 0.05 den küçüktür. Buna göre birinci değerlendirme kriterimiz uygun bulunmuştur.

Modelin verilere ne kadar iyi uyduğunu belirlemek için eşitlik 10’da gösterilen ikinci performans ölçütü Ortalama Kare Hata (Mean Squared Error) kullanılmaktadır. Daha küçük MSE değeri daha uygun bir modeli ifade eder. Geliştirilen ARİMA(2,2,1) modelinin elde edilen ortalama kare hata değeri 6,75971 olarak bulunmuştur. Bu da modelin oldukça uygun olduğunu ve kabul edilebildiğini göstermektedir.

$$MSE = \frac{1}{N} \sum_{j=1}^N e_j^2 \quad (6.1)$$

Ljung-Box chi-square, modelin performansını değerlendirmede kullanılan son kriterdir. Artık değerlerin kendi geçmiş değerleri ile bir ilişkisi olup olmadığını belirlemek için p-değeri anlamlılık düzeyi değerlendirilmiştir. Genellikle, p değeri 0,05 anlamlılık düzeyinden büyükse, artıkların bağımsız olduğu ve modelin uygunluğu sonucuna varılmaktadır.

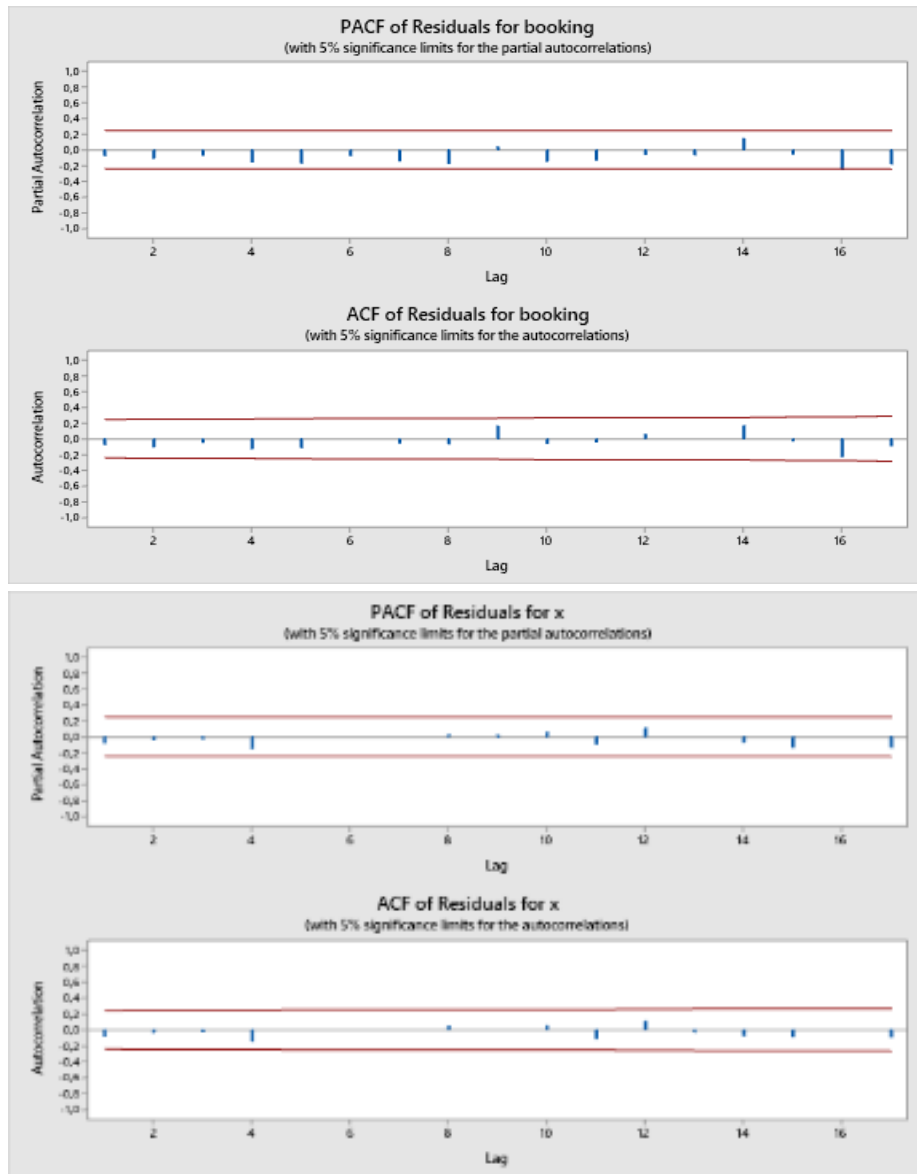
Çizelge 6.3. Yolcu veri serisinin ARİMA(2,2,1) modeli.

Lag	12	24	36	48
Chi-Square	8,89	23,63	30,68	38,03
DF	8	20	32	44
P-Value	0,352	0,259	0,533	0,724

Zaman serilerinin her ikisine ait ARİMA(2,2,1) modellerinin son dört gecikmesi için p-değerlerini içeren Çizelge 6.3'e bakıldığında tüm gecikmelerin değerleri 0,05 den daha büyük değerlere sahiptir. Dolayısıyla modelimiz Ljung-Box chi-square istatistikleri bakımından da kabul edilebilir seviyededir.

Çizelge 6.4. Kargo verisi ARİMA(2,2,1) Ljung-Box chi-square değerleri.


Lag	12	24	36	48
Chi-Square	7,68	19,90	27,17	35,92
DF	9	21	33	45
P-Value	0,567	0,528	0,752	0,831



Şekil 6.3. Yolcu ve kargo artık değerlerinin ACF ve PACF grafikleri.

Şekil 6.3, modellerin artık değerlerine ait kısmi otokorelasyon fonksiyonu (PACF) ve Otokorelasyon fonksiyonu (ACF) grafikleri gösterilmektedir. İncelendiğinde her ikisindeki gecikmelerin değerleri güvenlik limitleri içinde kalmıştır. Buna binaen artık değerlerin durağan olduğu kabul edilir.

Şekil 6.4’de görülen artık değer grafikleri regresyon uyumunu incelemek için kullanılmaktadır. Artık grafiklerin incelenmesi, geleneksel küçük kareler yöntemi varsayımlarının ne kadar karşılandığının belirlenmesine yardımcı olur. Bu varsayımlar karşılanırsa, en küçük kareler regresyonu, minimum varyansla yansız katsayı tahminleri üretecektir. Artıkların histogramı verilerin çarpık olup olmadığını veya verilerde aykırı değerleri belirlemek için kullanılır. Şekildeki histograma baktığımızda aykırı değer olmadığını görebiliriz. Artık değerlerin normal olasılık grafiğini incelediğimizde artık değerlerinin normal dağılıma uyduğundan emin olabiliriz.

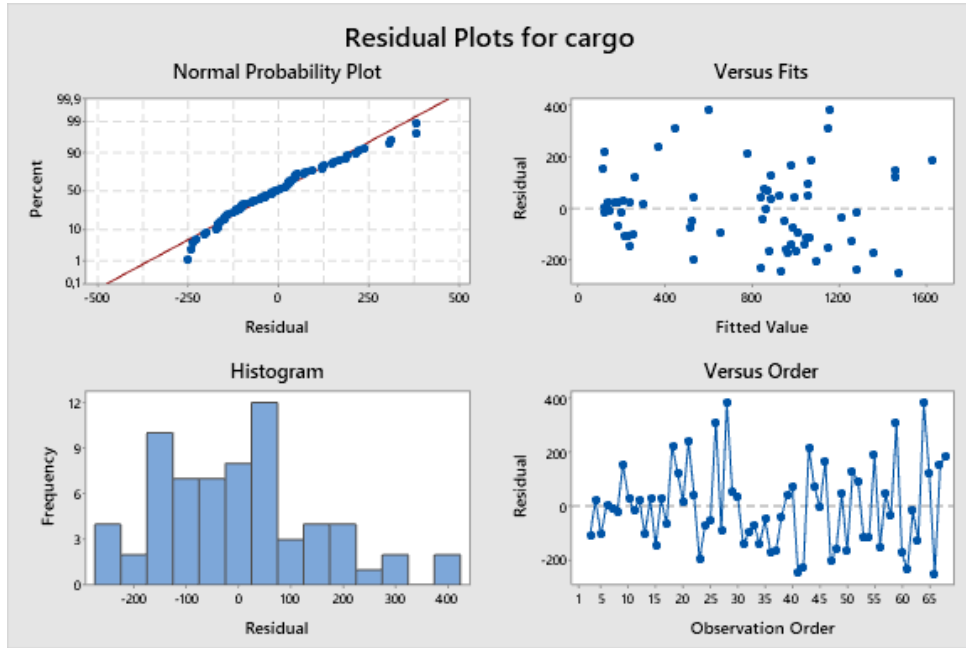


Şekil 6.4. Yolcu serisi artık değerleri analizi.

Şekil 6.5 ve Şekil 6.6’da yolcu ve kargo rezervasyonu verileri modellerinden elde edilen artık değerlerin grafikleri gösterilmektedir, normal olasılık grafiğini incelediğimizde artık değerlerinin nerdeyse tam olarak normal dağıldığı

görülmektedir. Artıkların birbiriyle ilişkisiz olduğu varsayımını doğrulamak için belirtilen artıklara karşı veri sırası grafiği incelendiğinde verilerin arasında bir ilişki olmadığı görülmektedir. "residuals versus fits plot" artıklar değer ve uygun değer grafiği, artık değer analizinde en sık kullanılan grafiklerdir. Doğrusal olmayan ve hata varyansları eşit olmayan aykırı değerleri tespit etmek için kullanılır. Elimizdeki artık değer – fit değer grafikleri değerlendirildiğinde üç madde halinde yorumlanmıştır.

- Artıklar, 0 çizgisi etrafında rastgele dağılır. Dolayısıyla artıklar ve tahmini değerlerin arasındaki ilişkinin doğrusal olduğu varsayımı kabul edilmektedir.
- Aynı zamanda artık değerlerin genellikle 0 çizgisi etrafında yer alması hata terimlerinin varyanslarının eşit olduğunu gösterir.
- Temel rastgele dağılımı tavrından çıkan hiçbir artık değer olmadığına göre aykırı değer bulunmadığına karar verilmektedir.



Şekil 6.5. Kargo serisi artık değerleri analizi.

Şekil 6.7 de ele alınan uçuşa ait yolcu ve kargo rezervasyonu zaman serilerine ait ARİMA modellerinin ürettiği tahmin değerleri ve gerçek değerlerin dağılımı gösterilmiştir.



Şekil 6.6. Yolcu ve kargo rezervasyonu zaman serilerinin arima modeli tahmini.

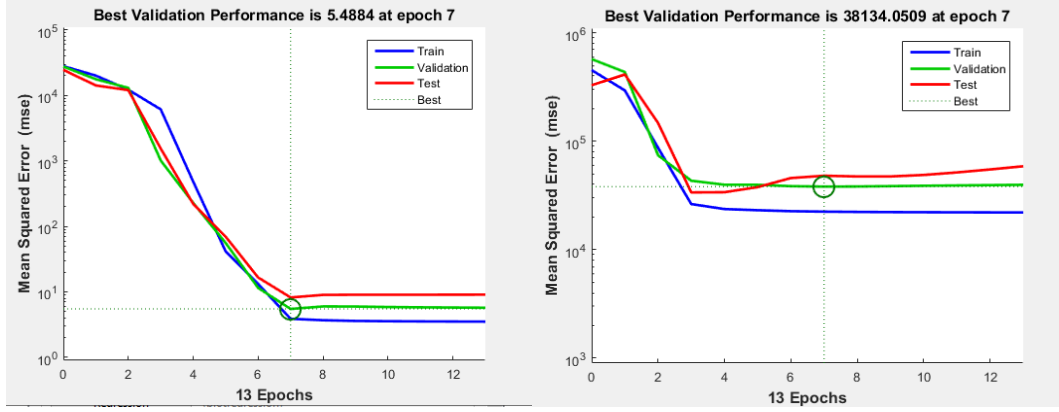
6.3. YAPAY SİNİR AĞLARI UYGULAMASI

Yapay sinir ağları zaman serisi tahmininde kullanılırken modelin parametrelerinin belirlenmesinde belli bir kural yoktur, dolayısıyla model seçiminde deneme yanılma yöntemi kullanılmaktadır. Farklı gecikme ve gizli nöron sayılarına haiz ağların hata değerlerini kıyaslayarak en iyi performans gösteren model seçilmektedir. NAR sinir ağları, MATLAB'da Levenberg-Marquardt geri yayılım eğitim algoritması kullanılarak derlenen zaman serisi verilerine uygulanmıştır. Eğitim süreci için 1. ile 48. gözlemler, doğrulama işlemi için 48. ile 58 gözlemler ve test süreci için 58. ile 68 arasındaki gözlemler kullanılmıştır. Yolcu serisi NAR sinir ağı için geri besleme gecikmeleri 2 ve gizli nöron boyutu 10 olarak oluşturulmuştur. Kargo veri seti için ise bir gecikme sayılı ve dört gizli nöronlu ağ en düşük hata değerlerini vermiştir.

Çizelge 6.5. Farklı gecikme ve nöron sayısı ile ağ performansı.

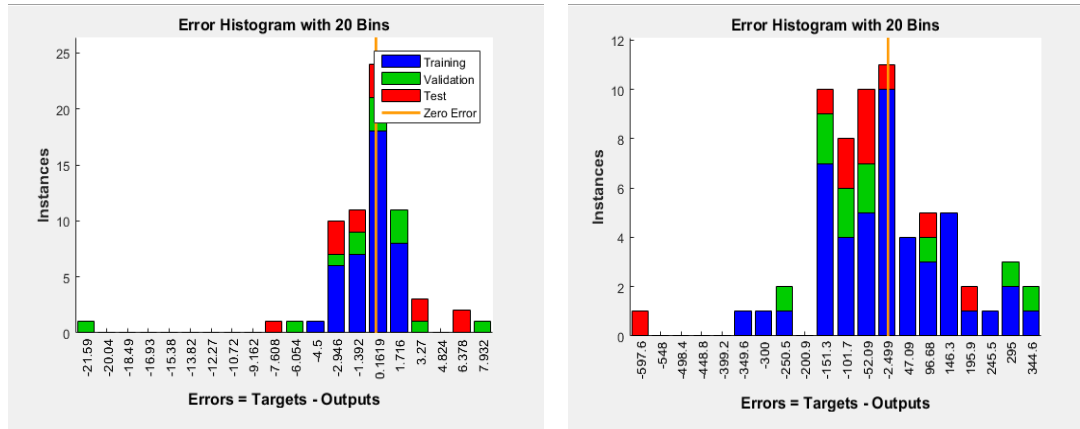
AĞ PARAMETRELERİ		KARGO REZERVASYONU NAR AĞI SONUÇLARI			YOLCU REZERASYONU NAR AĞI SONUÇLARI		
GEÇİKME SAYISI	GİZLİ NÖRÖN SAYISI	GEÇERLİK MSE	TEST MSE	GEÇERLİLİK R DEĞERİ	GEÇERLİK MSE	TEST MSE	GEÇERLİLİK R DEĞERİ
5	4	36,84267	16,42681	0,44686	24,13533	25,44732	0,07338
8	6	15,31155	24,24726	0,24632	17,47216	22,59634	0,60875
6	2	40,66829	15,45185	0,14636	20,29388	29,00509	0,16262
8	7	16,81009	13,50501	0,83048	13,73307	12,38191	0,68055
2	0	43,60756	11,29386	0,32166	16,54945	27,47814	0,07235
2	3	11,87137	9,92794	0,43893	5,99900	29,77404	0,19337
6	5	38,69236	13,48302	0,39756	14,45488	17,26760	0,07007
1	4	30,40723	17,44565	0,77051	4,78140	9,31369	0,99572
7	15	29,65592	11,74840	0,57962	20,96812	10,52851	0,16043
5	8	19,82468	23,73173	0,32536	10,74453	18,72263	0,92135
3	20	38,69679	12,86839	0,77831	6,08858	11,12631	0,11044
2	10	9,38699	8,37713	0,99935	8,02693	28,73933	0,10251
5	6	17,83138	14,05740	0,09593	9,93359	22,42443	0,88920
9	3	27,96510	19,12509	0,37194	11,59166	20,28770	0,87186
2	20	43,67297	20,85597	0,09486	18,78797	13,71917	0,46129
1	5	53,59483	10,05686	0,11005	16,71484	11,38653	0,15344
6	3	35,87859	28,34688	0,44091	17,55057	20,95036	0,11208
4	2	45,84627	12,20216	0,59254	20,44722	23,53767	0,82814
6	1	18,13604	19,12375	0,05416	9,27106	23,96654	0,03974
10	4	13,20092	23,69079	0,09045	21,85320	16,34823	0,31589
8	5	55,10599	18,63373	0,75260	8,41467	24,12475	0,20019

Aşağıdaki Şekil 6.8’de rezervasyon zaman serisine bir adet gizli katmanlı yapay sinir ağı 13 iterasyon sonra serinin performans geçerliliği görülmektedir. Hata histogramı ise Şekil 6.8’de gösterilmiştir. Eğitim ve doğrulama hatalarının işaretlenen iterasyona kadar azaldığı görülmektedir. Doğrulama hatası bu iterasyondan önce artmadığı için herhangi bir aşırı öğrenme meydana geldiği görülmemektedir.

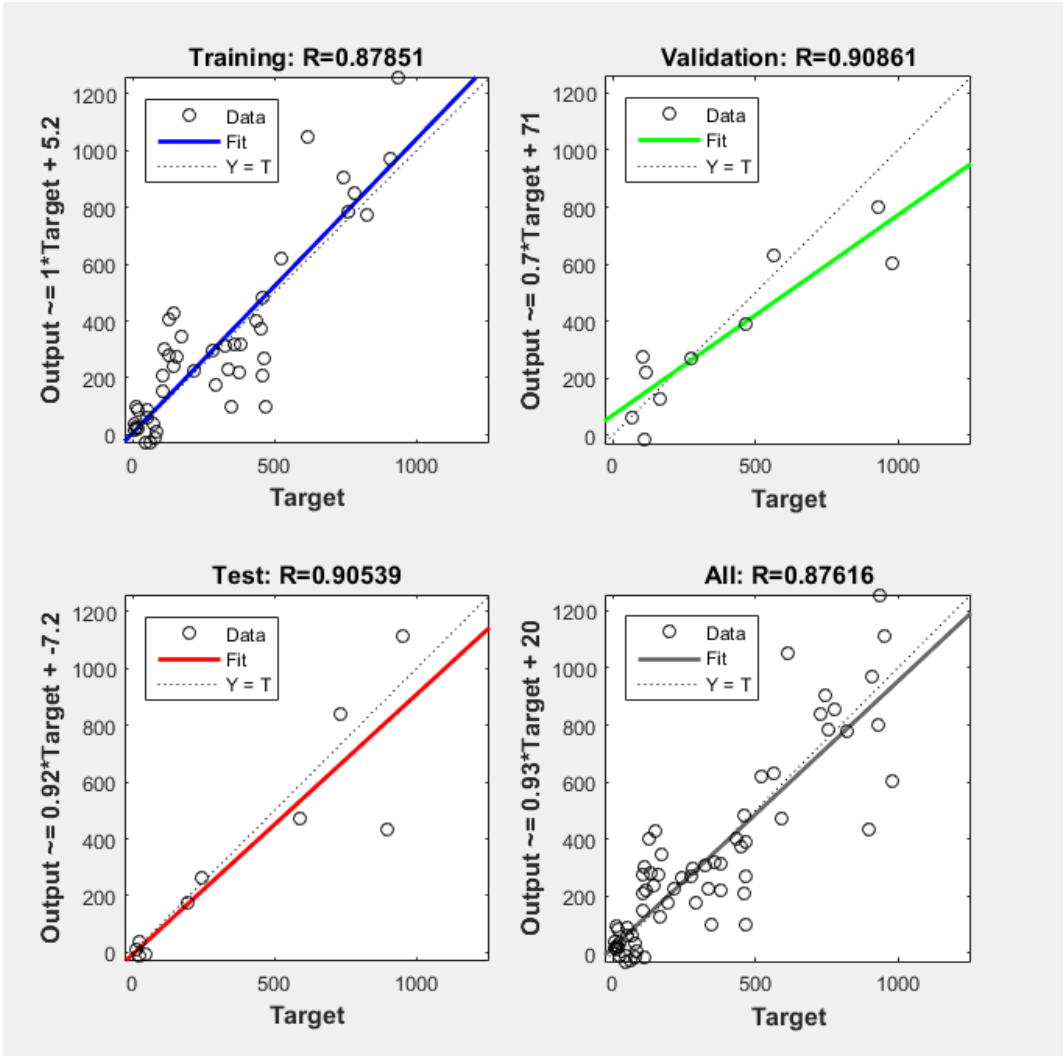


Şekil 6. 7. Yolcu ve kargo serisi için NN eğitim performansı.

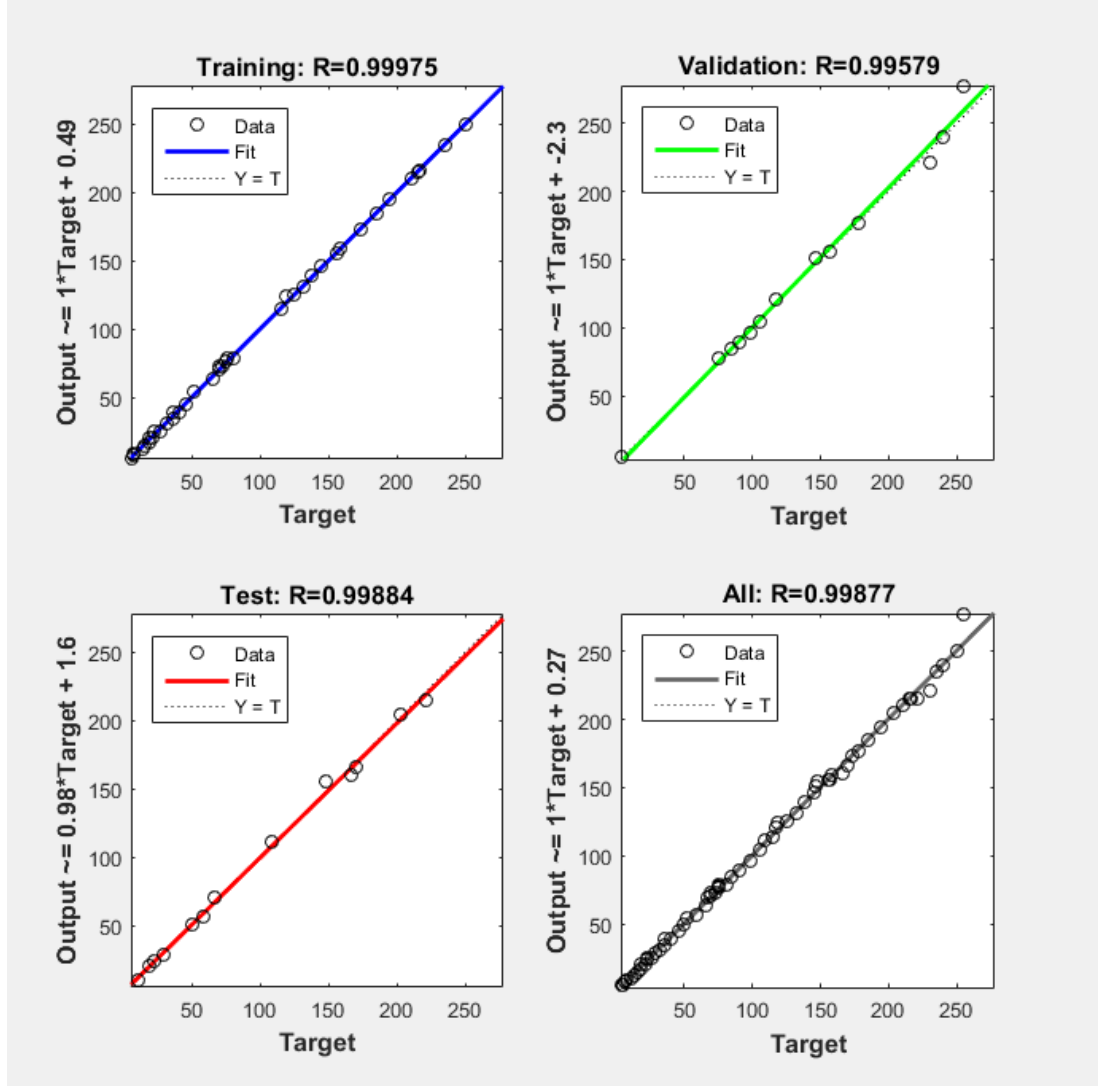
Tüm eğitim, doğrulama ve test işlemleri dahil olmak üzere açık döngüde yapılır. İş akışı, ağı tamamen açık döngüde oluşturmaktadır, ancak eğitildiğinde çok adımlı tahmin için kapalı döngüye dönüştürülür. Benzer şekilde, yapay sinir ağı uygulamasındaki R değerleri, açık döngü eğitim sonuçlarına göre hesaplanır. NN ağına ait regresyon şeklinde olduğu gibi eğitim, geçerlilik ve test R değerleri bire yakın olması modelin uygunluğunu yansıtmaktadır.



Şekil 6.8. Yolcu ve ve kargo serisi NN eğitim hatası.

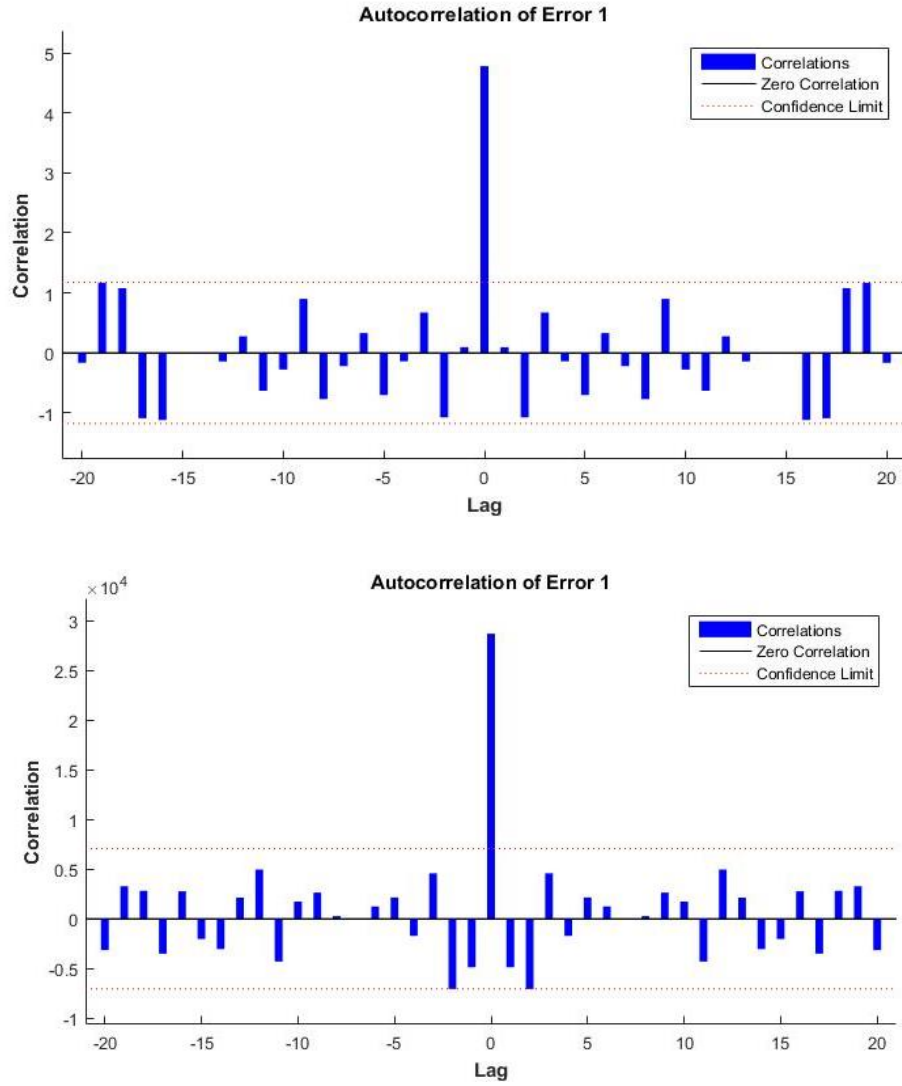


Şekil 6.9. Kargo serisi regresyon değerleri.



Şekil 6.10. Yolcu serisi regresyon değerleri.

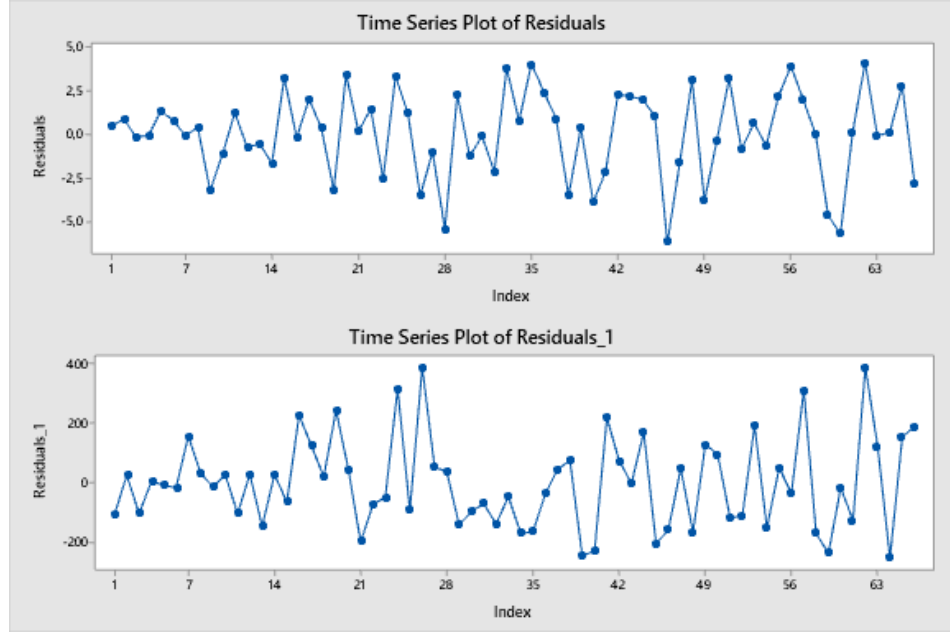
Şekil 6.12’de yolcu ve kargo rezervasyonu için otokorelasyon fonksiyon grafikleri incelendiğinde 0’da bir tane güven aralığını geçen değer vardır. Tahmin hatalarının korelasyonsuz olduğunu (white noise) olduğunu gösterir. Otokorelasyon dağılımlarına göre model uygundur.



Şekil 6.11. Yolcu serisi regresyon değerleri.



6.4. ARİMA-YSA HİBRİT MODELİ

Yapay sinir ağlar rezervasyon tahmini için doğrusal olmayan verileri ve karmaşık ilişkileri temsil etme yeteneğinden dolayı kullanılmaktadır. Verinin doğrusal ilişkisini kaçırmayan daha iyi bir tahmin için hibrit model uygulanmıştır. İlk 50 gözlemin ARİMA modeli ile bulunan artık değerlerini yapay sinir ağının girdisi olarak kullanıp geri kalan gözlemlere ait artık değerleri tahmin edilmiştir. Giriş değişkenleri seçildikten sonra optimum NAR modelinin geliştirilmesi, gecikme sayısı, gizli katmandaki nöron sayısı ve en iyi eğitim algoritması belirlenmiştir.

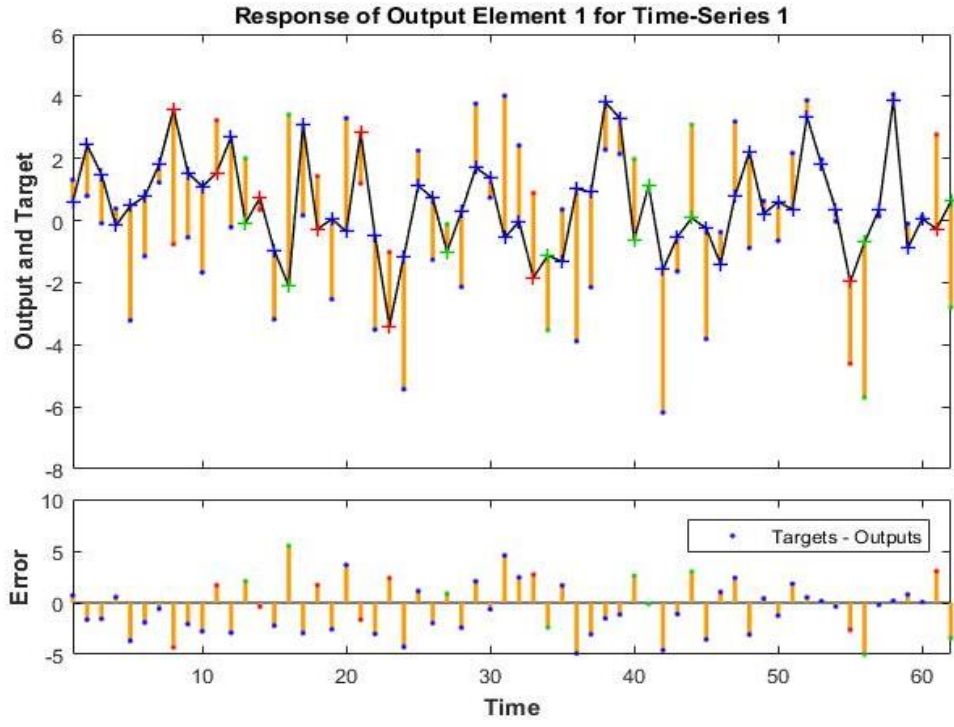


Şekil 6.12. ARIMA modelleri artık değerleri.

Deneme yanılma yöntemine göre gizli katmandaki optimum nöron ve gecikme sayısı 12 ve 4'tür. Eğitim, doğrulama ve test için en yüksek R değerleri sırasıyla 0.9489, 0.5390 ve 0.3439'dir. Tahmin hatalarının zaman ile ilişkisini açıklayan hata otokorelasyon fonksiyonu grafiği Şekil 6.13'da gösterilmiştir. Mükemmel bir tahmin modeli için ACF'nin yalnızca sıfır nolu gecikmedeki değeri güven aralığını geçmelidir. Böylece tahmin hatalarının birbiriyle tamamen ilişkisiz ve beyaz gürültü durumunda oluşu anlaşılmaktadır. Bu çalışmada, sıfırda bir hariç korelasyonlar tahmin hataları %95 güven aralığı içinde sıfır civarında yer almıştır. Bu nedenle, model yeterli olarak kabul edilmektedir.



Şekil 6.13. ARIMA-NAR modelleri hata otokorelasyon grafiği.



Şekil 6.14. ARIMA-NAR hibrit artık değer zaman serisi sonucu.

BÖLÜM 7

SONUÇ VE DEĞERLENDİRME

Havayolu gelir ve kapasite yönetimi için karar verme sürecine destek olarak beklenen talep tahmini yapılmıştır. Aynı rotanın geçmiş uçuşunda atanmış kapasiteyi gözden geçirip güncelleme kararını değerlendirmek için rezervasyon zaman serileri kullanılmıştır. Uçuşa ait 15 ayın 67 haftası boyunca yolcu ve kargo rezervasyon verileri kullanılmıştır. Veriler ile geliştirilen tahmin modellerinin en iyisini kullanarak uçuş gününde beklenen toplam yolcu sayısı ve kargo miktarı öngörülmüştür. Ona binaen havayolunun incelenen rotasına ait geçmiş uçak ataması kesinleştirilmiştir. Tahmin doğruluğu kriterlerine dayanarak öngörülen değerler gerçek değerlerle karşılaştırılmıştır. Veri analizi ve modellemesinde Matlab ve Minitab yazılımları kullanılmıştır. Yapılan NAR ve ARIMA modelleri, Ortalama Kare Hatası (MSE), Ortalama Mutlak Hata (MAE) değerleri Çizelge 6 gösterildiği gibi kıyaslanarak hibrit modelin en iyi performansa sahip olduğu görülmüştür.

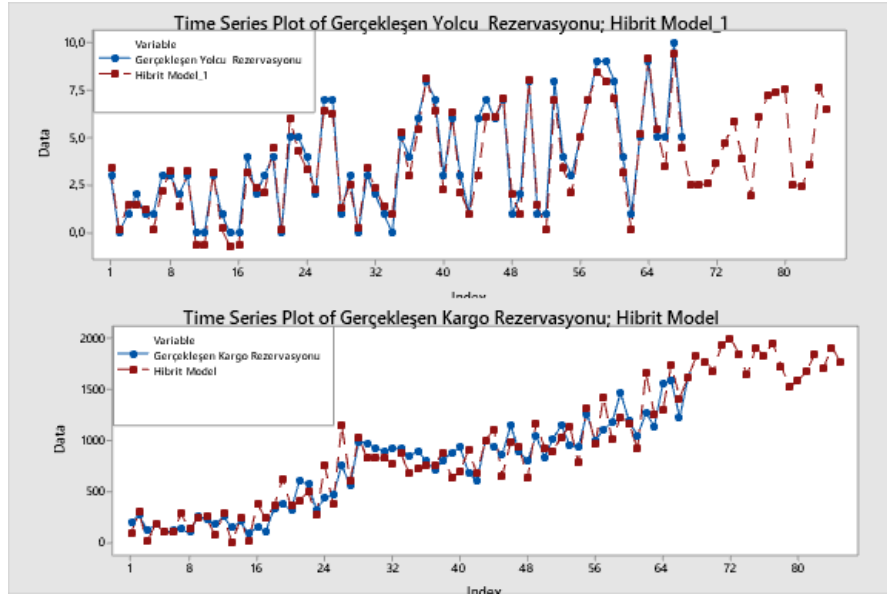
Çizelge 7.1. Tüm modellerinin tahmin performanslarının karşılaştırılması.

ÖLÇÜT	YOLCU		KARGO	
	MSE	MAE	MSE	MAE
ARIMA	6,75971	130,6423	27,7854	149,2811
NAR	4,7814	92,1025	9,38699	94,5435
HİBRİT	3,81715	89,5979	7,9584	79,5458

Elde edilen modellerin hata değerleri incelendiğinde hibrit modelin hem Ortalama Kare hata değeri hem de Ortalama Mutlak Hatası bakımından en iyi performans gösterdiği anlaşılmaktadır. Hibrit modelin güvenilirliğinden dolayı kalkış gününe kalan günlerde olabilecek rezervasyonların öngörüsünde kullanılmıştır. Sonrasında uçuşa beklenen kümülatif yolcu sayısı ve kargo miktarı hesaplanmıştır. Gerçekleşmiş doluluk oranı tahminine göre beklenen doluluk oranı ile kıyaslanmıştır. Havayolunun

temel aldığı en düşük yüzde yetmiş değerindeki doluluk oranı kısıtına istinaden uçak atama güncelleme kararı alınmıştır.

Optimum performansa sahip olan hibrit modelin tahmin ettiği son gözlemlerine ait ARİMA modeli artık değerleri tahmin edilmiştir. Son tahmin değerleri hesaplanıp elde edilmiştir. Şekil 7.1 gerçekleşen kargo ve yolcu rezervasyonu ile hibrit tahmin değerlerini göstermektedir.



Şekil 7.1. Gerçekleşen kargo ve yolcu rezervasyonu ile hibrit tahmin değerleri.

Yapılan çalışmanın vardığı tahmin sonuçları ışığında uygun kapasite ataması ve envanter yönetim sürecine esneklik sağlamaktadır. Daha düşük rezervasyon beklendiği durumlarda daha düşük kapasiteli kabin atanması mümkündür. Genellikle ele alınan rotaya tahsis edilen envanter 350 yolcu kapasitesindedir. Tahmine göre beklenen 70% doluluk oranına ulaşıldığından envanter ataması kabul edilir.

Çizelge 7.1. Tahmin edilen toplam rezervasyon.

Henüz Gerçekleşen		Tahminen Beklenen	
Yolcu (ADET)	Kargo (KG)	Yolcu (ADET)	Kargo (KG)
221	4683	314	8114

Son olarak, detaylı havayolu rezervasyonunu etkileyip tahmin doğruluğunu destekleyebilecek farklı deęişkenleri kapsayan veriler ile yapılan alıřmaların daha iyi bir sonu vermesi beklenmektedir.

Üstelik destinasyona baęlı olarak rezervasyonu etkileyen dıř faktörlerin yanında yerel döviz durumu gibi i faktörler müşteri'nin rezervasyon kararı üzerinde etki edebilmektedir. Yapılan alıřmada uuř bazlı talep tahmini yapmak üzere zaman serisi analizi kullanmak toplam ülke temelli tahminler kadar yeterli olmasa da talebe etki eden faktörlerin sabit olması ve şartların deęiřmedięi hipotezi ile uzun vadeli izelgelenmiř uuřlar iin kabul edilebilir tahminler saęlamaktadır. Ele alınan bu tarz rezervasyon verilerinin mevsimel olmayıp verinin genel seyri belirlenemedięinden kaynaklanmaktadır. Dolayısıyla verinin gelecekte alabileceęi deęerleri daha dikkatli bir řekilde tahmin edebilmektedir.

alıřma kapsamında ele alınan uuřun beklenen toplam rezervasyon sayılarını tahmin etmek iin NAR - ARIMA hibrit modelinin dięer klasik modellere göre daha yüksek performans gösterdięi deneysel bir biimde kanıtlanmıřtır. Haliyle rezervasyon süresine baęlı olarak derlenen verinin gözlem sayısı, genel havayolu talep tahmininde kullanılan verilerin gözlem sayısına göre yetersiz görülebilmektedir. Dolayısı ile toplu tahminler daha iyi tahminler elde edilebilmektedir. Ancak havayolu sektöründe detaylı rezervasyon tahmini, envanter yönetimi, uuř planları, fiyatlandırma stratejileri gibi yönetim operasyonlarında önemli bir yere sahip olması güvenilir tahmin rakamları gerektirir. Doğru ve güvenilir tahminler, havayolu sektöründe lojistik, satın alma, iř gücü ve müşteri hizmetlerinin organizasyonu ve planlaması ile ilgili süreçlerle doğrudan baęlantılıdır.

KAYNAKLAR

1. Biederman, "The role of forecasting at trans world airlines". **The Journal of Business Forecasting**, (1993).
2. Duncanson, "Short-Term Traffic Forecasting", *Proc. 14th Annu. AG- IFORS Symp.* 1974.
3. Tsui, H. Ozer Balli, A. Gilbey, ve H. Gow, "Forecasting of Hong Kong airport's passenger throughput", *Tour. Manag.*, c. 42, ss. 62-76, 2014.
4. Sa, "Reservations Forecasting in Airline Yield Management", *Mass. Inst. Technol.*, 1987.
5. Weatherford, T.W. Gentry, ve B. Wilamowski, "Neural network forecasting for air- lines", *J. Revenue Pricing Manag.*, ss. 319-331, (2003).
6. Ostaijen, F. Santos, ve M. Mitici, "Dynamic Airline Booking Forecasting", *Air Transp. Res. Soc. World Conf.*
7. Zenkert, "No-show Forecast Using Passenger Booking", **Lund University, Sweden.**
8. Bekin, "Türkiye'de Bazı Temel Gıda Fiyatları İçin Yapay Sinir Ağları ve Zaman Serisi Tahmin Modellerinin Karşılaştırmalı Analizi", **Pamukkale Üniversitesi, Denizli**, 2015.
9. Erturan, "Zaman Serileri İçin Optimize Arıma – Ysa Hibrit Modeli ve Finansal Zaman Serileri İle Örnek Uygulamalar", **Akdeniz Üniversitesi Sosyal Bilimler Enstitüsü, Antalya**, (2017).
10. Durdu, "A hybrid Neura Lnetwork and ARIMA Model for Water Quality Time Series Prediction", *WaterResourcesResearchCenter,Adnanmenderesuniversity*, ss. 586-594, (2010).
11. Lee, "Airline Reservations Forecasting: Probabilistic And Statistical Models of The Booking Process", **Massachusetts Institute Of Technology**, Department of Civil Engineering, (1990).
12. . Chismar ve J. Meier, "A model of Competing İnterorganizational Systems and its Application to Airline Reservation Systems", *Decis. Support Syst.*, c. 8, sy 5, ss. 447-458, (1992).

13. Berge ve C. A. Hopperstad, “Demand Driven Dispatch: A Method for Dynamic Aircraft Capacity Assignment, Models and Algorithms”, *Oper. Res.*, c. 41, sy 1, ss. 153-168, Şub. 1993, doi: 10.1287/opre.41.1.153.
14. Vickery, “Airline overbooking: some further solutions”, *J. Transp. Econ. Policy*, ss. 257-270, (1972).
15. Özer, “TUR OPERASYONLARINDA CHARTER SEFERLERİN KULLANIMI VE TERCİH EDİLİVIE NEDENLERİ ÜZERİNE”, s. 24.
16. Kluge, A. Paul, A. Cook, ve S. Cristóbal, “Factors influencing European passenger demand for air transport”, s. 15, 2017.
17. Monahan, “Aircraft Demand Forecasting”, **Massachusetts Institute Of Technology**, doi: 10.7275/7950755.
18. Bhuiyan, “Airline Group Reservation: predicting and minimizing cancellations”, (2020).
19. Sadreddin “FAQ Group Travel | **Austrian Airlines**”. <https://www.austrian.com/au/en/faq-group-trips> (erişim 04 Aralık 2021).
20. Al-hawari ve S. Mouakket, “Do offline factors trigger customers’ appetite for online continual usage? A study of online reservation in the airline industry”, *Asia Pac. J. Mark. Logist.*, (2012).
21. Ravich, “Deregulation of the Airline Computer Reservation Systems (CRS) Industry”, *J Air Com*, c. 69, s. 387, (2004).
22. [Sadreddini, “A Novel Cancellation Protection Service in Online Reservation System”, *IEEE Access*, c. 8, ss. 129094-129107, 2020, doi: 10.1109/ACCESS.2020.3009061.
23. Rothstein, “OR Forum—OR and the airline overbooking problem”, *Oper. Res.*, c. 33, sy 2, ss. 237-248,(1985).
24. Salih, “Custom Software Solutions for Airline Operations Management”. <https://www.altexsoft.com/travel-technology/airline-operations-management-solutions/> (2021).
25. Madsen, *Time series analysis*. Chapman and Hall/CRC, (2007).
26. Kirchgässner, J. Wolters, ve U. Hassler, *Introduction to modern time series analysis*. **Springer Science & Business Media**, (2012).
27. Chatfield ve H. Xing, *The analysis of time series: an introduction with R*. Chapman and hall/CRC, (2019).

28. Parzen, “An approach to time series analysis”, *Ann. Math. Stat.*, ss. 951-989, 1961.
29. Meidinger, *Applied time series analysis for the social sciences*. **Sage Publications**, 1980.
30. R. H. Shumway, D. S. Stoffer, ve D. S. Stoffer, *Time series analysis and its applications*, c. 3. Springer, (2000).
31. Pena, G. C. Tiao, ve R. S. Tsay, *A course in time series analysis*, c. 322. John Wiley & Sons, (2011).
32. Hill, M. O’Connor, ve W. Remus, “Neural Network Models for Time Series Forecasts”, *Manag. Sci.*, c. 42, sy 7, ss. 1082-1092, Tem. 1996, doi: 10.1287/mnsc.42.7.1082.
33. Ruben, “A dynamic artificial neural network model for forecasting time series events-ScienceDirect”.
<https://www.sciencedirect.com/science/article/abs/pii/S0169207004001116>
(2021).
34. Danişmani, “Altın Fiyatlarının Yapay Sinir Ağları ve Arma Modelleri ile Tahminlenmesi”, s. 183.
35. Reshon , “Social Network for Programmers and Developers”. **Manhattan centre**
<https://morioh.com> (2021).
36. SHARMA, “Activation Functions in Neural Networks Towards Data Science”.
<https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6> (2021).
37. Thourder, “Evolutionary assembled neural networks for making medical decisions with minimal regret: Application for predicting advanced bladder cancer outcome - **ScienceDirect**”.
<https://www.sciencedirect.com/science/article/abs/pii/S0957417414003996>
38. Madhavi vd., “Advanced electricity load forecasting combining electricity and transportation network”, içinde *2017 North American Power Symposium* (2017).
39. Colak, S. Sagiroglu, M. Yesilbudak, E. Kabalci, ve H. I. Bulbul, “Multi-time series and -time scale modeling for wind speed and wind power forecasting part I: Statistical methods, very short-term and short-term applications”, içinde *2015 International Conference on Renewable Energy Research and Applications (ICRERA)*, (2015).
40. Zhang, “Time series forecasting using a hybrid ARIMA and neural network model”, *Neurocomputing*, c. 50, ss. 159-175, (2003).

41. Stephen, "Model uncertainty and forecast accuracy ", **Journal of Forecasting - Wiley Online Library** (1996).

ÖZGEÇMİŞ

Alaa ABUSHUKUR, ilk ve orta öğrenimini Hebron şehrinde tamamladı. Fen lisesinden onur dercesi ile mezun oldu. 2014 yılında Türkiye'ye gelip Ankara Üniversitesi'nin İstanbul'daki Tömer şubesinde Türkçe eğitimi aldı. Aynı senede Sakarya Üniversitesi Endüstri Mühendisliği öğrenime başlayıp 2018 yılında Asaş ve Arma fabrikalarında uzun ve kısa dönem stajlarını biterek mezun oldu. 2019 yılında İstanbul'da yer alan Ashour dış ticaret ve pazarlama firmasında lojistik sorumlusu olarak göreve başladı. 2020 yılında yaşanan korona pandemi sürecine müteakip memleketine döndü. Yem sektöründe faaliyet gösteren İzdihar firmasında mesleki hayatını sürdürmektedir. Sakarya ve Karabük Üniversitelerinin ortak yüksek lisans programını kapsamında Lisansüstü Eğitim Enstitüsü Endüstri Mühendisliği Anabilim Dalı'nda tamamladı.