

TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**BEKLENMEDİK UÇAK YÖNLENDİRMELERİNİ AZALTMA: ZAMAN
SERİSİ ANALİZİ VE YAPAY SİNİR AĞLARI İLE MODELLEME**

YÜKSEK LİSANS TEZİ

Hazal Berve DOĞAN

Endüstri Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Tahir HANALIOĞLU

TEMMUZ 2019

Fen Bilimleri Enstitüsü Onayı

.....
Prof. Dr. Osman EROĞUL
Müdür

Bu tezin Yüksek Lisans derecesinin tüm gereksinimlerini sağladığını onaylarım.

.....
Prof. Dr. Tahir HANALIOĞLU
Anabilimdalı Başkanı

TOBB ETÜ, Fen Bilimleri Enstitüsü'nün 161311050 numaralı Yüksek Lisans Öğrencisi **Hazal Berve DOĞAN**'ın ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "**BEKLENMEDİK UÇAK YÖNLENDİRMELERİNİ AZALTMA: ZAMAN SERİSİ ANALİZİ VE YAPAY SİNİR AĞLARI İLE MODELLEME**" başlıklı tezi **17.07.2019** tarihinde aşağıda imzaları olan jüri tarafından kabul edilmiştir.

Tez Danışmanı : **Prof. Dr. Tahir HANALIOĞLU**
TOBB Ekonomi ve Teknoloji Üniversitesi

Eş Danışman : **Dr. Umut DEMİREZEN**

Jüri Üyeleri : **Prof. Dr. Fikri GÖKPINAR (Başkan)**
Gazi Üniversitesi

Doç. Dr. Kumru Didem ATALAY
Başkent Üniversitesi

Dr. Öğr. Üyesi Salih TEKİN
TOBB Ekonomi ve Teknoloji Üniversitesi

Dr. Öğr. Üyesi Başak GEVER
Türk Hava Kurumu Üniversitesi

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, alıntı yapılan kaynaklara eksiksiz atıf yapıldığını, referansların tam olarak belirtildiğini ve ayrıca bu tezin TOBB ETÜ Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırlandığını bildiririm.

Hazal Berve Dođan

ÖZET

Yüksek Lisans Tezi

BEKLENMEDİK UÇAK YÖNLENDİRMELERİNİ AZALTMA: ZAMAN SERİSİ ANALİZİ VE YAPAY SİNİR AĞLARI İLE MODELLEME

Hazal Berve Doğan

TOBB Ekonomi ve Teknoloji Üniversitesi
Fen Bilimleri Enstitüsü
Endüstri Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Tahir Hanalioğlu

Tarih: Temmuz 2019

Bu çalışmada, bir havayolu şirketinin beklenmeyen yönlendirmelerinin sebep olduğu maliyetlerin en aza indirgenmesi amacı ile bir karar destek sistemi tasarlanmıştır. Söz konusu havayolu şirketi tarafından temin edilen meteorolojik veriler ışığında R programlama dili kullanılarak, görüş mesafesini öngörmek amacı ile yapılan analizlerin sonuçları sunulmuştur. Verilerin zaman serisi analiz yöntemleri kullanılarak incelenmesi ile öngörülerde bulunmak amaçlanmıştır. İleriye dönük 3 saate karşılık gelecek şekilde ayrıntılı değerlendirme gerçekleştirilmiştir. Zaman serisi analizlerinden AR, MA, ARMA, ARIMA, AutoARIMA ve VAR kullanılarak elde edilen sonuçlar, hata oranı fonksiyonlarına göre karşılaştırılmıştır. Çalışmanın ikinci bölümünde, MATLAB programlama dili kullanılarak yapay sinir ağları oluşturulmuş, bu yöntem ile elde edilen meteorolojik verilerin tahminleri, zaman serisi analizi sonuçları ile karşılaştırılmıştır. Sistemsel olarak iyileştirme, yönlendirilen uçuşlara ait kararların doğruluğu ile ölçülmüştür. Ölçümler, karışıklık matrisine işlenmiştir.

Anahtar Kelimeler: Havacılık, Uçak Yönlendirme, Hava Tahmini, Zaman Serileri, Karar Destek Sistemi, , Tekrarlayan Yapay Sinir Ağları (TSA), LSTM.



ABSTRACT

Master of Science

REDUCE UNEXPECTED AIRLINE DIVERTS: MODELLING WITH TIME SERIES ANALYSIS AND NEURAL NETWORK

Hazal Berve Dođan

TOBB University of Economics and Technology
Institute of Natural and Applied Sciences
Department of Industrial Engineering

Supervisor: Prof. Dr. Tahir Hanaliođlu

Date: July 2019

In this study, a decision support system is designed in order to minimize the number of flights that are diverted unexpectedly. The aim is to reduce the expenses that arise when the aircraft is not able to land on the targeted airport due to the unfavorable weather conditions, such as rescheduling the timetable, overuse of aircraft fuel than planned, passengers' accommodation and ticket reissue. In order to reduce such temporal and financial losses caused by diverted flights, decision to take off or not is made before departure, while the decision to land or not is made during flight, after a brief analysis based on weather data of target airport. For the aircraft to land on target airport as scheduled, it is crucial that the weather forecasts for visibility range, ceiling and wind speed are within the limits of the safe flight requirements. Considering the significance of this decision regarding by finance, there is a need for a decision support system that is capable of boosting the process through optimal decision-making by forecasting airport weather conditions. In the first part of the study, weather is forecast using regression and time series analysis, of which methods can be detailed as auto regressive (AR), moving average (MA), auto regressive integrated moving average

(ARIMA) and vector auto regressive (VAR). Although such forecast methods are relatively effective in achieving the desired result, neural network and fuzzy logic techniques are expected to present more accurate forecast with their complicated and advanced algorithm structure. In the second part of the study, neural networks are created with using MATLAB. The results which is obtained with these methods are compared time series analysis results. Improvement is measured by accuracy of the decisions of diverted flights. The measurements are recorded on the confusion matrix.

Key Words: Divert, Weather Forecast, Regression, Time Series, Decision Support System, Neural Network, RNN, LSTM .



TEŐEKKÜR

Çalıőmalarım boyunca deęerli yardım ve katkılarıyla beni yönlendiren kıymetli hocam Sayın Prof. Dr. Tahir HANALIOĐLU'na, deęerli tecrübelerinden faydalandığım Eő-Tez Danıőmanım Sayın Dr. Umut DEMİREZEN'e, her konuda yanımda olan aileme ve tez çalıőmam boyunca, tüm bilimsel çalıőmalarım sırasında yardımlarını esirgeme-yen, her zaman yanımda olan çok kıymetli dostlarım Pınar DARENDE, Derya GÖ-ZEN ve Hakan MARAL'a teőekkür ederim.

İÇİNDEKİLER

Sayfa

ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER.....	ix
ŞEKİL LİSTESİ.....	xi
ÇİZELGE LİSTESİ.....	xiii
KISALTMALAR.....	xiv
SEMBOL LİSTESİ.....	xv
1. GİRİŞ	1
1.1 Tezin Amacı.....	3
1.2 Literatür Araştırması	4
2. ZAMAN SERİSİ ANALİZİ	9
2.1 Amaç	9
2.2 Zaman Serisi Analizi Yöntemleri.....	9
2.2.1 Box-Jenkins Tahmin Yöntemleri	11
2.2.2 Durağan Zaman Serileri	12
2.2.3 Durağan Olmayan Zaman Serileri	13
2.2.4 Zaman Serilerinde Durağanlığın Belirlenmesi.....	13
2.2.4.1 Klasik Yöntemler ile Durağanlığın Belirlenmesi.....	13
2.2.4.2 Modern Yöntemler ile Durağanlığın Belirlenmesi	14
2.2.5 Zaman Serisi Modelleri.....	15
2.2.5.1 Otoregresif Süreç Modeli - AR(p)	16
2.2.5.2 Hareketli Ortalama Modeli - MA(q).....	20
2.2.5.3 Otoregresif ve hareketli Ortalama Modeli - ARMA(p, q).....	23
2.2.5.4 Otoregresif Bütünleşik Hareketli Ortalama Modeli - ARIMA(p,d,q).....	26
2.2.5.5 Auto.ARIMA Modeli.....	29
2.2.5.6 Vektör Otoregresif Model - VAR(p).....	32
2.2.6 Modellerin Öngördüğü Tahminlerin Hata Testleri	34
2.3 Sonuç.....	35
3. YAPAY SİNİR AĞLARI.....	37
3.1 Amaç	37
3.2 Yapay Sinir Ağları Tanımı ve Tarihiçesi	37
3.3 Yapay Sinir Ağlarının Genel Özellikleri.....	38
3.3.1 Yapı ve Temel Elemanları	39
3.3.1.1 Biyolojik Sinir Hücreleri.....	39
3.3.1.2 Yapay Sinir Hücresi (İşlemci Eleman)	40
3.3.2 Yapay Sinir Ağları Yapısı.....	43
3.3.3 Yapay Sinir Ağlarının Sınıflandırılması	44
3.3.3.1 Tek Katmanlı Algılayıcılar	44
3.3.3.2 Çok Katmanlı Algılayıcılar	45

3.3.4	Yapay Sinir Ağlarında Öğrenme.....	47
3.3.4.1	Öğrenme Yöntemleri.....	48
3.3.5	Tekrarlayan Sinir Ağları (Recurrent Neural Network)	48
3.3.5.1	İki Yönlü TSA'lar (Bidirectional RNNs).....	50
3.3.5.2	Derin (İki Yönlü) RNN'ler (Deep RNNs).....	50
3.3.6	Kısa Uzun Süreli Hafıza (Long Short Term Memory - LSTM)	51
3.4	Sistem Modeli	52
3.4.1	Veri Analizi	52
3.4.2	Ağ Yapısı.....	52
3.4.3	LSTM Ağ Topolojisi.....	54
3.5	Yapay Sinir Ağları Sonuçları	55
3.5.1	Bir Adım Kaydırmalı Girdi Katmanı Sonuçları	55
3.5.2	Beş Adım Kaydırmalı Girdi Katmanı Sonuçları	57
3.6	Karışıklık Matrislerinin Karşılaştırılması.....	60
4.	SONUÇ VE ÖNERİLER.....	63
	KAYNAKLAR.....	65
	ÖZGEÇMİŞ.....	69

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1 : Örnek bir uçuş için METAR - TAF uyumu.....	2
Şekil 2.1 : Gerçek Veri Setinin Son 500 Verisi	11
Şekil 2.2 : Düzleştirme Uygulanmış Veri Setinden Bir Kesit.....	11
Şekil 2.3 : Modele ait ACF ve PACF Grafikleri.....	15
Şekil 2.4 : AR(1) model sonucu, 18.10.2011 20:20 uçuşu	17
Şekil 2.5 : MA(1) model sonucu, 18.10.2011 20:20 uçuşu.....	21
Şekil 2.6 : ARMA(1) model sonucu, 18.10.2011 20:20 uçuşu	24
Şekil 2.7 : ARIMA(1,1,1) model sonucu, 18.10.2011 20:20 uçuşu.....	27
Şekil 2.8 : Auto.ARIMA(p,d,q) model sonucu, 18.10.2011 20:20 uçuşu.....	30
Şekil 2.9 : Vektör Ardışık Bağlanım Modeli (VAR)	33
Şekil 2.10 : Ortalama Mutlak Hata (MAE) Karşılaştırması.....	34
Şekil 2.11 : Kök Ortalama Karesel Hata Oranlarının (RMSE) Karşılaştırması.....	35
Şekil 2.12 : Ortalama Mutlak Yüzde Hata Oranlarının (MAPE) Karşılaştırması	35
Şekil 3.1 : Biyolojik Sinir Hücresi	40
Şekil 3.2 : Yapay Sinir Hücresinin Yapısı	41
Şekil 3.3 : Yapay Sinir Ağlarının Yapısı	43
Şekil 3.4 : Tek Katmanlı Algılayıcı Modeli.....	45
Şekil 3.5 : Çok Katmanlı Algılayıcının Yapısı	46
Şekil 3.6 : Tekrarlamalı Sinir Ağı Modeli	49
Şekil 3.7 : İki Yönlü TSA	50
Şekil 3.8 : Derin TSA Yapısı	51
Şekil 3.9 : Bir Adım Kaydırmalı Ağ Eğitim Süreci.....	56
Şekil 3.10 : Bir Adım Kaydırmalı Tahmin Grafiği	56
Şekil 3.11 : Beş Adım Kaydırmalı Ağ Eğitim Süreci	58
Şekil 3.12 : Beş Adım Kaydırmalı Tahmin Grafiği	58
Şekil 3.13 : YSA - RMSE Karşılaştırması	59

ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1 : AR(1) Tahmini Değer- Gerçek Değer- Uydurulmuş Değer.....	18
Çizelge 2.2 : AR(1) Tahmini Değer - Alt - Üst Değer.....	19
Çizelge 2.3 : AR(1) Hata Oranları.....	19
Çizelge 2.4 : MA(1) Tahmini Değer- Gerçek Değer- Uydurulmuş Değer.....	21
Çizelge 2.5 : MA(1) Tahmini Değer - Alt - Üst Değer.....	22
Çizelge 2.6 : MA(1) Hata oranları.....	23
Çizelge 2.7 : ARMA(1) Tahmini Değer - Gerçek Değer - Uydurulmuş Değer	24
Çizelge 2.8 : ARMA(1) Tahmini Değer- Alt- Üst Değer.....	25
Çizelge 2.9 : ARMA(1) Hata oranları.....	26
Çizelge 2.10 : ARIMA(1,1,1) Tahmini Değer - Gerçek Değer - Uydurulmuş Değer	28
Çizelge 2.11 : ARIMA(1,1,1) Tahmini Değer - Alt - Üst Değer.....	29
Çizelge 2.12 : ARIMA(1,1,1) Hata Oranları.....	29
Çizelge 2.13 : Auto.ARIMA(5,1,6) Tahmini Değer - Gerçek Değer – Uydurulmuş Değer.....	31
Çizelge 2.14 : Auto.ARIMA (5,1,6) Tahmini Değer - Alt - Üst Değer.....	32
Çizelge 2.15 : Auto.ARIMA (5,1,6) Hata Oranları.....	32
Çizelge 2.16 : Zaman Serileri Analizine Ait Karışıklık Matrisi.....	36
Çizelge 3.1 : Fonksiyonlar.....	42
Çizelge 3.2 : Aktivasyon Fonksiyonları.....	42
Çizelge 3.3 : Bir Adım Kaydırmalı Girdi ve Çıktıları.....	53
Çizelge 3.4 : Beş Adım Kaydırmalı Girdi ve Çıktıları.....	53
Çizelge 3.5 : Ağ Yapısı Topolojisi Çizelgesi.....	54
Çizelge 3.6 : Ağ Eğitim Parametreleri.....	55
Çizelge 3.7 : Bir Özellikli YSA Modeli için RMSE ve Tahmin Değerleri.....	57
Çizelge 3.8 : Bir Özellikli YSA Modeli için Uydurulmuş (fitted) Değerler.....	57
Çizelge 3.9 : Beş Özellikli YSA Modeli için RMSE ve Tahmin Değerleri.....	58
Çizelge 3.10 : Beş Özellikli YSA Modeli için Uydurulmuş (fitted) Değerler.....	59
Çizelge 3.11 : YSA Karışıklık Matrisi.....	60
Çizelge 3.12 : ZSA Karışıklık Matrisi.....	61
Çizelge 3.13 : YSA Karışıklık Matrisi.....	61

KISALTMALAR

ACF	: Otokorelasyon Fonksiyon
ADF	: Geniřletilmiř Dickey Fuller Testi
AIC	: Akaike Bilgi Kriteri
ANFIS	: Adaptif Sinir Ađına Dayalı Bulanık ıkarım Sistemi
AR	: Otoresresif
ARMA	: Otoresresif ve Hareketli Ortalama
ARIMA	: Otoresresif Bütünleřik Hareketli Ortalama
BIC	: Bayesci Bilgi Kriteri
CTAF	: Düzeltilmiř Meydan Tahmini
KA	: ok Katmanlı Algılayıcı
DF	: Dickey Fuller Testi
ICAO	: Uluslararası Sivil Havacılık Kuruluřu
KNN	: En Yakın K Komřu
LSTM	: Uzun Kısa Süreli Hafıza
MA	: Hareketli Ortalama
MAE	: Ortalama Mutlak Hata
MAPE	: Ortalama Mutlak Yüzde Hata
MASE	: Ortalama Mutlak Ölekli Hata
ME	: Ortalama Hata
METAR	: Meydan Rutin Hava Raporu
MLR	: oklu Lineer Regresyon
MOS	: Model ıktı İstatistikleri
MPE	: Ortalama Yüzde Hata
MSE	: Hata Kareler Ortalaması
NGAFID	: Ulusal Genel Havacılık Uuř Bilgi Veritabanı
PACF	: Kısmi Otokorelasyon Fonksiyonu
RMSE	: Kök Ortalama Kare Hata
RTFA	: Radyal Tabanlı Fonksiyon Ađları
SARIMA	: Mevsimsel Otoresresif Bütünleřik Hareketli Ortalama
SC	: Schwarz Kriteri
TAF	: Meydan Tahmini
TSA	: Tekrarlayan Sinir Ađları
VAR	: Vektör Otoresresif
YGGA	: Yapay Sinir Ađları ile Güçlendirilmiř Genetik Algoritma
YSA	: Yapay Sinir Ađı
ZSA	: Zaman Serisi Analizi

SEMBOL LİSTESİ

Bu çalışmada kullanılmış olan simgeler açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklama
(Ω, U)	Olasılık uzayı
T	İndis kümesi (Genel olarak doğal sayılar kümesi)
$X_t (w)$ veya X_t	Zaman serisi
t	Zaman
p	AR modelinin derecesi (Geçmiş dönem gözlem sayısı)
q	MA modelinin derecesi
Y_t	Gözlem Değeri
β	Model parametresi
ε_t	Beyaz gürültü hata terimi
Φ	Aktivasyon fonksiyonu
A	Model parametresi
μ	Zaman serisinin beklenen değeri
d	Durağanlaştırma derecesi
X_m	Girdi değeri
W_m	Ağırlık değeri
B	Bias değeri
y	Çıktı Değerinet girdi
V	Net girdi
γ	Model parametresi

1. GİRİŞ

Uçak yönlendirmesi; uçağın, havayolu şirketinin zaman Çizelgesinde yayınladığı planlanmış varış noktası dışında, farklı bir havalimanına iniş yaptığı durumlar olarak adlandırılmaktadır (iata.org). Uçaklar, uçuş güvenliği (yangın / duman, mekanik arıza, doğal afet, güvenlik), operasyonel koşullar (yakıt sızıntısı, varış noktasındaki hava durumu, pist arızaları), ve hizmete ilişkin (medikal, azılı yolcular) sebepler dolayısıyla yönlendirilebilir.

Havayolu şirketleri için beklenmeyen yönlendirmelerinin en aza indirgenmesi, bu durumun sebep olduğu maliyetleri azaltma ve itibar kaybının önüne geçme konularında büyük önem arz etmektedir. Bu sebeple amaç; uçağın yönlendirilmesi durumunda havayolu şirketinin karşı karşıya kaldığı; uçuş zaman Çizelgesinin kayması, yolculara yeni biletlerin temin edilmesi, uçağın havada harcadığı yakıt, yolcuların konaklama ve sağlık harcamaları gibi maliyetleri en aza indirmektir. Bu çalışma kapsamında, varış noktasındaki hava durumunun güvenli inişe el vermemesi sebebi ile meydana gelen uçak yönlendirmeleri incelenecektir.

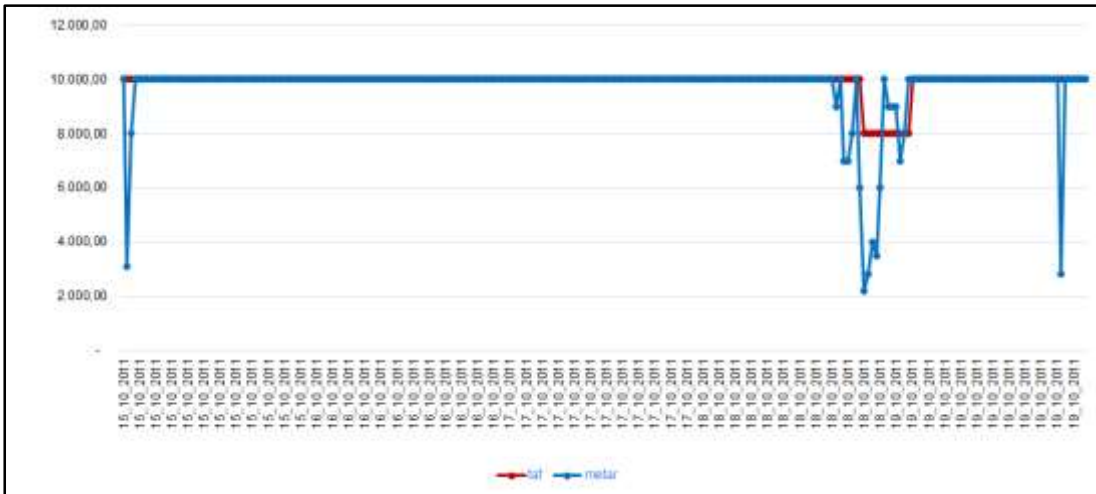
Yönlendirmelerin bir sonucu olarak ortaya çıkabilecek zaman ve mali kaynak kayıplarının azaltılması adına, uçak kalkmadan önce, uçağın ineceği bölgedeki meteorolojik değerlerin tahminlerinden yararlanarak uçuş kararı verilmektedir.

Bölgesel anlaşmalarla belirlenmiş düzenli aralıklarla (yarım veya bir saatlik) yayınlanan ve havalimanına ait hava durumu verilerini (görüş menzili, rüzgâr hızı, rüzgâr açısı, bulut tavan yüksekliği) içeren rapora, “Meydan Rutin Hava Raporu (METAR)” adı verilmektedir (hezarfen.mgm.gov.tr). Bir havalimanı için belirli aralıklarla yayınlanan (genellikle 9 ya da 24 saatlik), havalimanı ve civarında karşılaşılmaması öngörülen meteorolojik olayları içeren hava tahmin raporuna ise “Meydan Tahmini (TAF)” denir (hezarfen.mgm.gov.tr). TAF verileri incelenirken; görüş menzili, rüzgâr hızı, rüzgâr açısı, bulut tavan yüksekliği gibi etkenlerin, güvenli iniş için kabul edilen kısıtları sağlamaması durumunda, uçak havalanmadan önce kaldırma / kaldırmama veya uçuş sırasında indirip / indirmeme kararı alınır. Bu karara ve kararın sonuçlarına bağlı olarak

(TAF - METAR uyumsuzluğu), hava durumu verilerinin analizi ve hava durumu öngörme yöntemleri kullanılarak optimum kararın verilmesini sağlayacak bir karar destek sistemi ihtiyacı doğmuştur. Bu sebeple bu tezde, bu ihtiyaca yönelik bir karar destek sistemi çalışılmıştır.

Bu tezde, söz konusu havayolu şirketinin yurt içi uçuşlarından, Trabzon Havalimanı için, 2010-2018 yıllarına tekabül eden 130.000 satır (gözlem) METAR ve TAF verileri ile birlikte, aynı tarihler arasında meydana gelmiş 84 adet yönlendirilmiş uçuşa ait rapor, havayolu şirketi tarafından temin edilmiştir. METAR verilerinin TAF ile olan uyumu analiz edilmesi esnasında, uçak yönlendirmelerinin sağlanan meteorolojik veriler arasından en fazla (%90 oranında) görüş mesafesinden kaynaklı olduğu saptanmıştır. Programlamada kullanılan limit değerler, Uluslararası Sivil Havacılık Kuruluşu (ICAO) tarafından Trabzon ili için belirlenen standartlara (Uluslararası Sivil Havacılık Kuruluşu (ICAO) tarafından Trabzon ili için belirlenen bazı standartlar Görüş mesafesi > 1400 ft ve Bulut Tavan Yüksekliği > 386 ft) göre belirlenmiştir.

Daha önce sözü geçen yönlendirilmiş 84 uçuştan birinin uçuş anını da içinde bulunduran zaman aralığı için METAR ve TAF verileri, örnek teşkil etmesi açısından Şekil 1.1'de gösterilmiştir. 16.10.2011 - 19.10.2011 tarihleri arasında, görüş mesafesinin gerçek değerleri, tahmin değerleri ile karşılaştırıldığında, METAR ve TAF arasında fark olduğu gözlenmiştir. Buna ek olarak, TAF verilerinin, görüş mesafesinde yönlendirme kararını etkileyebilecek ani değişimleri öngörmede etkin sonuçlar vermediği sonucuna varılabilir.



Şekil 1.1: Örnek bir uçuş için METAR - TAF uyumu

TAF - METAR uyumsuzluğundan hareketle, görüş mesafesinde yaşanan ani değişimleri öngörebilmek ve yönlendirme kararını daha verimli bir şekilde verebilmek için, tezin ilk kısmında, zaman serileri metodu kullanılmıştır. R programlama dilinde, zaman serileri tahmin yöntemlerinden AR, MA, ARMA, ARIMA ve VAR kullanılarak ileriye dönük 6 adım seviyesinde (Geleceğe dönük 6 adım seviyesindeki öngörünün sebebi; Trabzon'dan Türkiye'nin herhangi bir noktasına en fazla 3 saatte gidebileceği öngörülmüştür, kullanılan METAR ve TAF verilerinin yarım saat arayla geldiği göz önüne alındığında ileriye dönük 6 adımlık bir öngörünün bir uçuş için yeterli olacağı düşünülmüştür). TAF öngörülleri yapılmış, her bir yöntemin sonucuna bağlı olarak hata fonksiyonları karşılaştırılmıştır. Hali hazırdaki TAF ile karışmaması için öngörülen değerlere CTAF (Corrected TAF- Düzeltilmiş TAF) ismi verilmiştir.

Çalışmanın ikinci bölümünde, zaman serileri yöntemi ile aynı koşullarda, MATLAB programlama dili kullanılarak oluşturulan uzun / kısa süreli hafızaya sahip ağ ile elde edilen meteorolojik verilerin tahminleri, zaman serisi analizi sonuçları ile karşılaştırılmıştır.

1.1 Tezin Amacı

Tezin amacı, havayolu şirketinin beklenmedik uçuş yönlendirmeleri sonucunda ortaya çıkan beklenmedik maliyetleri en aza indirmektir. Bu amaca yönelik olarak iki farklı karar destek sistemi geliştirilmiştir. İlk sistemde, beklenmedik uçak yönlendirmelerini azaltmak amacı doğrultusunda, meteorolojik verilerin tahminini yapmak için zaman serisi analizi kullanılmıştır. İkinci sistemde ise, yapay sinir ağları (YSA) yöntemi kullanılarak analiz yapılmıştır. Bu iki sistemde ortak amaç, meteorolojik verilerin geçmişe dönük analizini yaparak, geleceğe yönelik tahminlerde bulunmaktır; böylece, doğru uçuş kararının verilmesine destek olacak bir sistem tasarlanmasıdır. 2010 – 2018 yılları arasında gerçekleşen 84 adet yönlendirilmiş uçuş üzerinde, her iki sistem çıktıları kullanılarak karar doğrulukları incelenmiştir. Sonucunda elde edilen tahminlerin elde edilen iyileştirme oranı, YSA kullanılarak kurulan sistemin başarı oranı daha da iyileştirilmiştir.

ve maksimum sıcaklığı tahmin etmek için 40 yıllık veri üzerinde test gerçekleştirmiştir. Hata kareler ortalamasına (MSE) dayanan sonuçlar, bu modelin hava tahmini için başarılı bir uygulama potansiyeline sahip olduğunu göstermiştir.

Nury ve diğerleri çalışmalarında, Kuzeydoğu Bangladeş'teki Syiret ve Mouluibazar bölgelerinde, aylık minimum ve maksimum sıcaklıkların kısa vadeli tahminlerini yapmak için, ARIMA modeli kullanmışlardır. 1977-2011 yılları arasında Sylhet bölgesinde iki istasyonda kaydedilen sıcaklıklar ile model eğitilmiş, doğrulama işlemi ise 2010-2012 dönemi için yapılmıştır. ARIMA modelleri kullanılarak, 2010-2011 yılları özelinde 2 istasyondaki sıcaklıkların 1 ay sonrası için tahminleri gerçekleştirilmiştir (Nury ve diğerleri 2013).

Tortum ve diğerleri, tek değişkenli zaman serileri analizlerinde kullanılan ARIMA modellerini kullanarak, havayolu ulaşımının 1991–2008 yılları arasındaki dinamiklerinden hareketle, 2009 yılı için aylık yolcu sayılarını tahmin etmişlerdir. Modelden elde edilen tahmin değerleri, aylık yolculuk sayılarını yakınsama eğiliminde olduğu sonucuna ulaşmıştır (Tortum ve diğerleri 2014).

Janiszewski ve Wojtowicz'in çalışmalarında, Oslo Havalimanı'nda yolcu trafiğini tahmin etmek için, SARIMA modeli kullanılmıştır. Seçilen modelin parametreleri GRETL yazılımı kullanılarak maksimum olabilirlik metodu ile tahmin edilmiştir. SARIMA modelinin makul sonuçlar verdiği ve yolcu trafiğini tahmin etmede uygulanabileceği sonucuna varılmıştır (Janiszewski ve Wojtowicz 2014).

Radziukynas ve Klementavicius, zaman serileri yaklaşımını kullanarak Litvanya rüzgâr çiftliği için rüzgâr hızının kısa vadeli tahminini ele almışlardır. Tarihsel rüzgâr hızı verileri (4 ay), ARIMA modeline uygulanarak, tahmin sonuçları sunulmuştur. Tahminlerin doğruluğunu hesaplamada, kök ortalama kare hata (RMSE) ve mutlak hata kullanılmıştır (Radziukynas ve Klementavicius 2014).

Medar ve diğerlerinin çalışmalarında ise, Veri Madenciliği, Regresyon Yaklaşımları ve Yapay Sinir Ağları yöntemleri kullanılarak hava parametreleri tahmin edilmiş ve sonuçlar karşılaştırılmıştır (Medar ve diğerleri 2017).

Kırbaş'ın çalışmasında ise, bir meteoroloji istasyonunun 2016 Nisan ayı içerisinde yaptığı gözlem sonuçları derlenmiştir. Elde edilen rüzgâr hızı verileri, istatistiksel metotlar ve YSA kullanılarak incelenmiştir. Oluşturulan zaman serisi üzerinden ileriye yönelik rüzgâr hızı kestiriminde bulunulmuştur. Yapılan hesaplama ve hesaplamaların gerçek veriler ile kıyaslanması sonucunda, incelen ARIMA modelleri ve yapay sinir

1.2 Literatür Araştırması

Literatürde zaman serileri analizleri yöntemlerine ilişkin birçok çalışmaya rastlanmıştır.

Paras ve diğerleri, çalışmalarında hava tahmini için basit bir model kurmuşlardır. Kullanılan model çoklu doğrusal regresyon (MLR) modelidir. Belirli bir istasyondaki hava durumu verileri, minimum - maksimum sıcaklık, bağıl nem gibi hava parametreleri farklı zaman aralıklarında hava durumu veri setindeki korelasyon değerine bağlı olarak hesaplanan özellikler kullanılarak tahmin edilmiştir. Regresyon denklemleri katsayıları, gelecekteki hava koşullarını tahmin etmek için kullanılmıştır. Elde edilen sonuçlar, MLR modelinin hava koşullarını tahmin etmede kullanılabileceğini göstermektedir (Paras ve diğerleri, 2012).

Sfetsos çalışmasında, zaman serisi analizi kullanarak, saatlik ortalama rüzgâr hızı ve rüzgâr yönü üzerinde çeşitli tahmin yaklaşımlarının karşılaştırması sunulmuştur. Geleneksel doğrusal ARMA modellerine ve Yapay Sinir Ağlarına ek olarak, Adaptif Sinir Ağına Dayalı Bulanık Çıkarım Sistemi (ANFIS) ile en az hataya sahip olan model oluşturulmuştur (Sfetsos 2000).

Wu'nun çalışmasında, rüzgâr hızı ve gücü ile ilgili çeşitli tahmin yönleri vurgulanmıştır. Geçmiş zaman verilerinden (METAR) yararlanarak, TAF öngörüsü yapmak için ilk olarak en temel tahminleme yöntemi olan Regresyon Analizi ile birlikte, gelişmiş ve öğrenen bir yöntem olan yapay sinir ağlarından yararlanılmıştır (Wu 2007).

Bir başka çalışmada ise, SARIMA yaklaşımı kullanılarak, mevsimsel modelleme ve Sokoto aylık ortalama sıcaklığı için tahminleme sonuçları elde edilmiştir. Model seçim kriterleri kullanılarak beş mevsimsel model seçilmiştir. Seçilen modeller, sıcaklık tahmininde öngörülerin hata kareler ortalaması istatistiklerini en aza indirmiştir (Yukubu ve Gulumbe 2008).

Bahadır ve Saraçlı'nın çalışmalarında, sıcaklık, yağış ve buharlaşma parametreleri ARIMA (Box-Jenkins) modeli kullanılarak analiz edilmiştir. ARIMA modeli ile yapılan analizler sonucunda Isparta'da gelecek 5 yıl için, iklimde daha nemli bir döneme girileceği, yörenin küresel ısınma senaryolarından fazla etkilenmeyeceği ve bölgede kuraklığın etkili olmayacağı sonucuna ulaşılmıştır (Bahadır ve Saraçlı 2010).

Agrawal ve diğerleri, çalışmalarında iki önemli hava parametresini (minimum ve maksimum sıcaklık) tahmin etmek için MATLAB kullanılarak oluşturulan Yapay Sinir Ağı modelini sunmuşlardır. Model, 60 yıllık veriyi (1901-1960) eğiterek ve minimum

ağları arasında, YSA metodunu öne geçiren, belirgin hata oranı farkı olduğu görülmüştür. Önerilen çalışmada sık kullanılan tahmin metotlarının ileriye dönük 12 adım seviyesinde ayrıntılı değerlendirmeleri gerçekleştirilmiştir (Kırbaş 2018).

Literatürde geçmiş zaman verilerinden “öğrenerek” gelecek ile ilgili öngörülebilir bulunan YSA tabanlı birçok yöntem benzer girdilere sahip birçok problem için kullanılmıştır.

Camargo ve diğerleri yaptıkları çalışmada veri madenciliği ve bulanık mantık kullanılan hava radarları tarafından ölçülen verilerin analizine odaklanılmıştır. Bu çalışma neticesinde yapay sinir ağlarının hatalı bilgiyi ortadan kaldıran ve daha sonra standarda göre normalleştiren mükemmel bir araç olduğunu gösterilmiştir (Camargo J.R. ve diğ., 2018).

Mccann çalışmasında önemli sinir ağlarını detaylı bir şekilde incelemiş ve ardından sinir ağı tahminlerinin operasyonel meteoroloji üzerindeki potansiyel etkisi üzerinde çıkarımlarda bulunmuştur (Mccann, D.W., 1992).

Hacıoğlu çalışmasında, YSA ile Güçlendirilmiş Genetik Algoritmanın (YGGA) mühendislik üzerindeki en iyileme çalışmalarındaki uygulanışı üzerinde önerilerde bulunmuş YSA tekniği olarak Radyal Tabanlı Fonksiyon Ağları (RTFA)’dan faydalanılmıştır. Bu süreçte yöntemin, eniyileme algoritmalarının test edilmesinde kullanılan değişik model fonksiyonlar üzerindeki etkinliği araştırılmıştır (Hacıoğlu A., 2006).

Trani ve diğerleri, çalışmada uçak performans el kitabında verilen veriler kullanılarak temsili bir sinir ağı destekli yakıt tüketimi modeli geliştirilmiştir. Sinir ağı, örnek bir uçağın yakıt tüketimini tahmin etmek için eğitilmiştir. Doğrusal olmayan transfer fonksiyonlarına sahip üç katmanlı bir YSA’nın, tırmanma, seyir ve iniş aşamaları için karmaşık uçak yakıt tüketim fonksiyonlarını doğru şekilde gösterdiği sonucuna ulaşılmıştır (Trani A., ve diğ., 2004).

Blinova, hava yolcu taşımacılığı pazarını tahmin etmek için çoklu regresyon ve yerçekimi modelleri kullanmıştır. Ancak bu modeller hava taşımacılığı ağındaki topoloji değişim sürecini, ilgili yolcu trafiği akışlarının yapısındaki gelişimi veya yolcu trafiği akışlarının birbirine bağımlılığını dikkate almamaktadır. Blinova araştırmasında, Rus hava taşımacılığı ağının kısa vadeli tahminleri için kullanılacak bir sinir ağı yaklaşımı modelleme olasılığını analiz etmiş ve Rusya’da bölgeler arası yolcu trafiği akışının gelişimini öngören bir sinir ağı modeli tasarlamıştır (Blinova T.O., 2007).

YSA'ları hava tahminlerinde de oldukça fazla kullanılan bir yöntemdir. Özellikle sis oluşumu hava taşımacılığı işlemlerini önemli ölçüde etkileyebilir ve havacılık güvenliğinde önemli bir rol oynamaktadır Sayısal hava durumu tahmin rehberindeki ve sis fenomeninin modellenmesinde ki gelişmelere rağmen, sis tahmini oldukça zor bir alandır. Bu nedenle bu tahminlerin YSA'ları ile yapılması üzerinde bilimsel anlamda çalışmalar geliştirmektedir.

Bu çalışmalara örnek olarak, Weatherford ve diğ nin çalışması havayolu endüstrisine uygulanan sinir ağı tahmin tekniği hakkında yayınlanan ilk araştırma makalesidir Uygulanan yeni yöntem geleneksel tahmin teknikleriyle (hareketli ortalamalar, üssel düzeltme, regresyon vb.) karşılaştırılmış ve en temel sinir ağı yapılarının bile geleneksel tahmin yöntemlerinden daha iyi tahminler ürettiği sonucuna ulaşılmıştır (Weatherford L.R. ve diğ, 2002).

Kıskac ve Yardımcı, En Yakın K Komşu (KNN) algoritması, Bulanık Mantık ve YSA uygulaması performans karşılaştırmaları ile Yerel Hava Üssü'deki kısa vadeli hava tahmin uygulaması hakkında genel bir çalışma yapılmıştır. Bu çalışma hava tahmin uzmanlığı sistemleriyle ilgili tüm literatürleri ele alırken temel olarak yerel ve kısa vadeli tahminlere odaklanılmıştır (Kıskac ve Yardımcı H., 2004).

Murayziq ve diğ erleri, toz fırtınası olaylarının, potansiyel toz etkisini azaltmak için olası eylemlerin yanı sıra yeni toz fırtınalarının tahmininde nasıl yardımcı olabileceğini açıklamaktadır. Bu kavramı göstermek için, vaka temelli akıl yürütme ve YSA'larının bir kombinasyonu kullanılarak, karma bir yaklaşım önerilmiştir. Yaklaşımın vaka temelli muhakemenin başarılı tahminlerde ve aşırı hava tahminlerinin olası azaltılmasında kullanılma potansiyeli olduğunu ortaya koymaktadır (Murayziq T.S. ve diğ., 2017).

Desell ve diğ erleri çalışmalarında, Ulusal Genel Havacılık Uçuş Bilgi Veritabanı'dan (NGAFID) alınan verileri kullanarak sağlam veri parametrelerinin öngörülmesi için yapılan ilk çalışmadır. Yapılan bu incelemede cden seçilen beş alan ağırlıkların çeşitli sinir ağlarına geri yayılma ve diferansiyel evrimini kullanarak eğitimi konusunda titiz bir çalışmayı içermektedir (Desell T. ve diğ., 2014).

Fabban ve Dear bu çalışmalarında YSA'larının Canberra Uluslararası Havaalanında sis oluşumunu doğru tahmin etme yeteneğini değerlendirmişlerdir. Bu süreçte Avusturya Meteoroloji Bürosu'ndan elde edilen 44 yıllık standart meteorolojik gözlemler

veri tabanından destek olarak çeşitli YSA'larının mimarilerinin tahmin etme yeteneğinin göreceli çalışma karakteristiği eğrileri analiz edilmekte ve değerlendirilmektedir (Fabbian, D. ve Dear, R., 2005).

Marzbans ve diğerleri, çalışmalarında ise tavan ve görünürlük tahmini için doğrusal olmayan post-işlemcilerin gelişimi ele alınmış. Tahmin süresi, saatlik yüzey gözlemlerinden ve beşinci nesil Pennsylvania Eyalet Üniversitesi Ulusal Atmosferik Araştırma Mesoscale Modelinden elde edilen veriler kullanılarak elde edilmiş ve 39 sinir ağı yapısı kullanılmış ve sinir ağlarının performansının genellikle lojistik regresyon ve Model Çıktı İstatistikleri'nden (MOS) daha üstün olduğu gözlemlenmiştir (Marzbans, C. ve diğ., 2006). Literatürdeki çalışmalardan yola çıkarak, çalışmanın bir sonraki bölümünde, oluşturulmuş model sunulmuştur.



2. ZAMAN SERİSİ ANALİZİ

2.1 Amaç

Tezin bu kısmında, bir havayolu şirketinin beklenmeyen yönlendirmelerinin sebep olduğu maliyetlerin en aza indirgenmesi amacı ile bir karar destek sistemi tasarlanmıştır. Söz konusu havayolu şirketi tarafından temin edilen meteorolojik veriler ışığında R programlama dili kullanılarak, görüş mesafesini öngörmek amacı ile yapılan analizlerin sonuçları sunulmuştur. Verilerin zaman serisi analiz yöntemleri kullanılarak incelenmesi ile öngörülerde bulunmak amaçlanmıştır. İleriye dönük 3 saate karşılık gelecek şekilde ayrıntılı değerlendirme gerçekleştirilmiştir. Zaman serisi analizlerinden AR, MA, ARMA, ARIMA, Auto.ARIMA ve VAR kullanılarak elde edilen sonuçlar, hata oranı fonksiyonlarına göre karşılaştırılmıştır.

2.2 Zaman Serisi Analizi Yöntemleri

Zaman serisi, herhangi bir olaya ilişkin gözlem değerlerinin zamana göre sıralanmasıyla oluşturulan dizilerdir. Zaman serileri analizi ise, belirli zaman aralıklarında gözlenen bir olay hakkında, gözlenen serinin yapısını veren stokastik süreci modellemeyi ve geçmiş dönemlere ilişkin gözlem değerleri yardımıyla geleceğe yönelik tahminler yapmayı amaçlayan bir metottür (Kaynar ve Taştan 2009). Bir başka ifade ile zaman serisi analizinde gelecekteki verilerin geçmişteki veriler ile benzer davranışlar sergileyeceği varsayımı göz önünde bulundurularak geçmiş değerden gelecek değerler öngörülmeğe çalışılır.

Bir zaman serisinin tanımı ise tam olarak şu şekilde verilebilir: (Ω, U) bir olasılık uzayı, T 'de bir indis kümesi (genel olarak doğal sayılar kümesi) olmak üzere, bir zaman serisi $\Omega \times T$ çarpım uzayından reel sayılara giden bir fonksiyondur.

Yani bir zaman serisi;

$$\begin{aligned} X(.,.): \Omega \times T &\rightarrow IR \\ (w, t) &\rightarrow X(w, t) \end{aligned} \tag{2.1}$$

olarak tanımlanabilir. Zaman serisi bazen, $X_t(w)$ bazen de sadece X_t ile gösterilebilir (Akdi 2013).


Box-Jenkins, bir zaman serisini, ardışık olarak üretilmiş bir grup gözlemi olarak tanımlamaktadır (Box-Jenkins, 1976). Bir başka ifade ile zaman serileri, değişkenin farklı zaman aralıklarında gözlemlenen değerler kümesini ifade eder yani bir serinin zaman içindeki davranışlarını gözlemler. Değişkenlerle ilişkili değerler günlük, haftalık, aylık, yıllık... vb. olabilir.

Bir zaman serisi tek değişkenin zaman içindeki değişimini gözlemliyor ise tek değişkenli zaman serisi, birden çok değişkenin zaman içindeki davranışlarını inceliyorsa çok değişkenli zaman serisi adını alır. Zaman serilerinin temel amaçları istatistiksel ya da grafiksel yöntemler ile verilerin özetlenmesi ve incelenmesine ek olarak, serinin gelecekte alabileceği değerlerin tahmin edilmesi için veriyi açıklayarak uygun bir model oluşturmaktır. Zaman serilerine örnek olarak, kronolojik sıra ile elde edilen verilere sahip değişkenler verilebilir.


Zaman serilerinin gözlemlenen değerleri arasında artma, azalma ya da belirli dönemlerde sabit kalma gibi durumlar gözlemlenebilir. Bu gibi durumların çeşitli sebepleri olabilir. Söz konusu değişimlerin incelenmesi, öngörü yapılmak istendiğinde yani zaman serisi verilerinin geleceği ile ilgili tahmin yapılmak istendiğinde fayda sağlar çünkü zaman serileri gelecekte de benzer özellikler gösterebilir. Bu değişimler zaman serilerinin bileşenleri olan; trend, mevsimsel değişimler, konjüktürel (döngüsel, çevrimsel) ve rassal değişimler olarak dört grupta incelenir.

Mevsimsel, döngüsel veya düzensiz dalgalanmaları tam olarak yok etmek güç olsa da, belirli bir düzeyde düzleştirme (smooth) amacıyla çeşitli yöntemlere başvurulur. İlerleyen bölümlerde bu yöntemlerden bahsedilecektir.

Çalışma kapsamında kullanılan veri seti üzerinde düzleştirme işlemi, haftalık, günlük, saatlik zaman dilimleri için yapılmış olup, gerçek verinin her yarım saatte bir geldiği de göz önünde bulundurularak saatlik düzleştirmenin veri seti için en uygun seçenek olduğu saptanmıştır. Düzleştirme işleminde esas olan, veri setinin eğilimini (trendini) kaybetmeden uç değerlerden (outlier) kurtulmaktır. Bu doğrultuda gerçek veri seti Şekil 2.1’de, veri setine uygulanmış ve belirtilen zaman dilimlerine ait düzleştirme işlemi Şekil 2.2’de verilmiştir (düzleştirme işlemi 130.000 veriye uygulanış olup, Şekil 2.1’de gerçek veri setinin son 500 verisi Şekil 2.2’te ise son 500 veriye ait düzleştirme işlemi gösterilmektedir).



Şekil 2.1: Gerçek Veri Setinin Son 500 Verisi



Şekil 2.2: Düzleştirme Uygulanmış Veri Setinden Bir Kesit

2.2.1 Box-Jenkins tahmin yöntemleri

Zaman serisi modelleri, Box-Jenkins tahminleme modelleri olarak da anılmaktadır. Bu modeller, durağan zaman serileri ve durağan olmayan zaman serileri başlıkları altında incelenmektedir. Box-Jenkins modelleri, zamana bağlı olayların rastlantısal özellik gösterdiğini ve bu olaylara bağlı zaman serisinin stokastik süreç olduğu varsayımına dayanmaktadır (Kutlar 2000).

Zaman serisinin durağan olduğu, yani sürecin ortalamasının, varyansının ve kovaryansının zamana bağlı olarak değişmediği durumlarda daha sonra bahsedilecek olan zaman serisi modellerinden uygun olanlar kullanılmaktadır. Ancak zaman serilerinin çoğu, zaman boyunca değişen belirli bir stokastik sürecin özelliklerini taşıması nedeniyle durağan değildir (Pindyck and Rubinfeld 1998).

Zaman serileri, ortalamada gösterdiği sapmalara göre, durağan ve durağan olmayan seriler olarak iki başlık altında incelenir. Durağan olmayan zaman serilerine Box Jenkins yönteminin uygulanabilmesi için önce durağanlığı bozan, trend ve mevsimsellik gibi unsurların bazı dönüşüm yöntemleriyle ortadan kaldırılması, böylece serinin durağan hale getirilmesi gerekir (Özmen, 1986).

Bir zaman serisinin istatistiksel analizi yapılmadan önce, o seriyi yaratan sürecin durağanlığının araştırılması gerekmektedir.

2.2.2 Durağan zaman serileri

Zaman serilerinde en önemli kavramlardan biri durağanlık kavramıdır. Genellikle serinin durağanlığı bir varsayım olarak karşımıza çıkmaktadır. Hemen hemen bütün istatistiksel çıkarımlar serinin durağanlığı varsayımı altında yapılır (Akdi 2010:3). İncelenen zaman serisinin ortalaması ve varyansı simetrik bir değişim gösteriyorsa veya seri periyodik dalgalanmalardan arınmış ise bu tür seriler, durağan zaman serileridir. Özer ve diğerleri, ortalama ile varyansın zaman içinde değişmediği ve iki dönem arasındaki kovaryansın, hesaplandığı döneme değil, yalnızca iki dönem arasındaki uzaklığa bağlı olan olasılıklı süreçleri durağan olarak tanımlamaktadır (Özer ve diğerleri, 2013). Başka bir ifade ile bir zaman serisinin durağan olması, zaman içerisinde belli bir değere doğru yaklaşması, yani, sabit bir ortalama, sabit bir varyans ve gecikme seviyesine bağlı kovaryansa sahip olmasıdır (Akgül, 2003:43).

Bir stokastik sürecin durağan olmaması, serinin davranışını sadece ele alınan dönem için geçerli kılar ve seri hakkında diğer dönemler için bir genelleme yapmamızı güçleştirir. Bu sebeple, zaman serilerinde durağanlık, üzerinde durulması gereken en önemli özelliklerden biridir. Buna ek olarak, klasik regresyon modeli durağan değişkenler arasındaki ilişkilerde kullanılmak için ortaya çıkarılmıştır, bu nedenle durağan olmayan serilerde kullanılmamalıdır (Gujarati, 2005:709). Regresyon denklemindeki açıklayıcı değişkenlerin herhangi birisinin durağan olmaması neticesinde regresyon teorisinin bozulması, durağanlığın aslında bir gereklilik olduğunu göstermektedir.

2.2.3 Durağan olmayan zaman serileri

Bir zaman serisinin beklenen değeri, varyansı ve kovaryansı zaman içerisinde sabit kalmıyor (zamana bağlı olarak değişiyorsa) ise seri durağan değildir. Seri durağan değilse, ancak çeşitli teknikler kullanılarak durağan hale geldikten sonra analizler yapılır. Birçok iktisadi veri (özellikle parasal veriler) durağan değildir.

Durağan olmayan zaman serilerini de iki kısımda incelemek gerekir. Pratikte durağanlığı bozan başlıca iki neden vardır:

- Serinin ortalaması zamana bağlı olabilir; yani seri deterministik bir trend içerebilir.
- Serinin otokorelasyonu zamana bağlı olabilir.

Trend deterministik ise (ortalaması zamana bağlı ise) bu trendi yok etmek kolaydır. Diğer durumda ise, serideki trend stokastik olup, trendin ortadan kaldırılabilmesi için bazı teknikler (dönüşüm yapmak, fark almak gibi) kullanılır. Onun için serideki trendin deterministik mi yoksa stokastik mi olduğu önceden kontrol edilmelidir (Akdi 2013).

Eğer bir seri durağan değilse, beklenen değer veya varyansının ya da her ikisinin birden zamanla değişiyor olması, serinin davranışını sadece incelenen tahmin dönemi için geçerli kılar. Bu sebeple, durağan olmayan bir zaman serisinin durağan hale getirilmesi büyük önem taşır. Durağan olmayan bir zaman serisi, bir ya da daha fazla dereceden fark alma işlemi uygulanarak durağan hale getirilir.

2.2.4 Zaman serilerinde durağanlığın belirlenmesi

Durağanlığın tespitinde kullanılan yöntemler literatürde klasik ve modern olmak üzere ikiye ayrılır. Klasik yöntemler durağanlığın tespiti için serilerin grafikleri ile otokorelasyon (ACF) ve kısmi otokorelasyon (PACF) grafiklerinden oluşan korelogramlardan sezgisel olarak faydalanır. Modern yöntemler ise, Dickey Fuller Testi gibi matematiksel testleri içerir.

2.2.4.1 Klasik yöntemler ile durağanlığın belirlenmesi

Durağanlığı grafik yöntemi ile tespit etmek için serinin düzey ve farklarının grafikleri incelenir, böylelikle seride trend ya da mevsimsellik olup olmadığı, eğer varsa deterministik ya da rassal olup olmadığı tespit edilmeye çalışılır. Korelogram, otokorelasyon (ACF) ve kısmi otokorelasyon (PACF) fonksiyonlarının çizilmesiyle elde edilir.

Otokorelasyon fonksiyonu (ACF); otokorelasyon katsayıları bir zaman serisinin farklı dönemlerdeki gözlem değerleri arasındaki ilişkinin gücünü ifade etmektedir. Bu katsayının yüksek olması değişkenin geçmiş dönem değerlerine bağımlı olduğunu, düşük olması ise değişkenin tesadüfi olduğunu göstermektedir (Göktaş, 2005). Başka bir deyişle, bir seride bağımsızlığın göstergesi olarak otokorelasyon fonksiyonu (ACF), gözlem değerleri arasındaki korelasyonu göstermektedir.

Bir stokastik süreci tam anlamıyla tanımlamak mümkün olmadığından dolayı, süreci kısmen tanımlayan otokorelasyon fonksiyonu, model oluşturma sürecinde önemli bir yere sahiptir. Otokorelasyon fonksiyonu bir dizideki komşu veri noktalar arasındaki korelasyonun derecesi bilgisini verir.

Tüm gecikmelerden oluşan zaman serileri ve orijinal zaman serisi aynı grafikte çizilir ve bu grafik yardımıyla gecikmelerden oluşan zaman serilerinin orijinal zaman serisi ile benzer yapıya sahip olduğu görülür. Bir sonraki adımda, Otokorelasyon katsayılarının değerleri hesaplanır.


Kısmi otokorelasyon fonksiyonu (PACF); kısmi korelasyon fonksiyonu regresyon analizinden bilindiği gibi diğer değişkenler sabitken iki değişken arasındaki ilişkiyi verir. Kısmi otokorelasyon katsayıları da benzer şekilde zaman serilerinin, diğer gecikmeli serilerin etkileri ihmal edilerek ilgili gecikmeye ait zaman serisi ile arasındaki ilişkidir (Ünsal, 2010).

Bütün gecikmelere ait kısmi otokorelasyon katsayı değerleri kısmi otokorelasyon fonksiyonunu oluşturur. Zaman serileri analizinde otoregresif modelin kaçınıcı dereceye kadar devam edeceğini belirlemek için kısmi otokorelasyon katsayısı kullanılır. Başka bir ifade ile, kısmi korelasyon fonksiyonu gecikmeli değişkenler arasındaki ilişkiyi ifade eder.

2.2.4.2 Modern yöntemler ile durağanlığın belirlenmesi

Dickey ve Fuller (1981) çalışmasında geliştirdiği, bağımlı değişkenin gecikmeli değerleri açıklayıcı değişken olarak kullanılarak oluşturulmuş olan birim kök testlerinden “Genişletilmiş Dickey Fuller Testi”nden (ADF) yararlanılması izlenecek adımlardandır. Bu teste durağanlık yok hipotezi, otoregresif sürecin bir birim kök içermesi ve denklemdeki otoregresif katsayıların toplamının “1”e eşit olması olarak ifade edilir (Göktaş, 2005).

Çalışma kapsamında kullanılan veri seti, sezgisel olarak Şekil 2.3'teki ACF ve PACF grafiklerinden de anlaşılacağı üzere, herhangi bir durağanlaştırma işlemi uygulanmadan da zaten durağandır.



Şekil 2.3: Modele ait ACF ve PACF Grafikleri

Ancak; klasik yöntemlerin günümüzde yerini modern yöntemlere bırakması ile daha önce de bahsedildiği üzere çeşitli testleri bünyesinde barındıran modern yöntemler daha güvenilir bulunmaktadır. Bu doğrultuda, veri seti durağanlığı analiz edilirken, korelogramlarda veri setinin durağan olduğu çok net bir şekilde görülmesine rağmen, R Programlama dili yardımıyla, Dickey Fuller Testinden (DF) de yararlanılmıştır. Sonuç olarak analizlerini yapacağımız veri setinin durağan olduğu bilinerek, modellemelere geçilebilir.

2.2.5 Zaman serisi modelleri

Zaman serisi modelleri kullanılırken tüm zaman serilerinin durağan olduğu varsayılır ve bu varsayımlar ışığında beklenen değer, varyans, otokorelasyon gibi kavramlar hesaplanır. Herhangi bir zaman serisinin durağan olabilmesi için ortalaması, varyansı, kovaryansı ve daha yüksek dereceden momentlerinin zamana göre sabit olması gerekmektedir. Eğer model durağan değilse dizinin durağanlaştırılması gerekir. (Box and Jenkins, 1976). Zaman serisi analizinin ilk kısmında, tek değişkenli -doğrusal- durağan

zaman serileri ele alınacaktır. Zaman serileri modelleri üç genel sınıfa ayrılabilir. Otoregresif Süreç (AR) modelleri Yule (1926, 1927), Hareketli Ortalama (MA) modelleri Slutsky (1937) ve ARMA modelleri Wold (1954) tarafından geliştirilmiştir (Makridakis ve Wheelwright, 1989). Bu modellere ek olarak otoregresif bütünleşik hareketi ortalama modeli (ARIMA) uygulanmıştır. Zaman serisi analizinin ikinci kısmında ise, çok değişkenli doğrusal olmayan zaman serilerinden vektör otoregresif (VAR) modeli ele alınacaktır.

Aşağıda belirtilen her bir zaman serisi modeli için, yönlendirilmiş uçuş listesinden seçilen bir uçuşun sonuçları, örnek olması amacı ile sunulacaktır. Listedeki diğer uçuşlar için doğruluk ve model sonuçları değişiklik göstermektedir; bu sebeple sunulacak örnek, tüm listedeki uçuşların temsilcisi olarak değerlendirilmemelidir. Seçilen uçuş, 18.10.2011 tarihinde 20:20'de kalkarak, görüş mesafesi düşüklüğü sebebi ile yönlendirilen bir uçuştur. Uçuş saatine kadar kaydedilen METAR verilerinin bilindiği varsayılarak, uçuş saatinden itibaren 6 adım ilerisi için görüş mesafesi parametresi öngörülecek ve sonuçlar grafik formatında sunulacaktır. Yönlendirme listesindeki tüm uçuşlar için kurulan modellerin doğruluk kriterleri ve karşılaştırmalarına, 3.4 bölümünde yer verilecektir.

2.2.5.1 Otoregresif süreç modeli - AR(p)

Otoregresif modeller (ardaşık bağımlı modeller), zaman serilerinin geçmiş değerlerinin kullanılmasıyla gelecek değerlerinin tahmin edildiği modeller olarak tanımlanabilir. Birçok zaman serisi bu süreci içermektedir (Özer ve diğerleri, 2013).

Ardaşık bağımlı modellerde, Y_t 'nin t dönemindeki değeri, bir önceki dönemdeki değer ve rastsal hata terimine bağlıdır.

Parametrelerden otoregresif süreç olan Y_t serisi, artık terim ile Y_t değerlerinin p dönem geriye giden ağırlıklı ortalamasının toplamına eşittir.

(2.2)

$$Y_t = m + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \mathcal{E}_t$$

* β = model parametresi

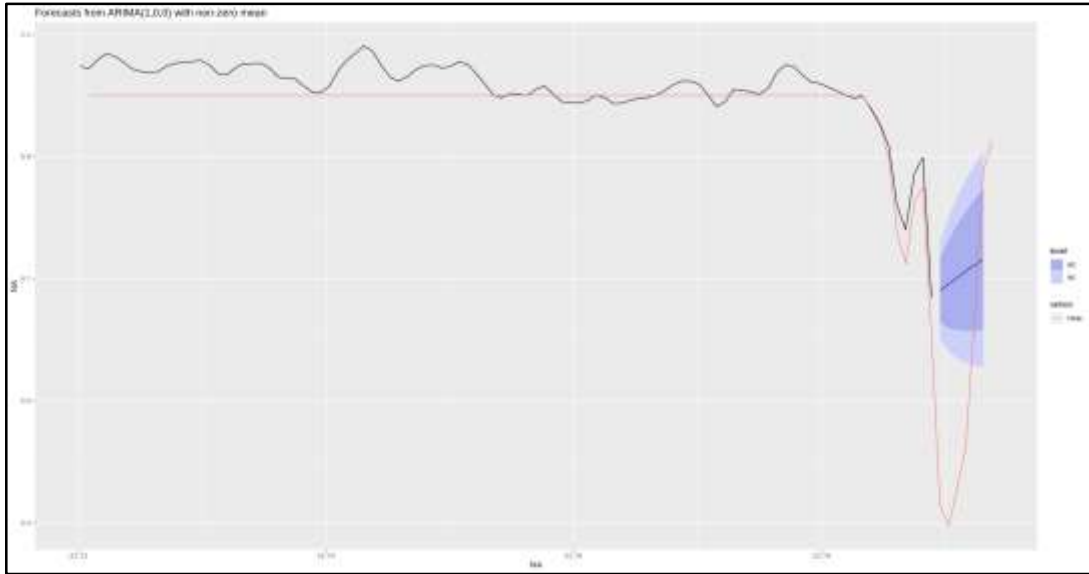
* \mathcal{E}_t = beyaz gürültü hata terimi

* m =stokastik sürecin ortalaması

Otoregresif süreç durağan ise ortalama (m) zamandan bağımsız olarak sabit kalır.

AR(p) süreci standart çoklu regresyon denkleminde benzerdir. Bu benzetimde Y_t bağımlı değişkendir. $Y_{t-1}, Y_{t-2}, \dots, Y_{t-1}, Y_{t-p}$, bağımsız değişkenler olarak düşünülür. Böylece otoregresif model için herhangi bir zaman serisinin t zaman değerinin $t - 1, t - 2, \dots, t - p$ zaman değerleri ile çoklu regresyon olduğu söylenir ancak otoregresif modelde çoklu regresyondan farklı olarak bağımsız değişkenler arasında ilişki vardır (Özer ve diğerleri, 2013).

Otoregresif süreç modelleri başlığı altında, başlangıç değeri olarak, birinci dereceden AR modeli, AR(1), kullanılmıştır (başlangıç değeri olarak). Örnek olarak, 18.10.2011 tarihli ve 20:20 kalkış saatli yönlendirilmiş uçuşun görüş mesafesi tahmin sonuçları Şekil 2.4'te sunulmuştur.



Şekil 2.4: AR(1) model sonucu, 18.10.2011 20:20 uçuşu

Şekil 2.4'te AR(1) modeli uygulanmış veri setinin son 500 adedi görselleştirilmiştir. Örnek uçuşa ait grafikte, kırmızı çizgi gerçek veriyi, siyah çizgi modele göre uydurulmuş değerleri (fitted), mavi çizgi ise öngörü (forecast) değerlerini ifade etmektedir. İleriye dönük 6 adım için öngörü, %85 ve %95'lik güven aralıklarında yapılmıştır. Grafikte, AR(1) modelinin, uydurma işleminde gerçek veriyi yakalama eğiliminde olmasına rağmen, öngörü yaparken doğrusal bir davranış sergileyerek METAR verilerine uyum sağlayamadığı ve ani görüş mesafesi düşüşünü tahmin edemediği gözlemlenmektedir.

Fitn uydurulmuş değerleri gösterirken, For ise öngörülen değerleri göstermektedir. Söz konusu uçuşa ait, grafiği verilmiş olan modele ait matematiksel veriler Çizelge 2.1'de verilmiştir. Gerçek veriye karşılık gelen uydurma (fitting) değerleri ve 6 adım seviyede öngörü değerleri yer almaktadır.

Çizelge 2.1: AR(1) Tahmini Değer - Gerçek Değer - Uydurulmuş Değer

	Tahmin	Gerçek D.
Fit1	0.9949867	1.000
Fit2	0.9988562	0.975
Fit3	0.9776120	0.950
Fit4	0.9531860	0.900
Fit5	0.9183054	0.775
Fit6	0.8196749	0.725
Fit7	0.7797943	0.825
Fit8	0.8717319	0.850
Fit9	0.8979877	0.605
Fit10	0.6686754	0.330
For1	0.6802416	

For2	0.6913345	
For3	0.7019736	
For4	0.7121774	
For5	0.7219638	
For6	0.7313497	

Öngörü değerlerinin, %80 ve %95 seviyesinde belirlenmiş olan alt ve üst sınır değerleri Çizelge 2.2’de verilmiştir.

Çizelge 2.2: AR(1) Tahmini Değer - Alt - Üst Değer

Forecast	Lo 80	Hi 80	Lo 95	Hi 95
0.6802416	0.6281546	0.7323285	0.6005814	0.7599017
0.6913345	0.6191636	0.7635054	0.5809586	0.8017104
0.7019736	0.6153469	0.7886004	0.5694894	0.8344578
0.7121774	0.6141175	0.8102374	0.5622077	0.8621472
0.7219638	0.6144554	0.8294721	0.5575439	0.8863836
0.7313497	0.6158306	0.8468688	0.5546784	0.9080209

Grafikte karşılaştırması verilmiş olan hata oranlarının matematiksel ifadesi Çizelge 2.3’deki gibidir.

Çizelge 2.3: AR(1) Hata Oranları

ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
-1.022838e-05	0.04064369	0.01870526	-0.6515459	2.83756	0.2379939	0.5438866

2.2.5.2 Hareketli ortalama modeli - MA(q)

Bir zaman serisinin gecikmeli hata terimleri, şimdiki değerini etkiliyor ise hareketli ortalama (MA) süreci tanımlanır. Yani hareketli ortalama sürecinde değişkenin tahmin değeri hata değerinin tahmin değerleri ile ilgilidir (Özer ve diğerleri, 2013).

q derecesindeki bir hareketli ortalama sürecinde her gözlenen Y_t , q değerine kadar gecikmesi uzanan artık terimlerin ağırlıklı ortalamasından oluşmaktadır.

$$Y_t = \mu + \mathcal{E}_t + \alpha_1 \mathcal{E}_{t-1} + \alpha_2 \mathcal{E}_{t-2} + \dots + \alpha_q \mathcal{E}_{t-q}$$

* α =model parametresi (2.3)

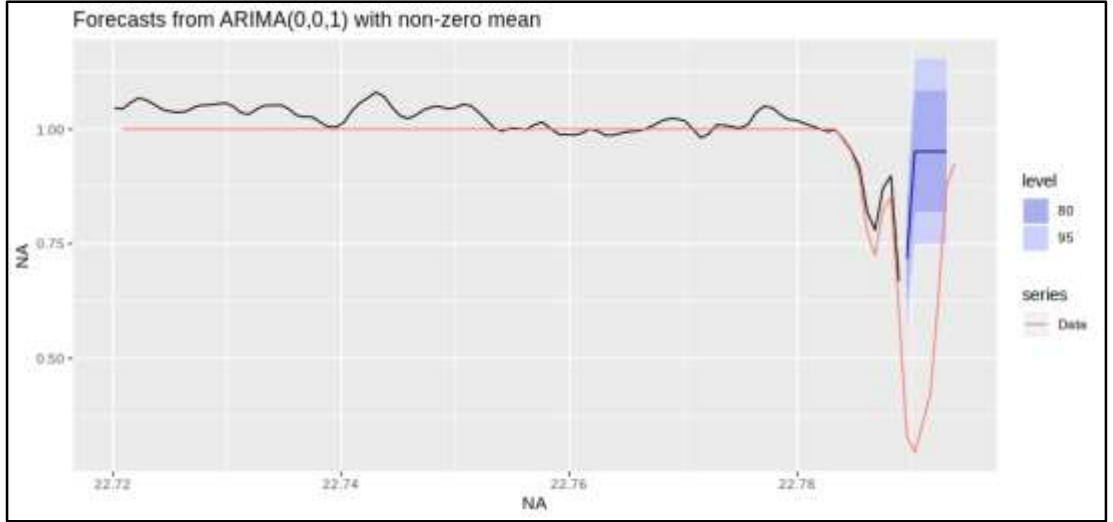
* \mathcal{E}_t = beyaz gürültü hata terimi

* μ =stokastik sürecin ortalaması

Y 'nin şimdiki değeri, sabit terim ve $t + 1$ dönemlik hataların ağırlıklı ortalamalarının toplamına eşittir. MA süreci, sabit sayıda beyaz gürültü hatalarının zaman içinde hareket eden doğrusal bileşenidir (Akdi, 2013).

Parametreler (-) veya (+) olarak gösterilebilir. Denklemden zaman boyunca artık terimler bağımsız beyaz gürültü süreci oluşturur. Yani artık değerler normal dağılıma, sabit varyansa (kovaryans=0), sıfır ortalamaya sahiptir.

Hareketli ortalama modeline giriş olarak, birinci dereceden, MA(1) modeli seçilmiştir. Örnek uçuşa ait sonuç grafiği Şekil 2.5 'te görülebilir.



Şekil 2.5: MA(1) model sonucu, 18.10.2011 20:20 uçuşu

Yukarıdaki grafik yorumlandığında, MA(1) modelinin, uydurma (fitting) işleminde gerçek veriyi yakalama eğiliminde olduğu; fakat öngöründe ani görüş mesafesi düşüşünü modelleyemediği sonucuna varılabilir. Görüş mesafesindeki ani düşüşün aksine, MA(1) modelinin çok daha iyimser bir öngöründe bulunduğu söylenebilir.

Söz konusu uçuşa ait, grafiği verilmiş olan modele ait matematiksel veriler Çizelge 2.4’de verilmiştir. Gerçek veriye karşılık gelen uydurma (fitting) değerleri ve 6 adım seviyede öngörü değerleri yer almaktadır.

Çizelge 2.4: MA(1) Tahmini Değer - Gerçek Değer - Uydurulmuş Değer

	Tahmin	Gerçek D.
Fit1	1.0005491	1.000
Fit2	0.9949867	1.000
Fit3	0.9988562	0.975
Fit4	0.9776120	0.950
Fit5	0.9531860	0.900
Fit6	0.9183054	0.775

Fit7	0.8196749	0.725
Fit8	0.7797943	0.825
Fit9	0.8717319	0.850
Fit10	0.8979877	0.605
For1	0.7173137	
For2	0.9513678	
For3	0.9513678	
For4	0.9513678	
For5	0.9513678	
For6	0.9513678	

Öngörü değerlerinin, %80 ve %95 seviyesinde belirlenmiş olan alt-üst sınır değerleri Çizelge 2.5'te verilmiştir.

Çizelge 2.5: MA(1) Tahmini Değer - Alt - Üst Değer

Forecast	Lo 80	Hi 80	Lo 95	Hi 95
0.7173137	0.6237075	0.8109199	0.5741554	0.860472
0.9513678	0.8191764	1.0835593	0.7491984	1.153537
0.9513678	0.8191764	1.0835593	0.7491984	1.153537
0.9513678	0.8191764	1.0835593	0.7491984	1.153537
0.9513678	0.8191764	1.0835593	0.7491984	1.153537
0.9513678	0.8191764	1.0835593	0.7491984	1.153537

Grafikte karşılaştırması verilmiş olan hata oranlarının matematiksel ifadesi Çizelge 2.6'daki gibidir.

Çizelge 2.6: MA(1) Hata oranları

ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
-4.514936e-06	0.0730413	0.03983827	-4.897795	8.829493	0.5068769	0.9346267

2.2.5.3 Otoregresif ve hareketli ortalama modeli - ARMA(p, q)

Çoğu durum tek başına AR(p) veya MA(q) süreçleri tarafından ifade edilemez. Bu seriler otoregresif ve hareketli ortalama modellerinin toplamı şeklinde ifade edilir. Bir zaman serisi hem AR, hem MA özelliklerini aynı anda taşıyor ise bu süreç, Otoregresif ve Hareketli Ortalama (ARMA) süreci olarak adlandırılır.

Otoregresif ve hareketli ortalama modeli (ARMA) ardışık bağlanım (AR) ve hareketli ortalama (MA) modellerinin özelliklerine aynı anda sahip olan model olarak tanımlanır. ARMA (p, q) ile gösterilir. Bir ARMA(p, q) sürecinde p tane ardışık bağlanım, (AR) q tane hareketli ortalama (MA) terimi olmak üzere, $p + q$ tane terim vardır.

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \beta_3 Y_{t-3} + \dots + \beta_p Y_{t-p} + \mathcal{E}_t + \alpha_1 \mathcal{E}_{t-1} + \alpha_2 \mathcal{E}_{t-2} + \dots + \alpha_q \mathcal{E}_{t-q}$$

* β, α =model parametreleri


* \mathcal{E}_t = beyaz gürültü hata terimi

(2.4)

Burada β_0 sabit terim, $\beta_1, \beta_2, \dots, \beta_p, \alpha_1, \alpha_2, \dots, \alpha_p$ model parametreleri, \mathcal{E}_t hata terimidir. Y_t zaman serisinin durağan olduğu varsayılırsa, zaman serisinin beklenen değerinin de sabit olduğu (μ) varsayılmış olur (Özer ve diğerleri, 2013).

AR(p), MA(q), ARMA(p, q) süreçleri zaman serilerinin durağan olduğu varsayımına dayanmaktadır.

ARMA modelleri sadece durağan eriyeye uygulanmaktadır. Bu nedenle ilk olarak trend-siz veri olup olmadığı kontrol edilmelidir. Eğer trend mevcut ise, ardışık farklar alınarak veya başka prosedürler ile trend kaldırılmalıdır. Örnek uçuşa ait ARMA(1,1) model sonuçları Şekil 2.6'da sunulmuştur.



Şekil 2.6: ARMA(1) model sonucu, 18.10.2011 20:20 uçuşu

Grafik incelendiğinde, ARMA(1,1) modelinin, AR(1) ve MA(1) modellerinde olduğu gibi uydurma (fitting) işleminde gerçek veriyi yakalama eğiliminde olduğu; öngörüsünde ise, AR(1) ve MA(1) modellerine göre gerçeğe daha yakın değerler verdiğini söylenebilir. Ani görüş mesafesi düşüşü, AR(1) ve MA(1) modelleri ile karşılaştırıldığında, ARMA(1,1) tarafından daha doğru tahmin edilmiştir.

Söz konusu uçuşa ait, grafiği verilmiş olan modele ait matematiksel veriler Çizelge 2.7’de verilmiştir. Gerçek veriye karşılık gelen uydurma (fitting) değerleri ve 6 adım seviyede öngörü değerleri yer almaktadır.

Çizelge 2.7: ARMA(1) Tahmini Değer - Gerçek Değer - Uydurulmuş Değer

	Tahmin	Gerçek D.
Fit1	1.0005491	1.000
Fit2	0.9949867	1.000
Fit3	0.9988562	0.975

Fit4	0.9776120	0.950
Fit5	0.9531860	0.900
Fit6	0.9183054	0.775
Fit7	0.8196749	0.725
Fit8	0.7797943	0.825
Fit9	0.8717319	0.850
Fit10	0.8979877	0.605
For1	0.4981074	
For2	0.5255501	
For3	0.5513313	
For4	0.5755515	
For5	0.5983053	
For6	0.6196815	

Öngörü değerlerinin, %80 ve %95 seviyesinde belirlenmiş olan alt-üst sınır değerleri Çizelge 2.8’de verilmiştir.

Çizelge 2.8: ARMA(1) Tahmini Değer - Alt - Üst Değer

Forecast	Lo 80	Hi 80	Lo 95	Hi 95
0.4981074	0.4657859	0.5304289	0.4486760	0.5475389
0.5255501	0.4555167	0.5955835	0.4184432	0.6326570
0.5513313	0.4601642	0.6424983	0.4119033	0.6907592
0.5755515	0.4691648	0.6819382	0.4128471	0.7382559
0.5983053	0.4801030	0.7165076	0.4175305	0.7790801
0.6196815	0.4919559	0.7474071	0.4243421	0.8150209

Grafikte karşılaştırması verilmiş olan hata oranlarının matematiksel ifadesi Çizelge 2.9'daki gibidir.

Çizelge 2.9: ARMA(1) Hata oranları

ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
-8.060519e-06	0.0252206	0.01168374	-0.2979279	1.725679	0.1486565	0.3283759

2.2.5.4 Otoregresif bütünleşik hareketli ortalama modeli - ARIMA(p,d,q)

Tek değişkenli zaman serilerinin analizinde kullanılan Box Jenkins yönteminin esası, zaman serilerinin herhangi bir dönemdeki değerini aynı serinin geçmiş dönemdeki gözlem değerlerinin ve hata terimlerinin doğrusal bir bileşimi ile açıklamaktır. Bu nedenle sözü edilen yöntemi literatürde Otoregresif Bütünleşik Hareketli Ortalama Yöntemi (ARIMA) olarak da karşımıza çıkmaktadır (Özmen, 1986).

Birçok zaman serisinin durağan dışı yani “bütünleşik (integrated)” olduğu bilinmektedir.

$I(1)$ (birinci derece tümleşik olan bir serinin), birinci farkı durağan $I(0)$ 'dır, $I(2)$ zaman serisinin iki kez farkı alındığında $I(0)$ olur. Genel olarak, $I(d)$ olan bir zaman serisinin d kez farkı alındığında durağanlaşır, bu seriyi $ARMA(p, q)$ ile modellediğimizde, $ARIMA(p, d, q)$ ile gösterilir.

Durağan olmayan seriler uygun derecede farklar alınarak ARIMA (otoregresif bütünleşik hareketli ortalama süreci) modelleriyle ele alınmaktadır. Seri durağanken 0. mertebeden $I(0)$ entegredir. Eğer durağanlığı sağlamak için d defa fark almak gerekiyorsa d . mertebeden $I(d)$ entegredir ve $ARMA(p, q)$ uygulanırsa $ARIMA(p, d, q)$ modeli elde edilmektedir.


ARIMA (p, d, q) süreci $AR(p)$, $MA(q)$ ve $ARMA(p, q)$ süreçlerinin kapsayıcısıdır. George Box ve Gwilym Jenkins tarafından geliştirilen bu yaklaşıma Box-Jenkins yöntemi adı verilmektedir.

Bir $ARIMA(p, d, q)$ sürecinde p tane ardışık bağlanım, q tane hareketli ortalama terimi bulunur ve d kere fark alınarak durağanlaşır. Yani, d farklılaşma seviyesini gösterir. p, d, q değerleri pozitif tam sayılardır ve nadiren 2'den büyük değerler alırlar. Farklı zaman serilerini anlatabilmek için p, d, q değerlerini bilmek yeterlidir.

Box-Jenkins yönteminin amacı; farklı zaman serilerini tanımlayan p, d, q değerlerini bulmak ve serinin tahminlemesini (forecast) kolaylaştırmaktır.

Durağan olmayan seri ise fark alma sonucunda durağanlaştırılır ve ARIMA modeli AR, MA veya ARMA modeli olacaktır. Yöntemin yaygın olarak kullanılmasının nedeni, ele alınan herhangi bir seri durağan olsun veya olmasın, mevsimsellik içersin veya içermesin, bir çözüme kavuşturma yeteneğidir. ARIMA modelinin yaygın olmasının bir nedeni de özellikle kısa dönem öngörmedeki yüksek başarı düzeyidir.

ARIMA modeli uygulanırken, başlangıç parametreleri ARIMA(1,1,1) olarak seçilmiştir. Model sonuçlarına Şekil 2.7’de ulaşılabilir:



Şekil 2.7: ARIMA(1,1,1) model sonucu, 18.10.2011 20:20 uçuşu

ARIMA(1,1,1) modeli uygulanmış grafikten de görüleceği üzere, ARIMA modeli, AR(1), MA(1) ve ARMA(1,1) modellerinde olduğu gibi uydurma işleminde gerçek veriyi yakalama eğiliminde olduğu söylenebilir. Bununla birlikte, ani görüş mesafesi düşüşünü, AR, MA ve ARMA modellerine nazaran daha iyi tahmin ederek; öngörülerin, gerçek verinin trendini yakalama eğiliminde olduğu gözlemlenmiştir.

Söz konusu uçuşa ait, grafiği verilmiş olan modele ait matematiksel veriler Çizelge 2.10'da verilmiştir. Gerçek veriye karşılık gelen uydurma (fitting) değerleri ve 6 adım seviyede öngörü değerleri yer almaktadır.

Çizelge 2.10: ARIMA(1,1,1) Tahmini Değer - Gerçek Değer - Uydurulmuş Değer

	Tahmin	Gerçek D.
Fit1	1.0005491	1.000
Fit2	0.9949867	1.000
Fit3	0.9988562	0.975
Fit4	0.9776120	0.950
Fit5	0.9531860	0.900
Fit6	0.9183054	0.775
Fit7	0.8196749	0.725
Fit8	0.7797943	0.825
Fit9	0.8717319	0.850
Fit10	0.8979877	0.605
For1	0.4249023	
For2	0.3477631	
For3	0.3233532	
For4	0.3156290	
For5	0.3131847	
For6	0.3124113	

Öngörü değerlerinin, %80 ve %95 seviyesinde belirlenmiş olan alt - üst sınır değerleri Çizelge 2.11'de verilmiştir.

Çizelge 2.11: ARIMA(1,1,1) Tahmini Değer - Alt - Üst Değer

Forecast	Lo 80	Hi 80	Lo 95	Hi 95
0.4249023	0.3937332	0.4560715	0.37723325	0.4725714
0.3477631	0.2698255	0.4257006	0.22856782	0.4669583
0.3233532	0.2086376	0.4380687	0.14791089	0.4987955
0.3156290	0.1709221	0.4603358	0.09431899	0.5369389
0.3131847	0.1430461	0.4833234	0.05298008	0.5733893
0.3124113	0.1199881	0.5048344	0.01812539	0.6066971

Grafikte karşılaştırması verilmiş olan hata oranlarının matematiksel ifadesi Çizelge 2.12'deki gibidir.

Çizelge 2.12: ARIMA (1,1,1) Hata Oranları

ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
-7.802727e-06	0.02432102	0.01128212	0.08526506	1.550106	0.1435466	0.1435466

2.2.5.5 Auto.ARIMA modeli

Optimal gecikme uzunluklarının belirlenmesi için ise Akaike bilgi kriteri (AIC) ve Schwarz kriteri (SC) sıklıkla kullanılmaktadır (Bozkurt, 2013). AIC minimum ortalama hata kareyi kullanır ve AIC değerini minimum yapan p değeri uygun gecikme sayısı olarak belirlenir. SC ise Bayesian düşünceden yola çıkarak hesap yapar ve SC değerini minimum yapan p değeri belirlenir (Montgomery ve diğ., 2008).

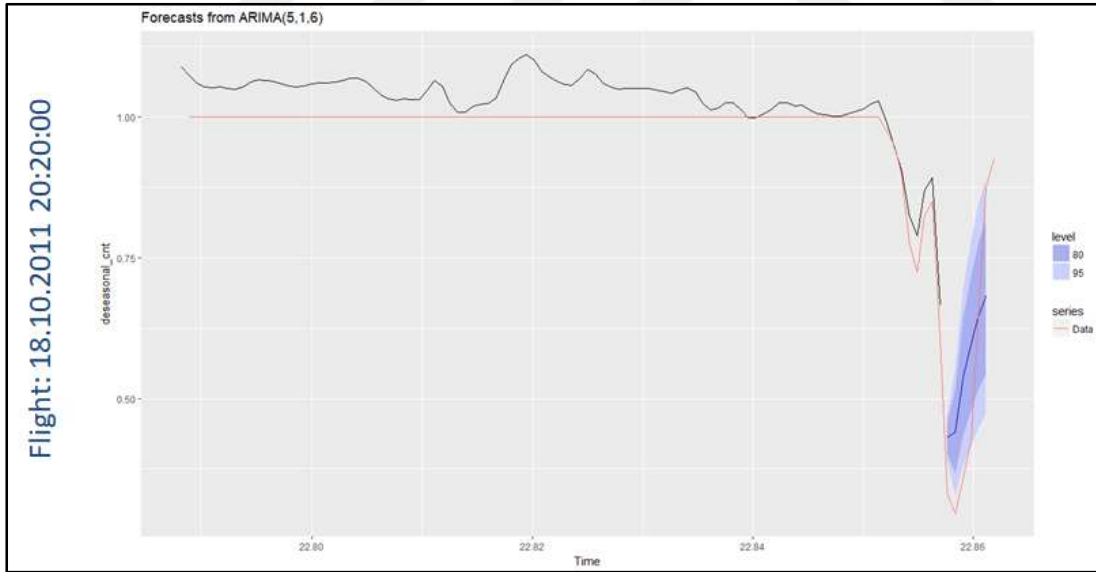
Bir modelleme sürecinde birden fazla alternatif model varsa, bunlardan en iyisini seçmek için literatürde birden çok model seçme ölçütü vardır. Bunların en sık kullanılanları AIC (Akaike Bilgi Kriteri) ve SC (Swarz Kriteri) bilgi ölçütleridir. Bu ölçütlere

göre en iyi model AIC ve SC değerlerine göre değeri sayısal olarak en küçük olan modeldir (Ünsal 2010).

AutoArima, tek değişkenli zaman serilerine en iyi ARIMA modelini yakıştırır (fit eder). AIC veya BIC değerine göre en iyi ARIMA modelini döndürür. Bu fonksiyon, kısıtlamalar dâhilinde olası modele göre bir arama gerçekleştirir. Yani ARIMA modellerininde manuel olarak belirlenen p, d, q değerleri, auto. arima' da program tarafından arka planda tüm kombinasyonlar denenerek en optimum olan program çıktısı olarak verilir.

auto.ARIMA, AIC, AICc ya da BIC değerine göre en iyi ARIMA modelini döndüren bir R fonksiyonudur. Fonksiyon, belirtilen kısıtlar dâhilinde, muhtemel modeller arasında bir arama gerçekleştirerek tek değişkenli zaman serilerine en iyi ARIMA modelini uydurur (rdocumentation.org).

Örnek uçuş için, Auto.ARIMA fonksiyonunun döndürdüğü ARIMA(5,1,6) modeline ait AIC değerine göre sonuçlar, Şekil 2.8'de görülmektedir:



Şekil 2.8: Auto.ARIMA(p,d,q) model sonucu, 18.10.2011 20:20 uçuşu

Grafik incelendiğinde, Auto.ARIMA fonksiyonunun sonucunda elde edilen ARIMA(5,1,6) modelinin; AR(1), MA(1), ARMA(1,1) ve ARIMA(1,1,1) modellerinde olduğu gibi fitting işleminde gerçek veriyi yakalama eğiliminde olduğu görülmektedir. Ani görüş mesafesi düşüşü, daha önce bahsedilen modellere nazaran çok

daha iyi öngörölmüş olup; gerçek verinin davranışını yakalama eğilimi ve model doğruluğu, önemli derecede artmıştır.

Söz konusu uçuşa ait, grafiğı verilmiş olan modele ait matematiksel veriler Çizelge 2.13’de verilmiştir. Gerçek veriye karşılık gelen uydurma (fitting) değerleri ve 6 adım seviyede öngörü değerleri yer almaktadır. Öngörü değerlerinin, %80 ve %95 seviyesinde belirlenmiş olan alt-üst sınır değerleri Çizelge 2.14’de verilmiştir.

Çizelge 2.13: Auto.ARIMA(5,1,6) Tahmini Değer - Gerçek Değer - Uydurulmuş Değer

	Tahmin	Gerçek D.
Fit1	1.0005491	1.000
Fit2	0.9949867	1.000
Fit3	0.9988562	0.975
Fit4	0.9776120	0.950
Fit5	0.9531860	0.900
Fit6	0.9183054	0.775
Fit7	0.8196749	0.725
Fit8	0.7797943	0.825
Fit9	0.8717319	0.850
Fit10	0.8979877	0.605
For1	0.4239812	
For2	0.4265726	
For3	0.5224655	
For4	0. 5817742	
For5	0.6256902	
For6	0.6594593	

Çizelge 2.14: Auto.ARIMA (5,1,6) Tahmini Değer - Alt - Üst Değer

Forecast	Lo 80	Hi 80	Lo 95	Hi 95
0.4239812	0.3967574	0.4512051	0.3823459	0.4656165
0.4265726	0.3536370	0.4995082	0.3150272	0.5381180
0.5224655	0.4196312	0.6252999	0.3651939	0.6797371
0.5817742	0.4634424	0.7001060	0.4008014	0.7627471
0.6256902	0.4970645	0.7543158	0.4289742	0.8224061
0.6594593	0.5233246	0.7955940	0.4512592	0.8676594

Grafikte karşılaştırması verilmiş olan hata oranlarının matematiksel ifadesi Çizelge 2.15'deki gibidir.

Çizelge 2.15: Auto.ARIMA (5,1,6) Hata Oranları

ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
5.274784e-06	0.02124254	0.01041098	-0.240043	1.5144	0.1324628	0.001229792

2.2.5.6 Vektör otoregresif model - VAR(p)

Vektör Otoregresif (VAR) modeli, tek değişkenli autoregression modelinin çok değişkenli zaman serisi verilerine bir uzantısıdır. Bu modelde, bütün değişkenler içsel kabul edilir ve bir değişken kendisinin ve modelde yer alan diğer değişkenlerin gecikmeli değerlerinin fonksiyonu olarak tanımlanır.

Değişkenleri Y_t ve Z_t olan iki değişkenli ve bir dönem gecikmeli bir VAR modeli;

(2.6)

$$Y_t = b_{10} - b_{12}Z_t + \gamma_{11}Y_{t-1} + \gamma_{12}Z_{t-1} + \mathcal{E}_{yt}$$

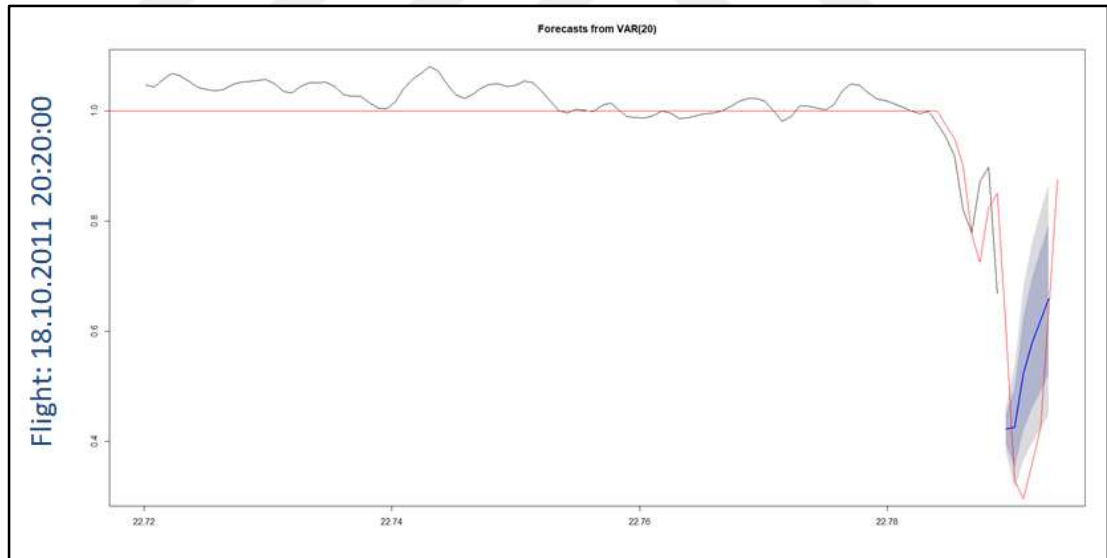
$$Z_t = b_{20} - b_{21}Y_t + \gamma_{21}Y_{t-1} + \gamma_{22}Z_{t-1} + \mathcal{E}_{zt}$$

* b, γ =model parametresi

* \mathcal{E}_{yt} ve \mathcal{E}_{zt} = beyaz gürültü süreçli hata terimleri

Denklemden, Y_t ve Z_t durağandır.

İki değişken için uygulanan yöntemde, görüş mesafesine ek olarak bulut tavan yüksekliği değişkeni kullanılmıştır. Bunun sebebi daha öncede belirtildiği gibi uçakların beklenmedik bir şekilde yönlendirilmelerinin sebebi %90 oranında görüş mesafesindeki düşüklükken, geriye kalan %10 luk dilimde, en çok yüzdeye sahip olan sebep ise bulut tavan yüksekliğindeki düşüklüktür. Şekil 2.9'da VAR modeli uygulanmış veri setin son 500 adedi görselleştirilmiştir.




Şekil 2.9: Vektör Ardışık Bağlanım Modeli (VAR)

Kırmızı ile gösterilenler gerçek veriler olup, siyahlar ise VAR modeli algoritmasına göre uydurulmuş (fit edilmiş) verileri göstermektedir. Mavi ile renklendirilmiş olan çizgi ise yine VAR algoritmasına göre öngörü (forecast) yapılmış veriyi göstermektedir. AIC değerine göre en iyi sonucu VAR (20) modeli vermiştir. İleriye dönük 6 adım için öngörü %85 ve %95'lik güven aralıklarında yapılmıştır, grafikten de görüleceği


üzere, VAR modeli, AR ve MA, ARMA ve ARIMA modellerinde olduğu gibi fitting işleminde gerçek veriyi yakalama eğilimindedir. Öngörü yaparken, ani görüş mesafesi düşüşünü AR, MA ve ARMA ve ARIMA modellerine nazaran gözle görülür bir şekilde, daha iyi modellemiş olup, gerçek verinin trendini yakalama eğilimindeki başarısı ARIMA modelinin başarısından çok daha yüksektir, fakat Auto.ARIMA modeli ile VAR modeli sonuçları birbirine yakın olduğundan, hangi modelin başarısının daha yüksek olduğunu anlamak için hata testlerine başvurulmuştur.

2.2.6 Modellerin Öngördüğü Tahminlerin Hata Testleri

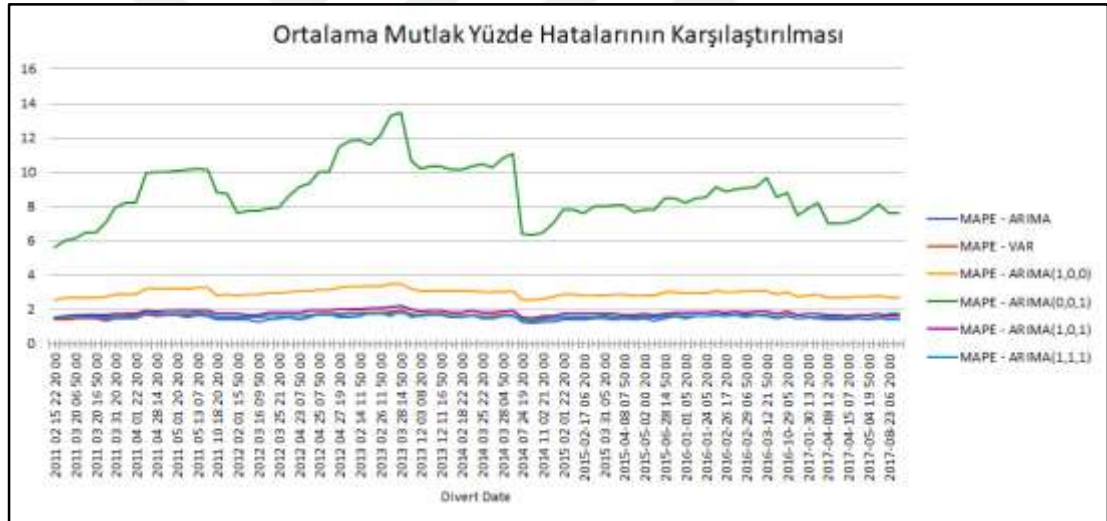
Öngörülen tahminlerin doğruluğunu ölçmek için kullanılabilecek birçok ölçüt bulunmaktadır. Bilgisayar programı yardımıyla istenen güven düzeyinde tahmin hesaplamaları yapılabilir. Model belirlenip, tahmin yapıp, uygunluk testlerinden geçirildikten sonra gelecek tahmini yapmak amacıyla kullanılabilir. Amaç, gelecek değere yakın tahmin değerleri elde etmektir. Burada hata testlerini minimum yapacak şekilde tahminler üretilmelidir. İleriye yönelik tahmin başarısı test edilerek verilere en iyi uyum gösteren model kullanılmalıdır. Tahmin başarısını ölçmek için çeşitli kıstaslar kullanılır: hata kareler ortalaması (MSE), kök ortalama hata kare (RMSE), ortalama mutlak yüzde hata (MAPE), ortalama yüzde hata (MPE), vs. En başarılı öngörü modelinin seçimi için bu kıstasların mümkün olduğunca küçük olması istenmektedir. AR, MA, ARMA, ARIMA, Auto.ARIMA ve VAR modelleri için hesaplanan MAE istatistikleri Şekil 2.10'de, RMSE istatistikleri Şekil 2.11'de ve MAPE istatistikleri ise Şekil 2.12'de verilmiştir.



Şekil 2.10: Ortalama Mutlak Hata (MAE) Karşılaştırması



Şekil 2.11: Kök Ortalama Kareyel Hata Oranlarının (RMSE) Karşılaştırması



Şekil 2.12: Ortalama Mutlak Yüzde Hatalarının (MAPE) Karşılaştırması

Hata oranlarının karşılaştırılması sonucu, Auto.ARIMA modelinin görüş mesafesini öngörmeye VAR modelinden daha başarılı olduğu saptanmıştır.

2.3 Sonuç

Meteorolojik verilerin tahmini kapsamında en uygun modelin belirlenmesi aşamasından sonra modelin, geleceğe yönelik öngöründe kullanılabilmesi için öngörü testlerine

ihtiyaç duyulmaktadır. Eğer, bir modele ilişkin öngörü gücü test sonucu anlamsız çıkarsa, ileriye yönelik tahminlerde kullanılamaz (Çuhadar vd. 2009). Tahmin doğruluklarını yapmak ve modelin gelecek tahmin gücünü belirlemek için Ortalama Mutlak Yüzde Hata (MAPE) istatistiği, Ortalama Mutlak Hata (MAE) ve Kök Ortalama Kareysel Hata (RMSE) oranları AR, MA, ARMA, ARIMA, AutoARIMA ve VAR modelleri için karşılaştırılmıştır. Karşılaştırma sonucunda tüm hata fonksiyonları incelendiğinde AutoARIMA ve VAR modellerinin hata oranların, diğer modellere göre çok daha düşük olduğu görülmüştür. VAR ve AutoARIMA modelleri karşılaştırıldığında ise AutoARIMA modelinin hata oranlarının belirli noktalarda daha düşük olduğu gözlenmiştir.

Karışıklık matrisi Çizelge 2.16’da sunulmuştur. Çalışma kapsamında amaç; görüş mesafesi düşüklüğü sebebiye oluşan yönlendirilmiş uçuş sayısını azaltmaktır. Görüş mesafesinin 4593 m’nin altında olduğu durumlarda uçma kararı verilmiştir. Dolayısıyla, CTAF ve METAR’ın “uçma” kararlarının örtüştüğü uçuş sayısı bizim için önemlidir. Amaçlanan, görüş mesafesi düşüklüğü sebebi ile yönlendirilecek uçuşu en baştan kaldırmamak olacaktır. Karışıklık matrisi bize yönlendirilmiş 84 adet uçuş için, CTAF referans alınarak 25’inin yönlendirilmesinin engellendiğini göstermektedir. Yüzdeler tabanda iyileştirme oranı yüzde 30’dur. Bu oranın yeterli görülmemesi sebebi ile çalışmada YSA’ları ile modelleme üzerine yoğunlaşılacaktır.

Çizelge 2.16: Zaman Serileri Analizine Ait Karışıklık Matrisi

		METAR		TOPLAM
		Uç	Uçma	
CTAF	Karar			
	Uç	27	5	32
	Uçma	27	25	52
TOPLAM		54	30	84

3. YAPAY SİNİR AĞLARI

3.1 Amaç

Tezin bu kısmında, yönlendirilmiş uçuş sayısını azaltarak problemi çözmek ve bir önceki bölümde, zaman serisi analizi ile elde edilen “uçak yönlendirme kararı verilirken yanlış karar vermeme yüzdesini” arttırmak için, doğrusal olmayan problemlerin çözümünde sıklıkla yararlanılan, YSA’ları kullanılmıştır. YSA’ları doğrusal olmayan problemlerin çözümünde etkin olarak kullanılmaktadır. Bu bölüm kapsamında MATLAB programı kullanılarak, YSA’ları ile yönlendirilmiş uçuş sayısını azaltmak için model oluşturulmuş ve modelin test edilmesi sonrasında gelecek 3 saat (6 adım ilerisi) için tahminlerde bulunulmuştur. Ayrıca model içerisindeki her bir değişkenin modele etkisi ve YSA’larının mevcut yöntemlerden üstün olduğu gösterilmiştir.

3.2 Yapay Sinir Ağları Tanımı ve Tarihçesi

Her insan varoluşsal olarak, doğduğu andan itibaren belirli bir zekâya sahiptir. Zekâ; çalışarak, eğitilerek edinilen bilgi birikim ve deneyimlerle geliştirilebilir. İlk kez karşılaşılan, ani gelişen bir duruma uyum sağlayabilme, anlama, öğrenme, analiz yeteneği zekâ ile gerçekleştirilebilmektedir. Zekâ yazılımlarla taklit edilebilmektedir. Bu durumda zekâ, “Yapay Zekâ” olarak adlandırılmaktadır (Elmas, 2007). Yapay Zekâ; “insan zekâsını” gerektiren eylemleri yapabilecek kabiliyette bir sistemin oluşturulması çabalarının tümüdür. Asıl amaç, insan varlığında gözlemlenen ve "akıllı davranış" olarak adlandırılan davranışları gösterebilen, öğrenebilen, taklit edebilen bilgisayarlar yapmaktır. Bu doğrultuda yapay zekâ; bilgisayarların, insana has düşünme sistemi yapısını öğrenerek, insana ait özelliklerin bilgisayarlar tarafından geliştirilip uyarlanması olarak tanımlanabilmektedir. Genel olarak; bilgisayarın “insan” gibi düşünme yeteneğine sahip olması demektir. Matematiksel bir modelleme yöntemi olan YSA’ları, yapay zekâ uygulamaları arasında yer almaktadır. YSA, insan beyninin en belirgin özelliklerinden olan “öğrenme” eylemi ile düşünsel faaliyetleri (bilgi edinme, algılama, sınıflandırma, ilişkilendirme, türetebilme, oluşturabilme, karar verebilme vb.) herhangi bir yardım almadan “otomatik” olarak gerçekleştirmek için geliştirilmiş bir akıllı (bilgisayar) sistemdir (Uygunoğlu ve Yurtçu, 2006).

3.3 Yapay Sinir Ağlarının Genel Özellikleri

YSA'larının günümüzde kullanılan diğer bilgi işlem yöntemlerinden farklılıkları aşağıdaki şekilde sıralanabilir: (Elmas 2007)

Doğrusal Olmama: Doğrusal olan bir yapıda, girdilerden biri değiştiğinde, çıktı bu değişime orantılı olarak değişir, bu durum değişen girdinin değeri ile ilişkilidir. YSA'ları bütün bir ağ boyunca doğrusal değildir. Bu sayede YSA'ları doğrusal olmayan karmaşık süreçlerin çözümünde yardımcı olmaktadır.

Öğrenme: YSA olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışırlar. YSA'nın karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden ayarlanamaz. Bu sebeple, problemden aldığı eğitim örneklerini, istenilen davranışı gösterecek doğrultuda, kullanarak öğrenmesi gerekir. Diğer klasik yöntemlerden farklı olarak, söz konusu problemle ilgili gerekli bilgileri, mevcut verileri kullanarak kendileri çıkarmaktadırlar (Kaya ve diğ., 2005).

Bilginin Saklanması: YSA'larında veriler herhangi bir veri tabanında ve programın içinde gömülü olarak değil ağ üzerinde saklanırlar (Adıyaman, 2007).

Hata Toleransı: YSA'larındaki doğrusal olmayan (paralel) yapı, ağına sahip olduğu bilginin tüm bağlantılara yayılmasını sağlar. Bu sebeple, bazı bağlantıların veya hücrelerin etkisiz hale gelmesi ağına doğru bilgi üretmesini önemli ölçüde etkilemez, geleneksel yöntemlere nazaran hatayı tolere etme yetenekleri yüksektir.

Genelleme: YSA kendisine gösterilen, tanıtilen, öğretilen durum ve süreçlerden yola çıkarak görmediği, tanımadığı ve daha önce öğrenmediği durum ve süreçler hakkında bilgi üretebilirler.

Dereceli bozulma: YSA, hata toleransına sahip oldukları için, beklenmedik bir durum ile karşılaştıklarında dereceli bir şekilde bozulur, hemen bozulmazlar (Adıyaman, 2007).

Uyarlanabilirlik: Belirli bir problemi çözmek için eğitilen YSA'nda, ağırlıkların yeniden yapılandırılabilir olması problemdeki değişimlere göre yeniden eğitilebilirlik ve farklı koşullara uyarlanabilirlik sağlamaktadır.

YSA'nda model tasarlanırken giriş ve çıkış kümeleri kullanılır. Böylece YSA girdiler ve çıktılar arasında, doğrusal ve doğrusal olmayan tüm ilişkileri, daha önceden edinilmiş geçmiş durumları öğrenerek daha önce görülmemiş, tanınmamış, öğrenilmemiş ve uygulanmamış örnekler için belirli limit aralıklarında çözümler üretebilmektedir.

YSA'nın doğrusal olmama özelliklerinden dolayı hızlı çalışabilme yeteneği, öğrenme yeteneği, genelleme yapabilmesi, rahatlıkla farklı problemlere uyarlanabilir olma özelliği, daha az bilgi gerektirmesi (bilgiyi ağ üzerinde taşıma özelliği), gibi birçok avantajı sebebi ile çok sayıda mühendislik alanında farklı problemlerin çözümünde kullanılmaktadır.

YSA'ların tarihsel gelişimi insanların nörobiyolojiye ilgi duymaları ve sonuçları bilgisayar yardımı ile uygulamalarıyla başlamaktadır.


- 1890: İnsan beyninin yapısı ve fonksiyonları ile ilgili ilk yayının yazılması
- 1943: Yapay Sinir hücrelerine dayalı hesaplama teorisinin ortaya atılması
- 1949: Biyolojik olarak mümkün olabilen öğrenme prosedürlerinin bilgisayarlar tarafından gerçekleştirilecek biçimde geliştirilmesi.
- 1957-1962: Tek Katmanlı Algılayıcının (Perceptron) geliştirilmesi.
- 1969: Tek katmanlı algılayıcıların problemleri çözme yeteneklerinin olmadığını gösterilmesi.
- 1969-1972: Doğrusal İlişkilendiricilerin geliştirilmesi.
- 1974: Geri Yayılım modelinin (Çok katmanlı algılayıcıların ilk çalışmaları) geliştirilmesi.
- 1982: Çok Katmanlı algılayıcılarının geliştirilmesi (Öztemel, 2003).

3.3.1 Yapı ve temel elemanları

3.3.1.1 Biyolojik sinir hücreleri

İnsan beyninin çalışmasını sağlayan en temel yapı taşlarından biri de biyolojik sinir ağlarıdır. İnsanların tüm davranışlarını ve çevresinde olup bitenleri anlamasını sağlar. İnsan beyninin yoğun bağlantılı ve karmaşık yapısı kendisine özgüdür. Bu yapıya erişmek günümüz teknolojisiyle mümkün değildir. YSA'lar da beynin yapısından esinlenilerek oluşturulmuştur, fakat kullanılan yapay nöronlar beyindeki nöronlara göre oldukça basit yapıları olmalarına rağmen, tutarlıdırlar. YSA'lar temel elemanları olan yapay nöronların aralarında bağlantı oluşturulup, tabakalar halinde gruplandırılmalarıyla oluşturulurlar (Yurtoğlu, 2005). Milyarlarca sinir hücresinin bir araya gelmesi ile sinir ağı oluşmaktadır. Bir sinir hücresi sinapslar, akson, soma (hücre gövdesi), ve dentrite'lerden oluşmaktadır. Sinapslar sinir hücreleri arasında elektrik sinyallerinin iletil-

mesini sağlayan bağlantılardır. Dendriteler ise bu sinyalleri snaps'lere göndererek diğer sinir hücrelerine iletilmesini sağlarlar. Şekil 3.1'de bir biyolojik sinir hücresinin hareket yönü gösterilmiştir.



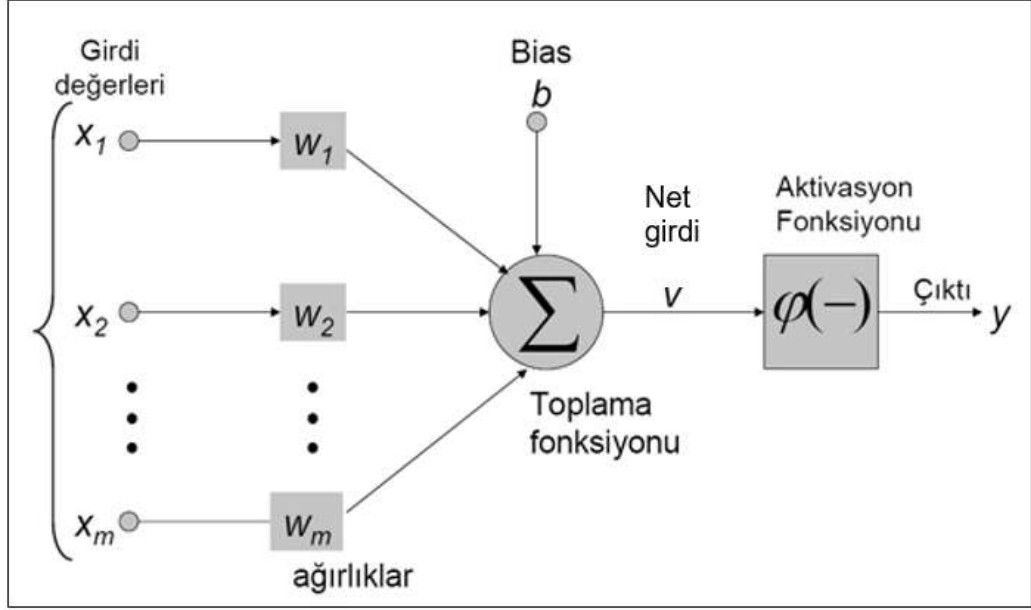
Şekil 3.1: Biyolojik Sinir Hücresi

Yapay bir sinir hücresi, biyolojik bir sinir hücresinin temel davranışını taklit ederek matematiksel modeli ortaya koyan bir algoritmadır. Biyolojik sinir hücresinin tanımından hareketle, yapay bir sinir hücresinin diğer sinir hücrelerinden aldığı sinyalleri bünyesinde topladığını ve toplam sinyal birikiminin belli bir eşiği aştığı anda, bu yapay sinir hücresinin kendi sinyalini bir başka sinir hücresine ilettiği söylenebilir (Fahey 2006).

3.3.1.2 Yapay sinir hücresi (işlemci eleman)

Biyolojik sinir ağlarında olduğu gibi YSA da hücreli yapıya sahiptir (Şekil 3.2). Bir YSA hücresi beş elemandan oluşmaktadır:

1. *Girdi değerleri*: Girdi değerleri (x_1, x_2, \dots, x_m) , yapay sinir hücresine dış dünyadan gelen bilgilerdir. Bilgiler başka hücrelerden gelebildiği gibi kendinden de gelebilir.



Şekil 3.2: Yapay Sinir Hücresinin Yapısı

2. *Ağırlıklar*: Ağırlıklar (w_1, w_2, \dots, w_m), hücreye gelen bilginin hücre üzerindeki etki ve önemini gösterir. Ağırlığın küçük ya da büyük olması önem derecesi belirtmez.

3. *Toplama Fonksiyonu*: Toplama fonksiyonuna, sinirde her bir ağırlığın ait olduğu girdi değerleri ile çarpılarak toplamlarına eşik b değerinin de eklenmesini sağlayarak etkinlik (aktivasyon) fonksiyonuna gönderilir. Böylelikle, hücreye gelen net girdi hesaplanmış olur. Toplam fonksiyonu için farklı fonksiyonlar kullanılabilir.

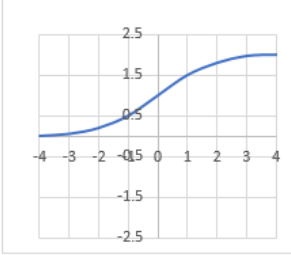
Belirtilmelidir ki, her girdi bağımsız olarak farklı bir toplama fonksiyonuna sahip olabileceği gibi aynı toplama fonksiyonuna da sahip olabilir. Yani, herhangi bir problem için optimum toplama fonksiyonunu belirleyecek bir formül yoktur. Ancak sıklıkla kullanılan fonksiyonlar Çizelge 3.1’de verilmiştir.

Çizelge 3.1: Fonksiyonlar

<p>Toplam</p> $\text{Net} = \sum_{i=1}^N X_i * W_i$	<p>Ağırlık değerleri girdiler ile çarpılır ve bulunan değerler birbirleriyle toplanarak Net girdi hesaplanır.</p>
<p>Çarpım</p> $\text{Net} = \prod_{i=1}^N X_i * W_i$	<p>Ağırlık değerleri girdiler ile çarpılır ve daha sonra bulunan değerler birbirleriyle çarpılarak Net girdi hesaplanır.</p>
<p>Maksimum</p> $\text{Net} = \text{Max} (X_i * W_i)$	<p>n adet girdi içinden ağırlıklar girdilerle çarpıldıktan sonra içlerinden en büyüğü NET girdi olarak kabul edilir.</p>
<p>Minimum</p> $\text{Net} = \text{Min} (X_i * W_i)$	<p>n adet girdi içinden ağırlıklar girdilerle çarpıldıktan sonra içlerinden en küçüğü NET girdi olarak kabul edilir.</p>
<p>Çoğunluk</p> $\text{Net} = \sum_{i=1}^N \text{Sgn} (X_i * W_i)$	<p>n adet girdi içinden girdilerle ağırlıklar çarpıldıktan sonra pozitif ile negatif olanların sayısı bulunur. Büyük olan sayı hücrelerinin net girdisi olarak kabul edilir.</p>
<p>Kümülatif Toplam</p> $\text{Net} = \text{Net} (\text{eski}) + \sum_{i=1}^N X_i * W_i$	<p>Hücreye gelen bilgiler ağırlıklı olarak toplanır. Daha önce hücreye gelen bilgilerle yeni hesaplanan girdi değerleri eklenerek hücrenin net girdisi hesaplanır.</p>

4. *Aktivasyon Fonksiyonu*: Hücreye gelen girdileri işleyerek, hücrenin bu girdiye karşılık üreteceği çıktıyı hesaplayan fonksiyondur. Toplama fonksiyonunda olduğu gibi çıktıyı belirlemek için değişik fonksiyonlar kullanılır. Çok Katmanlı Algılayıcı modelde sıklıkla sigmoid fonksiyonu kullanılmaktadır. En çok kullanılan aktivasyon fonksiyonlarından Sigmoid Çizelge 3.2’de sunulmuştur. Çalışma kapsamında kullanılan aktivasyon fonksiyonu da Sigmoid Aktivasyon fonksiyonudur.

Çizelge 3.2: Aktivasyon Fonksiyonları


<p>Sigmoid Aktivasyon Fonksiyonu</p>		$F(\text{Net}) = \frac{1}{1 + e^{-\text{Net}}}$	<p>Sigmoid aktivasyonu fonksiyonu sürekli ve türevi alınabilir bir fonksiyondur. Doğrusal olmayışı dolayısıyla yapay sinir ağı uygulamalarında en sık kullanılan fonksiyondur. Bu fonksiyon girdi değerlerinin her biri için 0 ile 1 arasında bir değer üretir.</p>
--------------------------------------	-------------------------------------------------------------------------------------	-------------------------------------------------	---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

5. *Hücrenin Çıktısı*: Girdi değerlerinin, aktivasyon fonksiyonuna girmesi ile belirlenen çıktı değeridir.

Üretilen çıktı biyolojik sinir hücresinde olduğu gibi dış dünyaya veya başka bir hücreye gönderilir. Bir yapay sinir hücresinde, birden çok girdi değeri olabilirken, sadece tek bir çıktı değeri vardır.

3.3.2 Yapay Sinir Ağları Yapısı

YSA’nda, yapay sinir hücreleri basit bir şekilde kümelendirilmektedirler. Bu kümelendirme katmanlar halinde yapılmaktadır ve daha sonra bu katmanlar bir diğeri ile ilişkilendirilmektedir. Bütün YSA’ları benzer bir yapıdadırlar. Bu yapıda, bazı yapay sinir hücreleri girdileri almak için bazı yapay sinir hücreleri ise çıktıları iletmek için dış dünya ya da diğeri hücreler ile bağlantılı haldedirler. Geri kalan bütün yapay sinir hücreleri ise gizli katmandadırlar, yani sadece ağ içinde bağlantıları vardır. YSA’larının yapısı Şekil 3.3’de gösterilmektedir.



Şekil 3.3: Yapay Sinir Ağlarının Yapısı

Girdi Katmanı: Bu katmanda, en az bir girdi değeri yer alır. Veriler, herhangi bir işleme tabi tutulmaz. Girdiler ile aynı değerde çıktı üretilir.

Ara Katmanlar: Bu katmanda, girdiler belirli işlemlere tabi tutulurlar. İşlem katmanının yapısı ve fonksiyonu seçilmiş olan ağı yapısına göre değişiklik gösterebilir. Ara katman, tek bir katmandan oluşabileceği gibi birden fazla katmandan da oluşabilir. Bu

gizli katmanlar çok sayıda yapay sinir hücresi içerirler. Çoğu ağ türünde, gizli katmandaki bir yapay sinir hücresi sadece bir önceki tabakanın tüm hücrelerinden sinyal alır, işlemin gerçekleştirilmesinin ardından ise çıktı bir sonraki tabakanın tüm yapay sinir hücrelerine gönderilir. Bu yapı ise ağ çıktısı açısından bir ileri besleme patikası oluşturur (Anderson ve diğ., 2006).

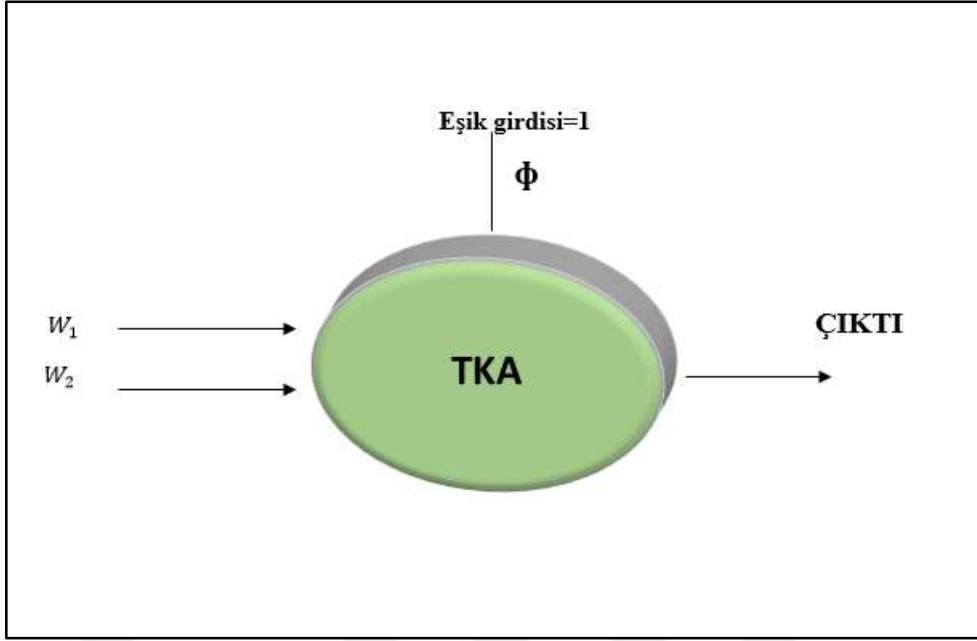
Gerekenden az gizli katmana sahip YSA'ları karmaşık fonksiyonların çözümünde yetersiz kalırken, çok fazla gizli katmana sahip YSA'ları ise kararsızlıklarla karşılaşmaktadır. Gizli katman sayısının belirlenmesinin ardından, her bir katmanda kaç tane yapay sinir hücresinin bulunacağı karşılaşılan bir başka problemdir. Girdi katmanı için daha önceden de belirtildiği gibi bir sorun bulunmamaktadır; bu sayı sistem içerisindeki girdilerin sayısına eşittir. Benzer şekilde, çıktı katmanı da istenilen çıktı sayısı ile belirlenebilmektedir. Asıl sorun, gizli katmanlardaki yapay sinir hücresi sayısını belirlemektir. Geleneksel matris algoritması, matris boyutlarının ya girdi sayısına ya da çıktı sayısına eşit olması gerektiğini söylemektedir. Ne yazık ki, gizli katmanda en verimli şekilde kaç tane yapay sinir hücresinin bulunacağı konusunda herhangi bir matematiksel test bulunmamaktadır. Deneme ve yanılma yöntemi uygulanarak karar verilmektedir (Detienne ve diğ., 2003).

Çıktı Katmanı: Çıktı katmanı en az bir çıktıdan oluşur ve çıktı ağ yapısında bulunan fonksiyona bağlıdır. Bu katmanda işlem gerçekleştirilir ve üretilen çıktı dış dünyaya gönderilir.

3.3.3 Yapay sinir ağlarının sınıflandırılması

3.3.3.1 Tek katmanlı algılayıcılar

Sadece girdi ve çıktı katmanından oluşan ağlardır. Her bir ağın bir veya daha fazla girdisi ve çıktısı vardır. Çıktılar bütün girdilere bağlanmaktadır ve her bağlantının bir ağırlığı (W) vardır. Bu ağlarda süreç elemanlarının değerinin sıfırdan farklı olmasını önleyen eşik değeri vardır ve bu daima 1'dir (Öztemel, 2003). Tek katmanlı YSA'ları, kullanım alanı olarak yalnızca doğrusal problem çözümlerinde kullanılan basit bir yöntemdir. Şekil 3.4'da Tek Katmanlı Algılayıcının yapısı verilmiştir.




Şekil 3.4: Tek Katmanlı Algılayıcı Modeli

Tek bir katmandan oluşan bir algılayıcı sadece doğrusal fonksiyonları tahminleyebilirken, giriş ve çıkış katmanı arasında gizli katmanlara sahip olan ileri beslemeli çok katmanlı algılayıcılar, tek katmanlı algılayıcıların karşılaştıkları zorlukları ortadan kaldırmaktadırlar (Alpaydın, 2004). Bir YSA'ndan çözmesi istenilen problem doğrusal değilse ilk başta tasarlanmış YSA'ları ile bunu modellemek mümkün değildir. Bu tür problemler için daha gelişmiş bir ağ türüne ihtiyaç vardır.

3.3.3.2 Çok katmanlı algılayıcılar

Çok katmanlı algılayıcılar, bu amaçla geliştirilen ağlardır. Bu modelin yaygın olarak kullanılmasının sebebi, birçok öğrenme algoritmasının bu ağı eğitmede kullanılabilir olmasıdır. Bir YSA'nın, öğrenmesi istenen olayların girdi ve çıktıları arasındaki ilişkiler doğrusal olmayan ilişkiler ise, Tek Katmanlı Algılayıcılar ile öğrenme gerçekleştirmek maalesef mümkün değildir. Gündelik hayatta karşılaşılan olayların çoğu doğrusal olmayan nitelik taşıması sebebi ile doğrusal olmayan problemi çözmek için yeni modellerin geliştirilmesine ihtiyaç duyulmuştur (Alataş, 2006). Çok Katmanlı Algılayıcı modeli (Şekil 3.5) mühendislik problemlerinin çok büyük bir kısmına çözüm üretebilecek bir güce sahiptir. Daha çok sınıflandırma, tanıma ve genelleme yapmayı gerektiren problemleri çözmeye kullanılırlar.



Şekil 3.5: Çok Katmanlı Algılayıcının Yapısı

Çok Katmanlı Algılayıcı (ÇKA) ağlarının yapısı Girdi Katmanı, Ara Katman ve Çıktı Katmanı olmak üzere üç katmandan oluşmaktadır. Öğrenilmesi istenen olay için ÇKA ağları aşağıdaki adımları izleyerek çalışmaktadır:

Örneklerin Toplanması: Ağın öğrenmesi için eğitim seti ve test edilip performansının ölçülmesi için test seti verileri toplanmaktadır.

Ağın Topolojik yapısının belirlenmesi: Girdi sayısı, ara katman sayısı, her ara katman için proses elemanı sayısı ve çıktı sayısı bu adımda belirlenir.

Öğrenme parametrelerinin belirlenmesi: Ağa ait öğrenme katsayısı, proses elemanlarına ait topama ve aktivasyon fonksiyonları bu adımda belirlenir.

Ağırlıkların başlangıç değerlerinin atanması: Proses elemanlarını birbirlerine bağlayan ağırlık değerleri başlangıçta genelde rastgele değerler atanır. Daha sonra uygun değerleri öğrenme sırasında kendi belirler.

Öğrenme setinden örneklerin seçilmesi ve ağa gösterilmesi: Ağın öğrenmeye başlaması için ağa örnekler belirli bir düzeneğe göre gösterilir.

Öğrenme sırasında ileri hesaplamaların yapılması: Girdiye karşılık ağın verdiği çıktı değerleri hesaplanır.

Gerçekleşen çıktının beklenen çıktı ile karşılaştırılması: Ağın ürettiği hata değerleri bu adımda hesaplanır.

Ağırlıkların değiştirilmesi: Genelleştirilmiş Delta Kuralına göre hatanın azaltılması için ağırlıkların değiştirilmesi yapılır. Çok Katmanlı Algılayıcı ağının öğrenmesi tamamlanmaya kadar yani hatalar kabul edilir düzeye ininceye kadar devam eder. Ağın öğrenmesi için bir durdurma kriterinin olması gerekir. Bu ise genellikle üretilen hatanın belirli bir düzeyin altına düşmesi olarak alınmaktadır. Doğrusal olmayan aktivasyon fonksiyonuna sahip olan ÇKA geri yayılım (back propagation) öğrenme yöntemini kullanmaktadır. YSA topolojisi, sınırlar arası bağlantıların yönlerine veya ağ içindeki işaretlerin akış yönlerine göre ikiye ayrılmaktadır. Bu ağlar; ileri beslemeli (feed forward) ve geri beslemeli (feedback, recurrent) YSA'dır. İleri beslemeli YSA'nda yapay sinir hücreleri genellikle katmanlara ayrılmışlardır. İşaretler, girdi katmanından çıktı katmanına doğru tek yönlü bağlantılar ile iletilirler. İleri beslemeli ağlarda, hücreler katmanlar halinde düzenlenirler ve bir katmandaki hücrelerin çıkışları bir sonraki katmana (ağırlıklar üzerinden) giriş olarak verilirler. Giriş katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan gizli katmandaki hücrelere iletir. Bilgi, gizli ve çıkış katmanında işlenerek ağ çıkışı belirlenir (Rojas, 1996).

Çok katmanlı algılayıcı modeli, bir giriş, bir veya daha fazla gizli ve bir de çıkış katmanından oluşmaktadır. Her bir katmanda bir veya daha çok sayıda yapay sinir hücresi bulunur. Bir katmandaki tüm yapay sinir hücreleri bir üst katmandaki yapay sinir hücrelerine bağlıdır. Bilgi akışı ileri doğrudur. Geri besleme yoktur. Bu sebeple, bu tip ağlar ileri beslemeli sinir ağı modeli olarak adlandırılmışlardır. Giriş katmanında herhangi bir bilgi işleme yapılmaz. Giriş ve çıkış katmanındaki yapay sinir hücresi sayısı tamamen uygulanan probleme bağlı olmakla beraber, gizli katman sayısı ve gizli katmandaki yapay sinir hücresi sayısı daha önceki bölümde de belirtildiği gibi, deneme yanılma yolu ile bulunmaktadır. Geri beslemeli ağ topolojisi, genellikle danışmansız öğrenme kurallarının uygulandığı ağlarda kullanılmaktadır. Geri besleme, bir katmandaki hücreler arasında olabileceği gibi katmanlar arasındaki hücreler arasında da olabilmektedir. Bu yapısı ile geri beslemeli YSA'ları, doğrusal olmayan dinamik bir davranış sergilemektedirler (Alataş, 2006).

3.3.4 Yapay sinir ağlarında öğrenme

YSA'larını yapılarına ve öğrenme algoritmalarına göre sınıflandırmak mümkündür. Çalışmanın bu alt bölümünde YSA'ları sadece yapılarına göre sınıflandırılacaktır.

3.3.4.1 Öğrenme yöntemleri

YSA’nda öğrenmeyi gerçekleştirecek olan sistem ve algoritmaların kullanımı üç öğrenme yöntemi ve bunların karması olan yöntemler ile uygulanmaktadır.


- Danışmanlı (Supervised) öğrenme yöntemi: Sistemlerin öğrenebilmesi için öğrenmeye dışarıdan müdahale eden bir danışman / öğretmenin yardımcı olduğu yöntemdir. Öğrenme danışmanın kontrolündedir. Öğrenilmesi istenen durum ile alakalı girdi ve çıktı değerlerini danışman verir. Eğitim kümesini ve hata değerini belirleyerek eğitimin ne kadar devam edeceğine karar verir. Bu yöntemin en önemli özelliği eğitim esnasında gerçek girdi çıktı değerlerin kullanılmasıdır (Şen, 2004).
- Danışmansız (Unsupervised) öğrenme yöntemi: Danışmansız öğrenme yönteminde danışmanlı öğrenmenin aksine, sistemin öğrenmesi için herhangi bir danışman yoktur. Sisteme sadece girdi değerleri verilir. Beklenen, tanıtilen durumlara ait parametreler arasındaki ilişkileri sistemin kendi kendine öğrenmesidir. Sistemin öğrenmesi tamamlandıktan sonra çıktıların ne anlam ifade ettiği kullanıcı tarafından belirlenmelidir. Bu yöntemler daha çok sınıflandırma için kullanılan yöntemlerdir (Öztemel, 2003).
- Destekleyici öğrenme (Reinforcement learning): Danışmanlı öğrenme kuralına yakın bir metottur. Bu yöntemde de sisteme bir danışman yardımcı olmaktadır. Ağın verdiği çıktı değerleri karşılaştırma için kullanılmasa da üretilen sistem çıktının doğru ya da yanlış olduğunu gösteren bir sinyal ağa geri verilir. Sistem, danışmandan gelen bu sinyali dikkate alarak öğrenmeyi gerçekleştirir (Öztemel, 2003).

3.3.5 Tekrarlayan sinir ağları (Recurrent neural network)

TSA girdi değerlerini anlık değil, önceki girdilere bağlı olarak değerlendirir. $t - 1$ anında bir girdi değeri için verilen karar, t anında verilecek olan kararı da etkilemektedir. TSA’larında girdi değerleri şimdiki ve daha önceki bilgilerin birleştirilmesi ile çıktı üretirler ve bir sonraki işlemde bu çıktıları girdi olarak kullanırlar, bu özellikleri ile de geri beslemeli ağlardan ayrılmaktadırlar. TSA’ları belleğe sahiptirler.

TSA, dinamik zamansal davranış sergileme eğilimindedirler. Zamana bağlı istatistiksel veriler gibi belli bir sıra ile gelen verilerin olduğu durumlarda sıklıkla kullanılan bir yöntemdir (Sak, 2014).

TSA'nın amacı, ardışık bilgileri kullanmaktır. Geleneksel bir sinir ağında tüm girdi ve çıktılar birbirinden bağımsız olduğu varsayılır. TSA'lar bir dizinin her ögesi için aynı görevi yerine getirirler, çıktı önceki hesaplamalara bağlıdır, bu sebeple tekrarlayan sinir ağları olarak adlandırılırlar. Teoride, TSA'lar uzun dizilerdeki bilgileri kullanılabilir, ancak pratikte yalnızca birkaç adım geriye dönmekle sınırlıdır. Her uzunluktaki girdinin işlenmesine imkân sağlarken, hesaplama süreleri uzun sürebilmektedir. İşleyen modelin boyutu, girdi sayısındaki artıştan bağımsızdır, geçmiş verileri işleme katarak hesaplamalar yapılmasına rağmen, uzun zaman önceki veriye ulaşmak bu tipteki ağlar için zordur. TSA modeli Şekil 3.6'da sunulmuştur.



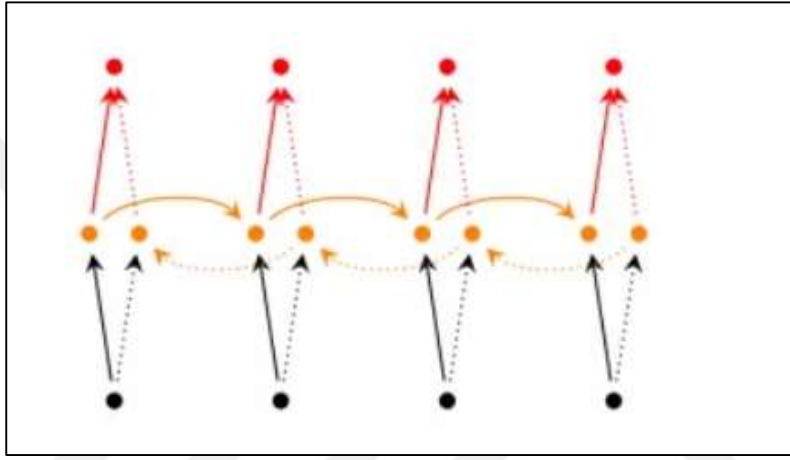
Şekil 3.6: Tekrarlamalı Sinir Ağı Modeli

TSA'lar girdilerini anlık olarak değerlendirmek yerine, önceki girdilere bağlı olarak değerlendirir. Şekil'de görüldüğü üzere TSA girdi verilerinin yanında önceki çıktı değerlerini de gösteren içerik birimleri (content unit) de ağı etkiler. $t - 1$ anındaki girdi için verilen karar, t anında verilecek olan kararı da etkilemektedir. Kısaca bu tip ağlarda girdiler şimdiki ve önceki bilgilerin birleştirilmesi ile çıktı üretirler.

TSA'lar, çıktılarını daha sonraki işlemlerde girdi olarak kullandıkları için feed-forward (geri beslemeli) yapılardan bu özellikleri ile ayrılmış olurlar. TSA'lar hafızalı yapılardır.

3.3.5.1 İki yönlü TSA'lar


t zamanındaki çıktı değerinin, sadece önceki öğelere değil gelecekteki öğelere de bağlı olabileceği düşüncesine dayanmaktadır. Yapı, Şekil 3.7'de gösterilmiştir.



Şekil 3.7: İki Yönlü TSA

3.3.5.2 Derin (İki yönlü) TSA'lar

Çift Yönlü TSA'larına benzer yapıdadır, ayırıcı özellik olarak, zaman adımında birden fazla katmandan oluşmaktadır (Şekil 3.8). Pratikte, bu durum daha yüksek bir öğrenme kapasitesi sağlamasına rağmen, birçok eğitim verisine gerek duyulduğu unutulmamalıdır.



Şekil 3.8: Derin TSA Yapısı

3.3.6 Kısa uzun süreli hafıza (Long short term memory - LSTM)

Değerleri rastgele aralıklarla hatırlayan sinir ağı yapısıdır. Öğrenilen ilerleme kaydedildiğinde saklanan değerler değiştirilmez. TSA'ları, nöronlar arasında ileri ve geri bağlantılara izin verir.

Uzun Kısa Süreli Bellek Ağları (LSTM'ler) uzun vadeli bağımlılıkları öğrenebilme özelliğine sahip bir TSA türüdür. Birçok farklı problem tipinde başarılı bir şekilde çalışabildikleri için günümüzde yaygın olarak kullanılmaktadırlar.

LSTM'ler, uzun vadeli bağımlılık probleminin önüne geçmek için tasarlanmışlardır. Uzun zaman dilimleri boyunca bilgileri hatırlamak (bellekte tutmak) varsayılan (default) davranışlarındandır.

LSTM ağı, uzun veya kısa zaman periyotlarını hatırlamaktadır. Saklanan değer tekrarlı bir şekilde değiştirilmez ve zaman içinde geri yayılımla eğitildiğinde eğitim kaybolmaz (Sak ve diğ., 2014).

Bir LSTM, zaman gecikmeleri göz önüne alındığında zaman serilerini sınıflandırmak, işlemek ve öngörmek konularında sıklıkla uygulanan bir yöntemdir.

Çalışma kapsamında, veri setinin özellikleri dikkate alındığında, LSTM ağ yapısının uygun olduğu düşünülmüştür.

3.4 Sistem Modeli

Tezin birinci bölümde, zaman serileri ile modellenen beklenmedik uçuş yönlendirmelerini azatma amacıyla METAR verileri kullanılarak görüş mesafesi tahmini (CTAF) yapılmıştır. Veri seti, meteorolojik veri olması sebebiyle, yakın geçmiş verilerinden etkilenen bir yapıdadır. Bu sebeple, yakın geçmiş zaman verilerinden öğrenerek, gelecek tahminlerde bulunabilen LSTM ağ yapısı kullanılarak, birinci bölümdeki sonuçların iyileştirilmesi amaçlanmıştır.

3.4.1 Veri Analizi

Tezin birinci bölümde, görüş mesafesi verisine sırasıyla uygulanan normalizasyon ve düzgünleştirme (smoothing) işlem basamakları aynı şekilde, bu bölümdede uygulanmıştır. Öznitelik seçimi kriteri, beklenmedik uçak yönlendirmelerini en fazla etkileyen özneliğin seçilmesi yoluyla olmuştur. Özniteliklerden, “görüş mesafesi düşüklüğü” beklenmedik uçak yönlendirmelerinin %90’ını oluşturduğu için, uygun bulunmuştur. Bu sebeple, ağ yapısının giriş katmanını, her bir yönlendirilmiş uçuş için, o ana kadar kaydedilmiş görüş mesafesi verileri oluşturmaktadır.

3.4.2 Ağ yapısı

Bu bölümde LSTM ağları kullanılarak yapılan zaman serisi tahmini işlenmektedir. Geçmiş verilerden hareketle, görüş mesafesi değerlerini tahmin eden bir LSTM ağı eğitilmiştir. Bu LSTM ağında bir adım kaydırılarak düzenlenen görüş mesafesi değerlerinin eğitilmesi sonucu elde edilen diziler, geleceğe yönelik görüş mesafesi tahminleridir. Başka bir deyişle, LSTM ağı, girdi dizisinin her bir adımında, bir sonraki zaman adımının değerini tahmin etmeyi öğrenmektedir.

Daha iyi bir uydurma (fitting) elde etmek ve eğitilen verinin sapmasını engellemek amacı ile görüş mesafesi verileri, tezin ilk kısmında belirtilen koşullar altında normalize edilmiştir.

Geriye dönük kaydırma işlemi, bir adım kaydırmalı ve beş adım kaydırmalı olarak iki şekilde uygulanmıştır. Bir dizinin gelecek zaman adımlarını tahmin etmek için, geriye dönük bir ve beş adım kaydırma işlemi Çizelge 3.3 ve Çizelge 3.4 ’deki gibi uygulanmıştır.

Çizelge 3.3: Bir Adım Kaydırmalı Girdi ve Çıktıları

Metar	Ağ Girdisi (X)	Ağ Çıktısı (Y)
9000	9000	10000
10000	10000	3000
3000	3000	3500
3500	3500	3800
3800	3800	4500
4500	4500	2500
2500	2500	10000
10000	10000	8000
8000		

Çizelge 3.4: Beş Adım Kaydırmalı Girdi ve Çıktıları

Me- tar	Ağ Girdisi 1	Ağ Girdisi 2	Ağ Girdisi 3	Ağ Girdisi 4	Ağ Girdisi 5	Ağ Çık- tısı
9000	9000	10000	3000	3500	3800	4500
10000	10000	3000	3500	3800	4500	2500
3000	3000	3500	3800	4500	2500	10000
3500	3500	3800	4500	2500	10000	8000
3800	3800	4500	2500	10000	8000	10000
4500	4500	2500	10000	8000	10000	10000
2500	2500	10000	8000	10000	10000	10000
10000						
8000						
10000						
10000						
10000						

n gözlem sayısını ifade etmek üzere, bir adım kaydırmalı girdi katmanı ve çıktı katmanı tek boyutlu ($nx1$) matristen oluşmaktadır. Beş adım kaydırmalı girdi katmanı ($nx5$) matris iken, çıktı katmanı ($nx1$) matristen oluşmaktadır. Başka bir deyişle, bir adım kaydırmalı dizide, her görüş mesafesi değeri, kendinden bir önceki adıma bağlıken, beş adım kaydırmalı dizide, her görüş mesafesi değeri kendinden önceki beş zaman adımına bağlıdır. Gerçek zaman dilimi olarak değerlendirildiğinde, iki buçuk saati ifade etmektedir.

Tezin birinci kısmında Auto.ARIMA ile elde edilen sonuçlarda, geçmişe yönelik beş adımın optimum zaman aralığı olduğu, iyilik kriterlerinden elde edilmiştir. Sonuçların karşılaştırılabilir olması açısından, bu bölümde de geçmişe dönük beş adım seviyede görüş mesafesi girdisinden yararlanılarak, tahminlemeler yapılmıştır.

3.4.3 LSTM ağ topolojisi

Bu bölümde, bir ve beş adım kaydırmalı iki farklı LSTM ağ topolojisi oluşturulmuştur. Oluşturulan topolojiler Çizelge 3.5’de gösterilmiştir. Ağ topolojisi dört katmandan oluşmaktadır, bu katmanlar; girdi katmanı, gizli katman, tam bağlantılı katman ve çıktı katmanıdır. Girdi katmanı Kısım 3.4.2’de belirtildiği gibi bir adım ve beş adım kaydırmalı olarak iki farklı şekilde ele alınmıştır. Diğer üç katmanın parametreleri ise sabit tutulmuştur.

Çizelge 3.5: Ağ Yapısı Topolojisi Çizelgesi

Katmanlar	Bir adım kaydırmalı	Beş adım kaydırmalı
Girdi Katmanı	1	5
Gizli Katman	200	200
Tam Bağlantılı Katmanı	1	1
Çıktı Katmanı	1	1

Topolojilerde Çizelge 3.6’daki ağ eğitim parametreleri kullanılmıştır.

Çizelge 3.6: Ağ Eğitim Parametreleri

Ağ Eğitim Parametreleri	Değer
Solver Name	“adam”
Max Epochs	250
Gradient Threshold	1
Initial Learn Rate	0.01
Learn Rate Drop Period	125
Learn Rate Drop Factor	0.2


Bu parametreler altında 84 ayrı uçuş yönlendirmeleri için bir ve beş adım kaydırmalı LSTM ağları ayrı ayrı çalıştırılmış olup, sonuçlar ilerleyen bölümlerde sunulmuştur.

3.5 Yapay Sinir Ağları Sonuçları

Bu kısımda bölüm 3.4’teki sistem modeli kullanılarak iki farklı girdi katmanına göre elde edilen sonuçlar paylaşılmıştır.


3.5.1 Bir adım kaydırmalı girdi katmanı sonuçları

Birinci bölümde zaman serilerini temsilen sunulan uçuş, bu bölümde de örnek olarak gösterilmiştir. İlgili uçuşa (18.10.2011, 20:20) ait bir adım kaydırmalı girdi katmanlı ağ modeline ait eğitim süreci Şekil 3.9’de verilmiştir. Şekil 3.9’da her bir iterasyon (epoch) için RMSE ve kayıp fonksiyonu (loss) değerleri sunulmuştur. Şekil 3.9 incelendiği zaman; tahmin edilen değerlerin gerçek veri ile aynı eğilimi gösterdiğini gözlemleyebiliriz.



Şekil 3.9: Bir Adım Kaydırmalı Ağ Eğitim Süreci

Şekil 3.10’da bir adım kaydırmalı yöntem için tahmin grafiği verilmiştir. Çizelge 3.7 ve Çizelge 3.8’de sırası ile RMSE tahmin değerleri ve uydurulmuş değerler gösterilmiştir. RMSE değeri 200 iterasyon (epoch) sonrası 0.0632617 olarak bulunmuştur. Bu değer iterasyon sayısı büyütülseydi daha da aşağı inebilirdi. Bu sebeple Bölüm 2’deki RMSE değerlerine göre düşük olarak gözlemlense bile performans olarak bölüm 2’ye göre daha yüksek seviyede gerçek veri eğilimini yakalamaktadır.



Şekil 3.10: Bir Adım Kaydırmalı Tahmin Grafiği

Çizelge 3.7: Bir Özellikli YSA Modeli için RMSE ve Tahmin Değerleri

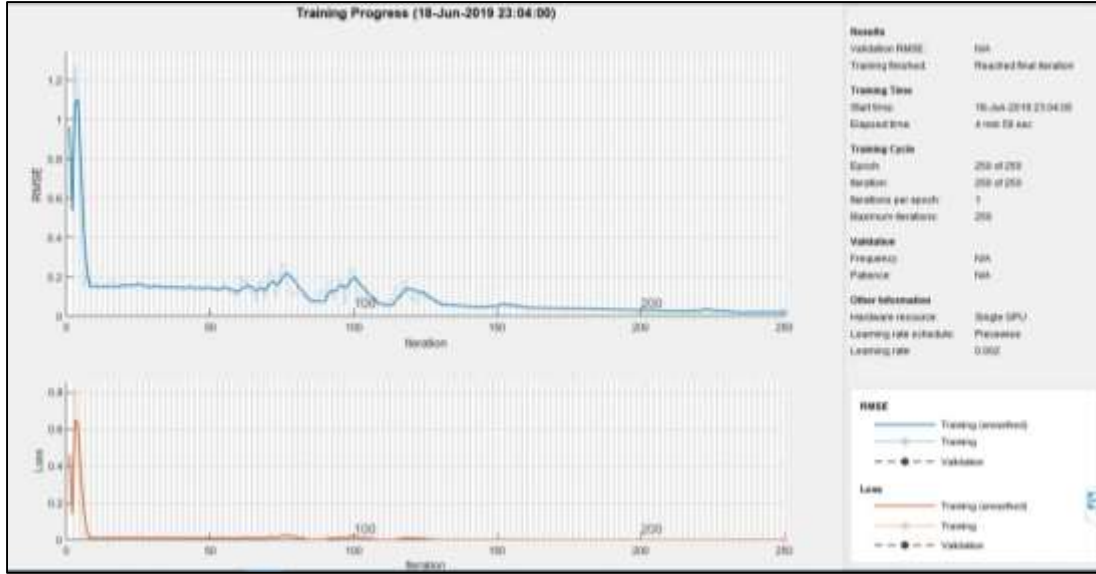
Yön. Uçuş Tarihi	RMSE	Forecast 1	Forecast 2	Forecast 3	Forecast 4	Forecast 5	Forecast 6
'18/10/2011 20:20:00'	0.063261 7	4.767	4.896	5.325	5.741	6.178	6.555

Çizelge 3.8: Bir Özellikli YSA Modeli için Uydurulmuş (fitted) Değerler

Uçuş Yön. T.	'18/10/2011 20:20:00'
Fitted 1	1.0039052
Fitted 2	1.0038767
Fitted 3	1.0088942
Fitted 4	1.0150613
Fitted 5	1.0163273
Fitted 6	1.0131135
Fitted 7	1.0097053
Fitted 8	1.0083945
Fitted 9	1.0077121
Fitted 10	1.0076208


3.5.2 Beş adım kaydırmalı girdi katmanı sonuçları

Şekil 3.11 incelendiği zaman; tahmin edilen değerlerin gerçek veri ile aynı eğilimi gösterdiğini gözlemleyebiliriz. Çizelge 3.9 ve Çizelge 3.10'da sırası ile RMSE tahmin değerleri ve uydurulmuş değerler gösterilmiştir. RMSE değeri 200 iterasyon (epoch) sonrası 0.0187206 olarak bulunmuştur. Bu değer iterasyon sayısı büyütülseydi daha da aşağı inebilirdi. Bu sebeple Bölüm 2'deki RMSE değerlerine göre düşük olarak gözlemlense bile performans olarak Bölüm 2'ye göre daha yüksek seviyede gerçek veri eğilimini yakalamaktadır.



Şekil 3.11: Beş Adım Kaydırmalı Ağ Eğitim Süreci

Beş adım kaydırmalı yöntem uygulanmış veri setinin tahmin grafiğini Şekil 3.12’de verilmiştir.



Şekil 3.12: Beş Adım Kaydırmalı Tahmin Grafiği

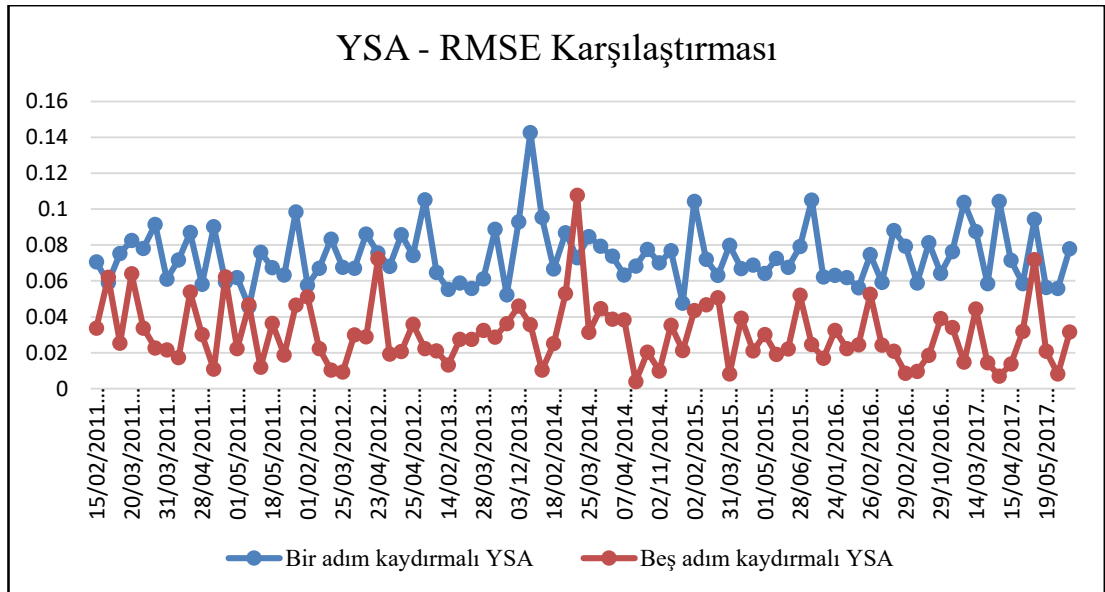
Çizelge 3.9: Beş Özellikli YSA Modeli için RMSE ve Tahmin Değerleri

Yön. Uçuş Tarihi	RMSE	Forecast 1	Forecast 2	Forecast 3	Forecast 4	Forecast 5	Forecast 6
'18/10/2011 20:20:00'	0.0187206678092480	4.820	5.033	5.039	5.386	5.669	5.854

Çizelge 3.10: Beş Özellikli YSA Modeli için Uydurulmuş (fitted) Değerler

Uçuş Yön. T	'18/10/2011 20:20:00'
Fitted 1	1.0408477
Fitted 2	1.0412197
Fitted 3	1.0422502
Fitted 4	1.0448376
Fitted 5	1.0457605
Fitted 6	1.0438536
Fitted 7	1.043533
Fitted 8	1.0446373
Fitted 9	1.0437006
Fitted 10	1.0412346

Şekil 3.13’de YSA yöntemleri uygulanmış veri seti için bir adım ve beş adım kaydırmalı yöntemlerin RMSE karşılaştırması verilmiştir.



Şekil 3.13: YSA - RMSE Karşılaştırması

Tezin ikinci kısmında YSA, LSTM ağı ile modellenen bir ve beş adım kaydırmalı yöntemler kendi aralarında karşılaştırıldıklarında, beş adım kaydırmalı yöntemin RMSE değerin daha düşük olduğu, yani ileriye dönük tahminlemede daha doğru (gerçeğe yakın) sonuçlar vereceği gözlemlenmiştir.

Çizelge 3.11’de YSA, LSTM Ağı beş adım kaydırmalı yönteme ait METAR ve CTAF kararlarının karşılaştırılması verilmiştir, burada amaç, görüş mesafesi düşüklüğü sebebiye oluşan yönlendirilmiş uçuş sayısını azaltmaktır. Görüş mesafesinin 4593 m’nin altında olduğu durumlarda “uçma” kararı verilmiştir. Dolayısıyla, CTAF ve METAR’ın “uçma” kararlarının örtüştüğü uçuş sayısı bizim için önemlidir. Amaçlanan, görüş mesafesi düşüklüğü sebebi ile yönlendirilecek uçuşu en baştan kaldırmamak olacaktır.

Çizelge 3.11: YSA Karışıklık Matrisi

		METAR		
		Karar		TOPLAM
		Uç	Uçma	
CTAF yöntemler	Uç	27	0	27
	Uçma	27	30	57
	TOPLAM	54	30	84

Seçilen metodolojinin öngürülerini yansıttığı olan CTAF kararları ile METAR kararlarına bakıldığında, 84 adet yönlendirilmiş uçuştan, kullanılan yöntem yardımı ile 30 tanesinin engellenebilmesi gözlemlenmiştir. Bu rakam ise % 36’lık bir iyileşme oranını ifade etmektedir.

3.6 Karışıklık matrislerinin karşılaştırılması

Çizelge 3.12 ve Çizelge 3.13’de verilmiş olan karışıklık matrislerine bakıldığında, uçak yönlendirmelerinin engellenmesine yardımcı nitelikte kararlar verilirken

yararlanılan zaman serisi analiz yöntemlerinden Auto.ARIMA ve YSA'ları yöntemlerinsden beş adım kaydırmalı LSTM ağı çıktıları karşılaştırıldığında, LSTM Ağı'nın yüzdelerik olarak daha iyi bir sonuç vermesi, bu çalışmada, karar destek sistemi olarak seçilmesine olanak sağlamıştır.

Çizelge 3.12: ZSA Karışıklık Matrisi

		METAR			
		Karar	Uç	Uçma	TOPLAM
CTAF	Uç	27	5	32	
	Uçma	27	25	52	
	TOPLAM	54	30	84	

Çizelge 3.13: YSA Karışıklık Matrisi

		METAR			
		Karar	Uç	Uçma	TOPLAM
CTAF	Uç	27	0	27	
	Uçma	27	30	57	
	TOPLAM	54	30	84	



4. SONUÇ VE ÖNERİLER

Beklenmedik uçuş yönlendirmeleri, havayolu işletmeleri tarafından, neden olduğu yüksek maliyet ve itibar kaybı sebebiyle olabildiğince en aza indirmek istenen bir durumdur. Meteorolojik verilerin kaotikliği bu durumun önündeki büyük bir engeldir. Ani hava değişimleri modellenemez ve tahmin edilemez niteliktedir, bu yüzden öğrenilen algoritmalar bile belirli bir iyileştirme oranının üzerine çıkamamaktadır. Geçmiş zaman verisi olarak adlandırılan METAR 'lardan yararlanarak gelecek zaman için öngörüle (CTAF) bulunabilmek adına 2010-2018 yılları arası yönlendirilmiş uçuşlar incelenmiştir. İncelemeler sonucunda, yönlendirmelerin %90 oranında nedeninin "görüş mesafesindeki düşüklük" olduğu saptanmıştır. Bu noktada amaç, görüş mesafesi düşüklüğünden kaynaklı yönlendirmeleri azaltmak olmuştur. Konu özelinde, bugüne kadar yapılmış çalışmalar ışığında, Zaman Serisi Yöntemlerinden, ARIMA modelinin geçmiş verilerden yararlanarak ileriye dönük öngörü yapmada başarılı ve sıklıkla kullanılan bir yöntem olduğu görülmüştür. Elimizdeki sekiz yıla ait, 130.000 adet veri R programlama dili üzerinden AR, MA, ARMA, ARIMA ve Auto.ARIMA yöntemleri ile modellenmiş, aralarında en düşük hata oranı ile gerçeğe en yakın tahmin değerini auto.ARIMA'nın verdiği görülmüştür. Sonuçlara göre 84 adet toplam yönlendirilmiş uçuş sayısını 59'a düşürerek %30 oranında bir iyileştirme sağlamıştır. Elde ettiğimiz bu sonucu daha da iyileştirmek adına, farklı yöntem arayışlarına girilmiş, yapılan araştırmalar sonucu, ancak "öğrenen" yapıların geçmiş zaman verilerini anlamlı bir şekilde kullanıp, gelecekle ilgili tutarlı öngörülerde bulunabileceği anlaşılmıştır. Makine öğrenmesinin temellerini oluşturan YSA'ları araştırılmıştır. Araştırmalar sonucunda; Tekrarlanan Sinir Ağları (RNN) yapısının probleme uygun olduğu görülmüş, kısa ve uzun dönem hafızalı (LSTM) ağ yapısı kullanılarak ileriye dönük bir ve beş adım kaydırmalı modeller uygulanmıştır, beş adım kaydırmalı modelin hata oranı daha düşük ve performansı daha yüksektir ve 84 yönlendirilmiş uçuş sayısını 54'e indirerek,

%36'lık bir iyileştirme sağlamıştır. Auto.ARIMA sonuçları ile karşılaştırıldığında sonucun belirli bir oranda iyileştiği görülmektedir. Elde edilen %36'lık oran çok yüksek görünmese de, kaotik verilerin hakim olduğu bir ortamda azımsanamayacak bir orandır. Mevcut oranı yükseltmek, sonuçları daha da iyileştirebilmek adına ileriki çalışmalarda Bulanık Mantık yöntemlerinden faydalanılacaktır.



KAYNAKLAR

- Agrawal, A., Kumar, V., Pandey, A. ve Khan, I.** (2012). An Application of Time Series Analysis for Weather Forecasting. *International Journal of Engineering Research and Applications*, 2(2), 974-980.
- Akdi, Y.** (2013). *Zaman Serileri Analizi*. Ankara: Gazi Kitapevi.
- Akgül, I.** (2003). *Zaman Serilerinin Analizi ve ARIMA Modelleri*. Türkiye: Der Yayınları.
- Alataş, B.** (2006). Sinirsel Ağlar. Erişim adresi <https://www.firat.edu.tr/akademik/fakulteler/muhendislik/bilgisayar/balatas/SinirselAglar.pdf>
- Altunkaynak, A., Başakin, E. E. (2018)**. Zaman Serileri Kullanılarak Nehir Akım Tahmini ve Farklı Yöntemlerle Karşılaştırılması. *Journal of Science and Technology* <https://doi.org/10.18185/erzifbed.339781>
- Alpaydın, E.** (2004). *Introduction To Machine Learning*. England: The MIT Press Cambridge.
- Anderson, D., Mcneill, G.** Artificial Neural Networks Technology. Erişim adresi <https://www.thedacs.com/techs/neural/neural.title.php>
- Adiyaman, F.** (2007). *Talep Tahmininde Yapay Sinir Ağlarının Kullanılması* (Yüksek lisans tezi, İstanbul Teknik Üniversitesi, İstanbul), Erişim adresi <https://polen.itu.edu.tr/xmlui/handle/11527/5861>
- Bahadır, M., & Saraçlı, S.** (2010). Isparta'da ARIMA Modeline Göre Sentetik İklim Verilerinin Analizi. *New World Science Academy*, 5(3), 163-177.
- Blinova T. O.** (2007). Analysis of Possibility of Using Neural Network to Forecast Passenger Traffic Flows in Russia. *Aviation*, 11(1), 28-34.
- Box, G., E., P., Jenkins, G.M.** (1976) *Time Series Analysis: Forecasting and Control*. San Francisco, CA: Holden-Day.
- Camargo L., Vargas, E., G., Perdomo, C., A.,** (2018). Analysis of the Reflectivity in Meteorological Radars Using Data Mining and Neural Networks. *Indian Journal of Science and Technology*. 11(19), 1-4.
- Çuhadar, M., Güngör, İ. ve Göksu A.,** (2009), Turizm Talebinin Yapay Sinir Ağları ile Tahmini ve Zaman Serisi Yöntemleri ile Karşılaştırmalı Ana-lizi: Antalya İline Yönelik Bir Uygulama, *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(1), 99-114.
- Desell, T., Clachar S., Higgins, J., Wild, B.** (2014). Evolving Neural Network Weights for Time-Series Prediction of General Aviation Flight Data. *International Conference on Parallel Problem Solving from Nature*. Erişim adresi https://link.springer.com/chapter/10.1007/978-3-319-10762-2_76

- Detienne, K. B., Detienne D. H. ve Joshi, S., A.,** (2003). Neural Networks As Statistical Tools For Business Researchers. *Organizational Research Methods*, 6(2), 236-265.
- ELMAS, Ç.** (2007). *Yapay Zeka Uygulamaları*. Ankara: Seçkin Kitapevi.
- Fabbian, D., De Dear, R., Lellyett, S.** (2007). Application of Artificial Neural Network Forecasts to Predict Fog at Canberra International Airport. *Weather and Forecasting*, 22(2), 372-381.
- Fahey, C.** (2006). Neural Network With Learning by Backward Error Propagation. Erişim adresi: https://www.colinfahey.com/neural_network_with_back_propagation_learning/neural_network_with_back_propagation_learning.html
- Göktaş, Ö.** (2005), *Teorik ve Uygulamalı Zaman Serileri Analizi*. İstanbul: Beşir Kitabevi.
- Gujarati, D., N.,** (2005), *Temel Ekonometri*. İstanbul: Literatür Yayıncılık.
- Hacıoğlu A.,** (2006). Hızlı Evrimsel Eniyileme İçin Yapay Sinir Ağı Kullanılması. *Havacılık ve Uzay Teknolojileri Dergisi*, 2(3), 1-8.
- Kaya, İ., Oktay, S., Engin, O.,** (2005). Kalite Kontrol Problemlerinin Çözümünde Yapay Sinir Ağlarının Kullanımı. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 21(1-2), 92-107.
- Kaynar, O., Taştan, S.,** (2009). Zaman Serisi Analizinde MLP Yapay Sinir Ağları ve Arıma Modelinin Karşılaştırılması. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. 0(33), 161-172.
- Kırbaşı, İ.** (2018). İstatistiksel Metotlar ve Yapay Sinir Ağları Kullanarak Kısa Dönem Çok Adımlı Rüzgar Hızı Tahmini. *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22(1), 24-38.
- Kıskac, B., Yardımcı, H.** (2004). Weather Prediction Expert System Approaches. Erişim adresi https://user.ceng.metu.edu.tr/~e132252/KE_Survey.pdf
- Kumar, N., Jha., G.** (2013). A Time Series ANN Approach for Weather Forecasting. *International Journal of Control Theory and Computer Modeling*, 3(1), 19-25.
- Kutlar, A.** (2000). *Ekonometrik Zaman serileri: Teori ve Uygulama*, Ankara: Gazi Kitapevi
- Marzban, C., Leyton, S., Colman, B.** (2007). Ceiling and Visibility Forecasts via Neural Networks. *Weather and Forecasting*, 22, 466-479.
- McCann, D. W.** (1992). A Neural Network Short-Term Forecast of Significant Thunderstorms. *Weather and Forecasting*, 7(3), 525-534.
- Murayziq, T.S., Kapetanakis, S., & Petridis, M.** (2017). Using Case-based Reasoning and Artificial Neural Networks for the Efficient Prediction of Dust Storms. *J. Expert Update*, 16, 39-48.
- Nury, A., Koch, M. ve Alam, M.,** (2013). Time Series Analysis and Forecasting of Temperatures in the Sylhet Division of Bangladesh. *4th International Conference On Environmental Aspects of Bangladesh (ICEAB)*, 24-26.

- Özer, H., Karagöz, M., Işık, H., Beşer, M. K., Işık, N., Koç, S.** (2013). *EKONOMETRİ*. İstanbul: Lisans Yayıncılık.
- Paras, Mathur, S.** (2012). A Simple Weather Forecasting Model Using Mathematical Regression. *Indian Research Journal of Extension Education Special Issues*, 1, 161-168.
- Radzuan, N., Othman, Z., Abu Bakar, A.** (2013). Uncertain Time Series in Weather Prediction. *Procedia Technology*
<https://doi.org/10.1016/j.protcy.2013.12.228>
- Ünsal, M. G.** (2010). *Zaman Serileri Analizinde Artık Türleri ve Uygulamaları* (Yüksek lisans tezi, Gazi Üniversitesi, Ankara), Erişim adresi www.acikarsiv.gazi.edu.tr/File.php?Doc_ID=3420
- Oundo, K.A.** (2012). Visibility Forecast Verification at Jomo Kenyetta International Airport. Erişim adresi http://erepository.uonbi.ac.ke/bitstream/handle/11295/56262/Oundo_Visibility%20forecast%20verification%20at%20Jomo%20Kenyatta%20International%20Airport.pdf?sequence=3&isAllowed=y
- Özmen, A.** (1986). *Zaman Serisi Analizinde Box- Jenkins Yöntemi ve Banka Mevduat Tahmininde Uygulama Denemesi*. Eskişehir: Anadolu Üniversitesi.
- Öztemel, E.** (2003). *Yapay Sinir Ağları*. İstanbul: Papatya Bilim Yayıncılık
- Makridakis, S., Wheelwright, S.,C.** (1989), *Forecasting Methods for Management*. Chichester: Wiley.
- Medar , R., Niranjana , P., Angadi, A., Tamase , P.** (2017). Comparative Study of Different Weather Forecasting Models . *International Conference on Energy, Communication, Data Analytics and Soft Computing*, 1604-1609.
- Montgomery C., Woodall, W.** (2008). An Overview of Six Sigma. *International Statistical Review*. 76 (3). 329-346.
- Pindyck, R. S., Rubinfeld, D. L.** (1998). *Econometric models and economic forecasts*. Boston, Mass: Irwin/McGraw-Hill.
- Radziukynas, V., Klementavičius, A.** (2014). Short-term Wind Speed Forecasting with ARIMA Model. *55th International Scientific Conference on Power and Electrical Engineering of Riga Technical University* <https://doi.org/10.1515/lpts-2016-0008>
- Rojas, R.** (1996). *Neural Networks - A Systematic Introduction*. Berlin: Springer-Verlag.
- Sak, H., Senior, Andrew., Beaufays, F.** (2014). Long short-term memory recurrent neural network architectures for large scale acoustic modeling. *Proceedings of the Annual Conference of the International Speech Communication Association, Interspeech*. Erişim adresi <https://static.googleusercontent.com/media/research.google.com/tr//pubs/archive/43905.pdf>
- Sfetsos, A.** (2000). A Comparison of Various Forecasting Techniques Applied to Mean Hourly Wind Speed Time Series. *Renewable Energy* 21(1), 23-25.

- Şen, Z.** (2004). *Yapay Sinir Ağları İlkeleri*. İstanbul: Su Vakfı Yayınları.
- Tortum, A., Çodur, M. Y.** (2014). Türkiye’de Hava Ulaşım Talebinin Arıma Modelleri ile Tahmin. *İğdır Üni. Fen Bilimleri Enst. Der.* 4(2), 39-54.
- Trani, A., A., Wing-Ho, F., C., Schilling, G., Baik, H., Seshadri, A.,** (2004). A Neural Network Model to Estimate Aircraft Fuel Consumption. *AIAA 4th Aviation Technology, Integration and Operations (ATIO) Forum* <https://doi.org/10.2514/6.2004-6401>.
- Uygunoğlu, T., Yurtcu, S.** (2006). Yapay Zeka Tekniklerinin İnşaat Mühendisliği Problemlerinde Kullanımı. *Yapı Teknolojileri Elektronik Dergisi.* 2(1), 61-70.
- Weatherford, L.R., Gentry T., Wilamowski, B.** (2003). Neural Network Forecasting for Airlines: A comparative analysis. *Journal of Revenue and Pricing Management,* 1(4), 319-331.
- Wójtowicz , M., Janiszewski , S.** (2014). Forecasting of Air Traffic: The Case Study of Oslo Airport. Erişim adresi <https://www.infona.pl/resource/bwmeta1.element.baztech-bad3559a-30fb-4b70-a8ee-f242fdcc71dd>
- Wu, Y., Hong, J.** (2007). A literature review of wind forecasting technology in the world. Erişim adresi: <http://assets.fiercemarkets.net/public/sites/energy/reports/ieewindforecasting.pdf>
- Yakubu , M., Gulumbe, S.** (2008). Forecasting of Temperature in Sokoto Metropolis Using Seasonal Modelling. *Nigerian Journal of Basic And Applied Sciences,* 16(1), 36-47.
- Yurtoğlu, H.** (2005). Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler için Türkiye Örneği. Erişim adresi: <http://www.sbb.gov.tr/wpcontent/uploads/2018/11/HasanYurtoglu.pdf>
- Diversion Management** (2014). Erişim adresi <https://www.iata.org/whatwedo/workgroups/Documents/ACC-2014-GVA/occ-5-diversion.pdf>
- Havacılık Amaçlı Rutin Hava Raporu** (2018). Erişim adresi <https://hezarfen.mgm.gov.tr /KodA/Default.aspx>
<https://www.dhmi.gov.tr/dosyalar/pdf/DHMi-Havacilik-Terimleri-Sozlugu.pdf>
- Auto.arima** (2018) <https://www.rdocumentation.org/packages/forecast/versions/8.7/topics/auto.arima>

ÖZGEÇMİŞ

Ad-Soyad : HAZAL BERVE DOĞAN
Uyruđu : T. C.
Dođum Tarihi ve Yeri : 01.01.1990 - ANKARA
E-posta : hazalbdogan@gmail.com

ÖĐRENİM DURUMU:

- **Lisans:** 2013, İstanbul Teknik Üniversitesi, İşletme Fakóltesi, Endüstri Mühendisliđi

MESLEKİ DENEYİM VE ÖDÜLLER:

Yıl	Yer	Görev
2017 -	STM A.Ş.	Sistem Mühendisi
2013 - 2016	DGN Mühendislik A.Ş.	Proje Mühendisi

YABANCI DİL: İngilizce, Fransızca