

**ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**TÜRK HAVA SAHASINDAKİ SİVİL HAVA TRAFİK YOĞUNLUĞUNUN
ZAMAN SERİLERİ VE YAPAY SİNİR AĞLARI İLE ANALİZİ**

Nurullah GÜLTEKİN

İSTATİSTİK ANABİLİM DALI

**ANKARA
2022**

Her hakkı saklıdır

ÖZET

Yüksek Lisans Tezi

TÜRK HAVA SAHASINDAKİ HAVA TRAFİK YOĞUNLUĞUNUN ZAMAN SERİLERİ VE YAPAY SİNİR AĞLARI İLE ANALİZİ

Nurullah GÜLTEKİN

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
İstatistik Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Sibel AÇIK KEMALOĞLU

Bu çalışmada Türkiye hava sahasında uçuş gerçekleştiren sivil hava trafiklerine ait veriler zaman serileri ve yapay sinir ağları analizi ile incelenmiştir. Hava yolu ulaşımı ve hava trafiği ile ilgili genel bilgi ve tanımlara değinildikten sonra literatürde zaman serileri analizi ile ilgili bazı tanım ve metotlar tanıtılmıştır. Uygulamada 2010-2019 yılları arasında ülkemiz hava sahasında uçuşunu gerçekleştirmiş sivil uçak sayıları dikkate alınmıştır. İlgili verilerde mevsimsellikten arındırma işlemi yapılmış daha sonra durağanlık tespiti için genişletilmiş Dickey-Fuller birim kök testi uygulanmıştır. Durağanlaştırma işleminden sonra uygun ARIMA modeli belirlenmiş ve modelin uygunluğu ile ilgili 2018-2019 yılları için model öngörülleri ile gerçekleşen uçuş sayıları karşılaştırılmıştır. Daha sonra ilgili modelden yararlanılarak 2020-2022 yıllarına ait öngörülerde bulunulmuştur. Bu öngörüler yapıldıktan sonra, son yıllarda zaman serileri analizinde yaygın olarak kullanılan metotlardan biri olan yapay sinir ağları yöntemlerinden ‘ileri beslemeli yapay sinir ağları (FFNN)’ ve ‘çok katmanlı algılayıcı (MLP)’ modelleri ilgili verilere uygulanıp söz konusu zaman aralığına ait öngörüler yeniden hesaplanmıştır. Öngörü performansları, kurulan modeller göz önüne alınarak çeşitli performans kriterleri baz alınıp karşılaştırılmıştır. Hesaplanan tüm öngörüler ile 2020 yılının başlarından itibaren tüm dünyada etkisini gösteren Covid 19 salgını sebebiyle düşen uçuş sayıları grafikler üzerinde gösterilmiş ve salgının Türkiye hava sahasındaki hava trafik yoğunluğuna etkisinin ne boyutta olduğuna ilişkin karşılaştırmalar yapılmıştır.

Ocak 2022, 58 sayfa

Anahtar Kelimeler: Zaman serileri, ARIMA modeli, yapay sinir ağları, hava trafiği, DHMİ(Devlet Hava Meydanları İşletmesi)

ABSTRACT

Master Thesis

ANALYSIS OF AIR TRAFFIC VOLUME IN TURKISH AIRSPACE WITH TIME SERIES AND ARTIFICIAL NEURAL NETWORKS

Nurullah GÜLTEKİN

Ankara University
Graduate School of Natural and Applied Sciences
Department of Statistics

Supervisor: Asst. Prof. Dr. Sibel AÇIK KEMALOĞLU

In this study civil air traffic data using Turkish airspace has been analyzed with time series analysis. After presenting general information about air transportation and air traffic, some definitions and methods which exist in the literature have been presented. In the application, civil airplane numbers flew in Turkish airspace between 2010-2019 have been taken into account. Following seasonal adjustment procedure has been implemented to the original data, to check potential stationarity, augmented Dickey-Fuller unit root test has been applied. After stationarity processes, proper ARIMA model has been determined and this model's forecasts has been checked by comparing the actual flights for the years 2018-2019. Later, relevant forecasts have been made for 2020-2022 by using the model. After these forecasts, two of the special types of Artificial Neural Networks models, which are commonly used recently, 'feed-forward neural networks (FNNN)' and 'multi-layer perceptron (MLP)' were implemented the same data. The forecast performances were compared based on some performance criteria. These forecasts and the actual flight numbers which have been impacted by the global Covid 19 pandemic since the beginning of 2020 have been compared to understand the magnitude of the pandemic effects in Turkish Airspace.

January 2022, 58 pages

Key Words: Time series, ARIMA models, artificial neural networks, air traffic, DHMI(General Directorate of Civil Airport Authority)

TEŞEKKÜR

Bu çalışmanın tüm aşamalarında yardım ve desteklerini esirgemeyen değerli hocalarım Dr. Öğr. Üyesi Sibel AÇIK KEMALOĞLU'na ve Prof. Dr. Mehmet YILMAZ'a en içten dileklerimle teşekkür ederim.

Bu süreçte fedakarlıkları ile bana destek olan sevgili eşim Sevda'ya, canım kızlarım Zeynep ile Elif'e ve aileme tüm kalbimle teşekkürü bir borç bilirim.

Nurullah GÜLTEKİN
Ankara, Ocak 2022



İÇİNDEKİLER

TEZ ONAY SAYFASI

ETİK.....	i
ÖZET.....	ii
ABSTRACT	iii
TEŞEKKÜR	iv
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	ix
1. GİRİŞ	1
1.1 Hava Yolu Taşımacılığı	2
1.2 Hava Trafığı	2
2. ZAMAN SERİLERİ ANALİZİ.....	6
2.1 Zaman Serilerinin Tanımı, Özellikleri ve Bazı Önemli Kavramlar.....	6
2.1.1 Zaman serilerinin bileşenleri	8
2.1.2 Zaman serilerinin sınıflandırılması	9
2.2 Zaman Serileri Analizinde Kullanılan Bazı Önemli Kavramlar.....	9
2.2.1 Durağanlık.....	9
2.2.2 Tahmin, kestirim ve öngörü	11
2.2.3 Model sadeliği.....	11
2.3 Zaman Serisi Modelleri	11
2.3.1 Hareketli ortalamalar (Moving average-MA) modelleri	12
2.3.2 Otoregresif (Autoregressive) modeller	13
2.3.3 Otoregresif hareketli ortalamalar modeli (Autoregressive moving average-ARMA).....	13
2.3.4 Entegre otoregresif hareketli ortalamalar modeli (Autoregressive integrated moving average-ARIMA)	14
2.3.5 Mevsimsel entegre otoregresif hareketli ortalamalar modeli (Seasonal autoregressive integrated moving average-SARIMA)	15
2.4 Durağanlık Analizi ve Birim Kök Testleri.....	16
2.4.1 Dickey-Fuller testi ve genişletilmiş Dickey-Fuller testi	16
2.4.2 Phillips-Peron testi.....	17
2.5 Model Seçimi	18
2.5.1 Otokorelasyon (ACF) ve kısmi otokorelasyon fonksiyonu (PACF).....	18
2.5.2 Box-Jenkins metodu	19
2.5.3 Model performansı ölçüm kriterleri	20

3. YAPAY SİNİR AĞLARI.....	23
3.1 Yapay Sinir Ağları.....	23
3.2 Yapay Sinir Ağları Modelleri	23
3.2.1 İleri beslemeli yapay sinir ağları (Feed forward neural network- FFNN).....	24
3.2.2 Çok katmanlı algılayıcı modeli (Multi layer perceptron- MLP).....	25
3.2.3 Geri beslemeli yapay sinir ağları (Recurrent neural networks- RNN).....	26
4. UYGULAMA	28
4.1 Veri.....	28
4.2 ARIMA Analizi Uygulaması	29
4.3 Yapay Sinir Ağları Analiz Uygulaması.....	43
4.4 Küresel Salgının Hava Trafik Yoğunluğuna Etkisi	50
5. SONUÇ	53
KAYNAKLAR	56
ÖZGEÇMİŞ.....	58

ŞEKİLLER DİZİNİ

Şekil 1.1 2002-2019 yılları arası Türk hava sahasında gerçekleşen sivil hava trafik yoğunluğu verileri	4
Şekil 2.1 Box-Jenkins metodu ile model seçim aşamaları	20
Şekil 3.1 Tek katmanlı FFNN modeli	25
Şekil 3.2 Çok katmanlı FFNN modeli	25
Şekil 3.3 RNN modeli	27
Şekil 4.1 2010-2019 yılları arası aylık sivil uçak verilerinin grafik gösterimi	30
Şekil 4.2 2010-2019 yıllarına ait sivil uçak verilerinin aylık ortalamaları	31
Şekil 4.3 2010-2019 yıllarına ait sivil uçak verilerinin yıllara göre ayrılmış gösterimi	31
Şekil 4.4 2010-2019 yıllarına ait sivil uçak verileri serisinin otokorelasyon fonksiyonu grafiği	32
Şekil 4.5 2010-2019 yıllarına ait sivil uçak verileri serisinin kısmi otokorelasyon fonksiyonu grafiği	32
Şekil 4.6 Genişletilmiş Dickey-Fuller (ADF) testi sonuçları.....	33
Şekil 4.7 2010-2019 yıllarına ait sivil uçak verileri serisinin bileşenlerine a yırıştırılmış hali.....	34
Şekil 4.8 Mevsimsellikten arındırılmış 2010-2019 yıllarına ait sivil uçak verileri serisi.....	35
Şekil 4.9 Mevsimsellikten arındırılmış 2010-2019 yıllarına ait sivil uçak verileri serisinin aylık bazda ortalamaları	35
Şekil 4.10 Mevsimsellikten arındırılmış 2010-2019 yıllarına ait sivil uçak verileri serisinin ACF ve PACF grafikleri	36
Şekil 4.11 İkinci kez gerçekleştirilen Genişletilmiş Dickey-Fuller Testi sonuçları.....	37
Şekil 4.12 Fark alma işlemi uygulandıktan sonra 2010-2019 yıllarına ait sivil uçak verileri serisinin grafik gösterimi	38
Şekil 4.13 Farkı alınmış 2010-2019 yıllarına ait sivil uçak verileri serisinin ACF ve PACF grafikleri	39
Şekil 4.14 Üçüncü kez gerçekleştirilen genişletilmiş Dickey-Fuller Testi sonuçları	40
Şekil 4.15 ARIMA(1,1,1)(1,1,1) ₁₂ modeli yardımıyla elde edilen öngörüler ile gerçekleşen durumun karşılaştırması	42
Şekil 4.16 ARIMA(1,1,1)(1,1,1) ₁₂ modeli yardımı ile 2022 yılına kadar elde edilen öngörüler.....	43
Şekil 4.17 FFNN NNAR(1,1,2) ₁₂ modeli yardımıyla hesaplanan 2020-2022 yıllarına ait öngörülerin grafik gösterimi	45

Şekil 4.18 FFNN NNAR(1,1,2) ₁₂ modeli ile ARIMA(1,1,1)(1,1,1) ₁₂ modelinden elde edilen öngörülerin karşılaştırması.....	46
Şekil 4.19 MLP modeli	47
Şekil 4.20 MLP modeli yardımıyla elde edilen öngörüler	48
Şekil 4.21 MLP ve ARIMA(1,1,1)(1,1,1) ₁₂ modelleri yardımıyla elde edilen öngörülerin karşılaştırılması	50
Şekil 4.22 ARIMA(1,1,1)(1,1,1) ₁₂ modeli yardımıyla elde edilen öngörüler ile gerçekleşen hava trafik yoğunluğunun görsel karşılaştırılması.....	51
Şekil 4.23 MLP modeli yardımı ile elde edilen öngörüler ile gerçekleşen hava trafik yoğunluğunun görsel karşılaştırılması.....	52



ÇİZELGELER DİZİNİ

Çizelge 4.1 2010-2019 yılları arasında Türkiye hava sahasını kullanan aylık sivil uçak trafiği sayıları (Anonim 2021)	29
Çizelge 4.2 Farklı model denemelerinden elde edilen AIC, RMSE ve MAPE değerleri.....	41
Çizelge 4.3 ARIMA(1,1,1)(1,1,1) ₁₂ model parametre tahminleri.....	41
Çizelge 4.4 ARIMA(1,1,1)(1,1,1) ₁₂ modeli yardımı ile elde edilen 2020-2022 yıllarına ait öngörüler	42
Çizelge 4.5 FFNN modeli yardımıyla hesaplanan 2020-2022 yıllarına ait öngörüler	44
Çizelge 4.6 FFNN NNAR(1,1,2) ₁₂ modeli ile ARIMA(1,1,1)(1,1,1) ₁₂ modelinin performanslarının karşılaştırılması.....	47
Çizelge 4.7 MLP modeli yardımı ile elde edilen öngörüler.....	48
Çizelge 4.8 FFNN NNAR(1,1,2) ₁₂ , ARIMA(1,1,1)(1,1,1) ₁₂ ve MLP modelleri ile yapılan analizlerin performanslarının karşılaştırılması	49

1. GİRİŞ

İnsanlık tarihi boyunca lojistik faaliyetler medeniyetlerin gelişiminde önemli bir rol oynamıştır. İnsan, mal, hayvan veya kargonun bir yerden başka bir yere taşınması ihtiyacı eski çağlardan beri medeniyetler tarihinde önemli bir yer tutar. Bir kişi veya nesnenin bulunduğu yerden farklı bir yere aktarılmasına ulaşım denir (Anonymous 2020). Ulaşım çeşitleri günümüzde havayolu ulaşımı, kara yolu ulaşımı, demir yolu ulaşımı ve deniz yolu ulaşımı olarak sınıflandırılabilir. Eski çağlarda, özellikle binek hayvanlarının ehlileştirilip taşımacılıkta kullanılmaya başlanmasıyla kara yolu ulaşımı yaygın iken, daha sonraki çağlarda su üstü araçların icat edilip kullanıma sunulması deniz yolu ulaşımını da yaygınlaştırmıştır. Buhar makinelerinin ulaşım araçlarında kullanımının yaygınlaşması ve 19. yüzyılda ilk içten yanmalı motorların icadı ile kara yolu ve deniz yolu taşımacılığının gelişmesine ilave olarak demir yolu taşımacılığı da ulaşımında önemli bir yer edinmiştir.

Bu çalışma beş bölümden oluşmaktadır. Giriş bölümünde ulaşım, ulaşım çeşitleri, hava yolu ulaşımı ve hava trafiği ile ilgili tanım ve genel bilgilerden bahsedilmiştir. İkinci bölümde zaman serileri analizi ile ilgili yöntem ve modeller tanıtılmıştır. Ayrıca bu bölümde durağanlık ve birim kök testleri ile ilgili kavramların üzerinde durulmuştur. Üçüncü bölümde son yıllarda zaman serileri analizinde yaygın olarak kullanılan yöntemlerden biri olan yapay sinir ağları yöntemleri tanıtılmıştır. Dördüncü bölümde 2010-2019 yılları arasında Türkiye hava sahasını kullanan sivil uçak trafiği verilerine ilişkin uygulama yapılmıştır. Son olarak beşinci bölümde ise söz konusu uygulamadan elde edilen çıktılar değerlendirilmiş ve 2020 yılı başından itibaren tüm dünyada etkisini gösteren Covid 19 pandemisinin sivil hava trafiğine olan etkisi karşılaştırmalı olarak sunulmuştur. Yapılan karşılaştırmalı analizler sonucunda üç farklı yöntem ile 2020-2022 yıllarına ait öngörüler hesaplanmış ve bu öngörülerin performansları karşılaştırılmıştır.

1.1 Hava Yolu Taşımacılığı

Uçuş tutkusu insanlık tarihinde hep bir amaç olarak yer almış olmasına karşın fotoğrafla kaydedilen ilk havadan ağır motorlu uçuş Wright kardeşler tarafından 17 Aralık 1903'te gerçekleştirilmiştir (Anonymous 2013). Bu olay havacılık tarihinde bir dönüm noktası olarak kabul edilmektedir. Havadan ağır, motor gücü ile seyreden yapay veya doğal özel platformlara inip kalkabilen hava aracına uçak denilmektedir (Anonim 2011). İlk zamanlarda uçaklar daha çok askeri amaçlarla kullanılmasına rağmen ilk tarifeli ticari uçuş bir deniz uçağıyla 1 Ocak 1914'te St. Petersburg/Florida'da gerçekleştirilmiştir (Anonymous 2010). Daha sonraları ticari havacılık faaliyetleri özellikle 2. Dünya Savaşı'ndan sonra büyük bir mesafe kat etmiştir. 20. yüzyılın dördüncü çeyreğine kadar havacılık teknolojilerindeki ilerlemeler ve bu teknolojilerin ticari amaçlarla kullanımı iyice yaygınlaşmış, bununla birlikte gökyüzünde artan uçak sayısı beraberinde artan hava trafiğinin kontrolünü gerektirmiştir.

Devletler hem ticari hem de güvenlik amacıyla egemen oldukları hava sahalarını kontrol etme ihtiyacı duymuşlardır. 20. yüzyılın başlarında icat edilen ve daha sonra geliştirilen radarların havacılıkta kullanımının yaygınlaşmasıyla, ilgili havacılık otoriteleri hava sahalarında hem güvenliği sağlamayı hem de hava trafiğini emniyetli ve etkin bir şekilde idare etmeyi amaçlamışlardır. Bununla birlikte havacılıkta standart kurallar belirlemek ve havacılığın düzenli ve emniyetli bir şekilde büyümesini sağlamak gibi amaçlarla uluslararası sivil havacılık organizasyonları kurulmuştur. Önde gelen uluslararası sivil havacılık organizasyonlarından bazıları şunlardır: 1944'te kurulan, Türkiye'nin de kurucu üyeleri arasında yer aldığı ICAO (International Civil Aviation Organisation-Uluslararası Sivil Havacılık Örgütü) ve 1963'te kurulan, Türkiye'nin 1989'da üye olduğu EUROCONTROL (Avrupa Hava Seyrüsefer Emniyeti Teşkilatı) (Anonim 2021).

1.2 Hava Trafiği


Sabit yüzeyler üzerinde bir takım aerodinamik reaksiyonlarla havada tutunabilen, havadan ağır, motor gücüyle işleyen araçlara hava aracı, bir havaalanının manevra

sahasında ya da uçuşta hareket eden hava araçlarına da hava trafiği denilmektedir (Anonim 2011).

Hava trafiğini oluşturan hava araçları uçuşlarını iki şekilde icra ederler. Bunlardan biri aletli uçuş kuralları ile gerçekleşen uçuşlardır (IFR, Instrument Flight Rules). IFR uçuşlarda hava aracında aktif olarak bulunan elektronik veya mekanik sistemler yardımıyla uçuş gerçekleştirilir. Bir diğer uçuş şekli de görerek uçuş kuralları ile icra edilen uçuşlardır (VFR, Visual Flight Rules). VFR uçuşlarda hava aracını yöneten pilot ya da pilotlar uçuşlarını, hava şartlarının görerek uçmaya müsait olduğu hallerde görsel temas ile gerçekleştirirler. Bu çalışmadaki hava trafiği verileri IFR hava trafiklerini kapsamaktadır.

Ulaşım çeşitleri arasında en hızlı taşımacılığı sağlaması sebebiyle hava yolu ulaşımı günümüz dünyasında önemli bir yer kaplamaktadır. Özellikle olağanüstü durumların yaşandığı (doğal afet vb.) bölgelere gerekli yardımların zamanında ulaştırılmasından, organ nakli bekleyen ya da hastaneye yetiştirilmesi gereken bir hastanın zamanında ve güvenli bir şekilde intikalinin sağlanması gibi durumlarda hava yolu ulaşımının önemi daha fazla anlaşılmaktadır. Bunun yanı sıra hava yolu ulaşımı, turizm amaçlı yolcu taşımacılığında ya da ticari kargo taşımacılığında özellikle uzun mesafelerde günümüz dünyasının vazgeçilmez bir ihtiyacı haline gelmiştir. Ayrıca askeri lojistik faaliyetlerinde ve güvenlik politikalarıyla paralel olarak askeri personel veya kargo taşımacılığında da hava yolu ulaşımı günümüz dünyasının vazgeçilmezleri arasındadır.

Böylesine büyük bir organizasyonun güvenli, emniyetli ve düzenli bir şekilde idare edilebilmesi için devletler, bünyelerinde hava seyrüsefer hizmetlerini sağlamak üzere kurum ve kuruluşlar oluşturmuşlardır. Türkiye’de bu hizmet DHMİ (Devlet Hava Meydanları İşletmesi) bünyesinde verilmektedir. Türkiye’de havacılığın gelişimi özellikle 2000’li yıllardan sonra çıkarılan kanunlar ve sağlanan teşviklerle birlikte özel sektör teşebbüslerinin arttığı ve hava sahasındaki ticari hava trafik yoğunluğunun önemli ölçüde ivme kazandığı 2002-2019 yıllarına ait sivil hava trafik verileri görsel olarak şekil 1.1’de gösterilmiştir (Anonim 2021).



Şekil 1.1 2002-2019 yılları arası Türk hava sahasında gerçekleşen sivil hava trafik yoğunluğu verileri

Şekil 1.1 incelendiğinde hava sahasını kullanan hava trafiği sayılarında özellikle 2003 yılından sonra ivmeli olarak artış gözlenmektedir. Bunun temel sebebi 2001 yılında çıkarılan sivil havacılık alanındaki kanun ve düzenlemeler ile birlikte devletin özel sektör teşebbüslerinin önünü açmasıdır (Şen ve Polat 2015). Sivil havacılık alanındaki bu yapısal değişiklikler kısa sürede sonuç vermiş ve Türkiye hava sahasını kullanan iç ve dış hat trafikleri ile birlikte transit uçuşlarda da artışlar gözlenmiştir. Bununla birlikte özellikle yerli hava yolu firmaları artan ihtiyacı karşılamaya yönelik planlamalar yapmış ve filolarındaki uçak sayılarını artırmak amacıyla yeni yatırım teşebbüslerinde bulunmuşlardır.

Türkiye'nin bulunduğu jeopolitik konum itibarıyla hava sahası, özellikle uzak doğu ve orta doğu ile Avrupa'nın arasında bir köprü vazifesi görmektedir. Özellikle son 15 yılda bölgedeki siyasal istikrarsızlıklar ve savaşlar Türkiye hava sahasının önemini artırmıştır. Özellikle bölgede meydana gelen Suriye iç savaşı, Irak'taki siyasal istikrarsızlıklar, Ukrayna'daki iç karışıklıklar gibi olaylar neticesinde ilgili ülkelerin hava sahalarının güvensizliği havacılık otoriteleri ve hava yolu firmalarının rota

planlamaları yaparken Türkiye hava sahasını kullanmayı tercih etmelerine yol açmış ve bu durum hava sahasının yoğunluğunu artıran bir diğer etken olmuştur. Türkiye hava sahasının yoğunluğuna etki eden bir diğer transit rota ise kuzey ülkeleri (Rusya, Ukrayna vb.) ile Türkiye'nin güneyinde yer alan ve önemli turistik merkezlere sahip Orta Doğu ülkeleri arasındaki rotadır. Özellikle yaz aylarında artış gösteren talepler neticesinde kuzey-güney transit rotalarının yoğunluklarında da artışlar gözlenmektedir.



2. ZAMAN SERİLERİ ANALİZİ

2.1 Zaman Serilerinin Tanımı, Özellikleri ve Bazı Önemli Kavramlar

Periyodik zaman aralıklarında gözlenen ölçümlerin bir dizisine zaman serisi denmektedir (Akdi 2012). Bir diğer ifade ile belirli bir zaman periyodunda gözlem ve ölçümlerin kronolojik olarak sıralanmasıyla elde edilen nümerik değerler bütünü zaman serisi olarak adlandırılır. Genel olarak bir dizi gözlem zaman serisi olarak ifade edildiğinde, gözlem sıklığı ile ilgili belirli bir düzen (yıllık, aylık gibi) varsayımı yapılır (Lüthkepol ve Kratzig 2004).

Zaman serilerinin literatürde teorik gelişimi, stokastik süreçler ile ilgili çalışmaları takiben Yule-Walker denklemi olarak adlandırılan ilk otoregresif model uygulamaları ile 1930'larda başlamıştır. 1970'lerde George E. P. Box ve Gwilym M. Jenkins'in meşhur kitabı "Time Series Analysis"de zaman serileri analizinde günümüzde de yaygın olarak kullanılan Box-Jenkins modelleri tanıtılmıştır. Bu modeller son yıllarda dinamik bir araştırma konusu olmuş ve birçok farklı alanda çalışmalarını sürdüren araştırmacıların ilgisini çekmiştir. Box-Jenkins modelleri ile analiz yapılırken tek değişkenli bir seri için kurulan model için şu aşamalar öne sürülmüştür: tanımlama, tahmin, teşhis ve öngörü (Anonymous 2017). Bunun yanı sıra literatürde 70'den fazla doğrusal veya doğrusal olmayan öngörü metodu bulunmaktadır (Kerkkanen vd. 2009).

Zaman serileri analizinde ana amaç geçmiş dönem gözlem verilerini incelemek, verilerde (varsa) analiz yapmayı zorlaştıracak düşünülen verilerle ilgili gerekli işlemleri yapmak ve son olarak verilere en uygun modeli belirlemektir. Bu model belirlenirken incelenen verinin karakteristiği önemlidir. Çünkü gerçekte istatistiksel analiz yapılırken genelde bir veya birden çok varsayımda bulunulur. Daha sonra ise analiz için kurulan modelden yararlanılarak seriye yönelik gelecek öngörüler yapılabilir. Bu bağlamda zaman serileri analizi ile öngöründe bulunmak, geçmişini anlayarak geleceği kestirmek olarak adlandırılabilir (Adhikari ve Agrawal 2013).

Zaman serileri, ‘veri’ ile analiz yapılabilen bilimin hemen hemen bütün alanlarında karşımıza çıkmaktadır (Mills 2019). Zaman serileri analizinde kullanılabilecek verilere örnek olarak yıllık ihracat ya da ithalat rakamları, yıllık kişi başına düşen milli gelir, aylık enflasyon verileri, günlük hava sıcaklıkları veya bir cihazın yaydığı saatlik ya da dakikalık ses titreşimleri verilebilir. İlgilenilen verinin özelliğine göre zaman periyodu daha kısa veya daha uzun olabilir.

Zaman serileri, serinin kesikli veya sürekli olmasına bağlı olarak kesikli ya da sürekli olabilir. Uygulamada karşılaşılan örnekler genelde sürekli olmasına karşın yapılacak analizin karmaşıklıklaşmaması için bu seriler çeşitli işlemlerle kesikli hale getirilebilir. (Duru 2007).

Eğer bir zaman serisinin gelecek değerleri tam olarak matematiksel bir fonksiyon ile ifade edilebiliyorsa, örneğin; $z_t = \sin(2\pi ft)$ gibi, bu zaman serisi deterministiktir. Öte yandan gelecek değerler sadece bir olasılık dağılımı yönünden ifade edilebiliyorsa bu seriye deterministik olmayan ya da istatistiksel zaman serisi denir. Zaman söz konusu olduğunda olasılık kanunlarına göre stokastik süreç adı verilen bir olgu ortaya çıkmaktadır (Box vd. 1979). Stokastik süreç, gelişimi zamana bağlı rastgele değişkenlerin bir koleksiyonu olarak adlandırılır (Lawler 2006). Dolayısıyla bir zaman serisi analiz edilirken bir stokastik süreç olarak değerlendirilebilir.

T bir indis kümesi olmak üzere eğer T reel sayı veya $[0,1]$ gibi sürekli aralıklar olarak seçilirse $\{Y_t: t \in T\}$ zaman serisine sürekli zamanlı stokastik süreç, eğer T doğal sayılar ya da tam sayılar kümesi olarak seçilirse $\{Y_t: t \in T\}$ rastgele değişkenlerin koleksiyonuna bir zaman serisi adı verilir (Akdi 2012). Zaman serilerinde analiz yapılırken genelde $t = 1, 2, \dots, T$ eşit aralıklı gözlem periyotlarını göstermek için kullanılır.

2.1.1 Zaman serilerinin bileşenleri

Zaman serileri genel olarak 4 bileşenden oluşur. Bunlar trend, mevsimsel bileşen, konjonktürel bileşen ve düzensiz bileşendir.

Trend, bir zaman serisinin artma, azalma ya da sabit kalma eğilimidir. Daha açık bir ifade ile trend, bir zaman serisinin yeterli uzunlukta bir zaman periyodundaki değişimi ya da sabit kalma eğilimidir. Özellikle ekonomi ile doğrudan ya da dolaylı olarak ilişkili verilerde trend gözlenebilir. Örnek olarak gelişmekte olan ülkelerin kişi başına düşen milli gelirleri, nüfusları gibi veriler bir zaman serisi olarak ifade edildiğinde genelde trend gözlenir.

Mevsimsel bileşen, bir zaman serisinde yılın belirli mevsimlerinde, mevsime bağlı gelişmelerden etkilenerek seride meydana gelen dalgalanmaları ifade eder. Zaman serileri analizinde mevsimsellik, durağan dışılığı içerdiğinden göz ardı edilmesi durumunda sonuçların güvenilirliğini doğrudan etkiler (Sampson 2001). Mevsimselliğe örnek olarak doğalgaz tüketiminin kış mevsiminde artıp yazın azalması verilebilir.

Konjonktürel bileşen, bir zaman serisinde orta vadede ortaya çıkan ve döngüsel olarak tekrar eden değişimleri ifade etmektedir (Adhikari ve Agrawal 2013). Bu döngüler bazen birkaç yıl sürebildiği gibi daha kısa da sürebilir. Özellikle ekonomik ya da ekonominin etkilediği verilerle oluşturulan zaman serilerinde genelde bu değişimlere rastlanır.

Düzensiz bileşen, önceden tahmin edilemeyip belirli bir periyotla devam etmeyen, hata terimi olarak nitelendirilebilecek değişimlerdir. Bu değişimlerin ölçülebileceği istatistiksel bir yöntem bulunmamaktadır (Adhikari ve Agrawal 2013). Örnek olarak savaş, doğal afet gibi durumların bir ülkedeki makro ekonomik verilere etkisi verilebilir.

2.1.2 Zaman serilerinin sınıflandırılması

Zaman serileri yukarıda anlatılan dört bileşenin bir fonksiyonu olarak genelde toplamsal ya da çarpımsal olarak ifade edilebilir. T ile trend, M ile mevsimsel bileşen, K ile konjonktürel bileşen ve D ile düzensiz bileşen gösterilmek üzere bu modeller;

Çarpımsal model: $Y_{(t)} = T_{(t)} \times M_{(t)} \times K_{(T)} \times D_{(t)}$

Toplamsal model: $Y_{(t)} = T_{(t)} + M_{(t)} + K_{(T)} + D_{(t)}$ şeklinde gösterilir.

Toplamsal modelde bileşenlerin birbirinden bağımsız olduğu varsayılırken çarpımsal modelde böyle bir varsayıma ihtiyaç yoktur (Adhikari ve Agrawal 2013).

2.2 Zaman Serileri Analizinde Kullanılan Bazı Önemli Kavramlar

2.2.1 Durağanlık

Durağanlık zaman serileri analizinde önemli bir varsayım olarak karşımıza çıkmaktadır. Durağan olmayan zaman serileri ile analiz yapılması durumunda sahte regresyon gibi matematiksel karmaşıklığı artıran durumlar ortaya çıkabilmektedir. Sahte regresyonda değişkenlerin tümünün veya bir kısmının trende sahip olmaları sonucunda değişkenler arasındaki ilişki gerçek ilişkiyi yansıtmayabilir. Dolayısıyla bu durum yanlış öngörü yapılmasına sebep olur. O halde zaman serileri ile analiz yapılmadan önce ilgili zaman serisinin durağan olup olmadığı kontrol edilmeli ve eğer seri durağan değil ise durağan hale getirilmelidir.

Bir stokastik sürecin durağanlığı tanımlanırken, istatistiksel dengenin özel bir şekli olarak zihinde canlandırılabilir. Zaman serilerinin durağanlığı ise ilgili serinin ortalama ve varyans gibi istatistiksel özelliklerinin zamana bağlı olmamasıdır (Adhikari ve Agrawal 2013). Pratikte ise bir serinin durağanlığı için serinin sabit bir ortalamasının

olması ilk koşul olabilir ancak tek başına yeterli değildir (Mills 2019). Bununla birlikte serinin diğer parametrelerinin de zamana bağlı olmama koşuluna uyması gerekir.

Literatürde güçlü durağanlık ve zayıf durağanlık olarak iki tür durağanlık türü bulunmaktadır. Güçlü durağanlık, sürecin mümkün tüm rastgele değişken setlerinin ortak olasılık dağılımının zamandan bağımsız olmasıdır (Adhikari ve Agrawal 2013). Bir başka ifade ile $\{Y_t: t \in T\}$ bir zaman serisi ve T bir indis kümesi olmak üzere $\forall n, h \in \mathbb{R}$ için $(Y_1, Y_2, \dots, Y_n)$ rastgele vektörünün dağılımı ile herhangi bir öteleme ile elde edilen $(Y_{1+h}, Y_{2+h}, \dots, Y_{n+h})$ rastgele vektörlerinin dağılımı aynı ise $\{Y_t: t \in T\}$ zaman serisine güçlü durağandır denir (Akdi 2012). Pratikte güçlü durağanlık koşullarını sağlamak kolay olmadığından zayıf durağanlık kavramı ortaya atılmıştır.

$\{Y_t: t \in T\}$ bir zaman serisi olmak üzere;

- i. $E(Y_t) = \mu$,
- ii. $Cov(Y_t, Y_s)$ Sadece $|t - s|$ 'nin bir fonksiyonu,

koşullarını sağlıyor ise $\{Y_t: t \in T\}$ zaman serisine zayıf durağandır ya da durağandır denir. Literatürde bir zaman serisinin durağanlığından bahsedildiğinde genelde zayıf durağanlık anlaşılır (Akdi 2012).

Bir zaman serisinde durağanlığın tespiti için genelde iki yöntem kullanılmaktadır. Bunlar görsel saptama (parametrik olmayan) ve birim kök testleridir. Birim kök testleri arasında en yaygın kullanılan testlerden biri ADF (Genişletilmiş Dickey-Fuller testi)'dir.

Uygulamada genellikle zaman serilerinin durağan olmayan durumu ile karşılaşılır. Söz konusu seri model kurulmadan önce fark alma gibi çeşitli yöntemlerle durağan hale getirilir.

2.2.2 Tahmin, kestirim ve öngörü

Zaman serilerinde önemli kavramlardan biri de öngörüdür. İstatistikte yaygın olarak kullanılan tahmin, kestirim ve öngörü, yakın anlamlı olmalarına karşın farklı kavramlardır (Akdi 2012). Tahmin kitle parametresi için hesaplanan değer olarak adlandırılır. Örneğin kitle ortalaması μ için bir tahmin edici örneklem ortalaması $\bar{X}$ olabilir. $\bar{X} = 10$ gibi bir değer hesaplandığı varsayılırsa buradaki nümerik değer μ 'nın tahminidir. Kestirim, bir rastgele değişken için oluşturulan bir modelin parametrelerinin tahmin değerleri yerine konulduğunda elde edilen değer ya da değerlerdir (Akdi 2012). Öngörü ise genel olarak gelecekteki olay ya da olayların önceden kestirimidir (Montgomery vd. 2015). Zaman serilerinde ise öngörü, tahmin edilen model parametreleri ile ilgilenilen rastgele değişken ya da değişkenlerin gelecekte alacağı değerlerin kestirilmesi olarak tanımlanabilir.

2.2.3 Model sadeliği

Zaman serileri analizinde model seçimi yapılırken dikkate alınması gereken bir başka kavram ise model sadeliği (parsimony) ilkesidir. Model sadeliği ilkesi kurulan uygun modeller arasında seçim yapılırken yeterli ve en sade olanını seçmek üzerine kurulu bir ilkedir. Bir başka ifade ile bir zaman serisi için birden çok yeterli ve uygun model söz konusu olduğunda en az parametrelili modelin seçimini öngörür (Montgomery vd. 2015).

2.3 Zaman Serisi Modelleri

Önceki kısımda zaman serileri analizi ile ilgili temel kavramlar tanıtılmaya çalışıldı. Daha önce bahsedildiği gibi seriye ilişkin uygun bir model belirlemek zaman serileri ile geleceğe dair öngörü yapılabilmesi için son derece önemlidir.

Doğrusal zaman serisi modelleri görece olarak uygulamadaki kolaylığı ve anlaşılır olması sebebiyle zaman serilerinde yaygın olarak kullanılmaktadır (Adhikari ve Agrawal 2013). Literatürde birçok doğrusal ve doğrusal olmayan zaman serisi modelleri

bulunmaktadır. Doğrusal zaman serisi modellerinden yaygın olarak kullanılan başlıca iki model bulunmaktadır. Bunlar hareketli ortalamalar (Moving Average-MA) ve otoregresif (Autoregressive-AR) modellerdir. Bu iki modelin doğrusal birleşiminden Otoregresif hareketli ortalamalar (Autoregressive Moving Average-ARMA) ve entegre otoregresif hareketli ortalamalar (Autoregressive Integrated Moving Average-ARIMA) modelleri türetilir. Mevsimsel zaman serileri için ise ARIMA modellerinin bir varyasyonu olan mevsimsel entegre otoregresif hareketli ortalamalar (Seasonal Autoregressive Integrated Moving Average-SARIMA) modelleri öne sürülmüştür (Adhikari ve Agrawal 2013). Literatürde ARIMA modelleri ve varyasyonları Box-Jenkins modelleri olarak da adlandırılmaktadır.

2.3.1 Hareketli ortalamalar (Moving average-MA) modelleri

Bir zaman serisinin herhangi bir gözlem değerinin hata terimi ve geçmiş dönem hata terimlerinin doğrusal birleşimi şeklinde ifade edildiği modeldir. Matematiksel gösterimi şu şekildedir:

$$y_t = \mu + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} = \mu + e_t - \sum_{j=1}^q \theta_j e_{t-j}$$

y_t : t anındaki gözlem değerini,

$\theta_0, \theta_1, \dots, \theta_q$: model parametrelerini,

q : model derecesini,

μ : serinin ortalamasını,

e_t : hata terimlerini,

göstermektedir. Burada hataların (rastgele şokların) beyaz gürültü süreci olduğu varsayılır. Ortalaması sıfır, varyansı sabit ve σ^2 olan bağımsız ve aynı dağılımlı rastgele değişkenler dizisine beyaz gürültü süreci denir ve $e_t \sim WN(0, \sigma^2)$ şeklinde gösterilir (Adhikari ve Agrawal 2013). Buradan yola çıkarak MA serilerine en basit örnek olarak beyaz gürültü serileri verilebilir (Akdi 2012).

2.3.2 Otoregresif (Autoregressive) modeller

AR modellerinde bir rastgele değişkenin gelecek değerlerinin, geçmiş dönem gözlem değerleri ve bu değerlere ait hata terimlerinin bir sabit terim ile birlikte doğrusal birleşimi şeklinde ifade edilebildiği modellerdir (Adhikari ve Agrawal 2013). Bir başka ifade ile AR serileri geçmiş dönem gözlem değerleri ve beyaz gürültü sürecinden etkilenen serilerdir (Akdi 2012). Matematiksel olarak şu şekilde gösterilir:

$$y_t = \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \dots + \varphi_p y_{t-p} + e_t = \sum_{i=1}^p \varphi_i y_{t-i} + e_t$$

Burada,

$y_t, \dots, y_{t-p}$: gözlem değerlerini,

$\varphi_1, \dots, \varphi_p$: model parametrelerini,

$e_t: e_t \sim WN(0, \sigma^2)$ beyaz gürültü sürecine sahip hata terimlerini,

p : model derecesini,

göstermektedir. Ekonometrik zaman serileri çoğunlukla AR serileri ile modellenmektedir.

2.3.3 Otoregresif hareketli ortalamalar modeli (Autoregressive moving average-ARMA)

Daha öncede belirtildiği gibi AR ve MA modellerinin doğrusal birleşimi ile ARMA modelleri elde edilir. Belirli sayıda geçmiş dönem gözlem değerleri ve hata terimlerinin doğrusal birleşimi ile seriye ait herhangi bir dönem gözlem değeri ifade edilmiş olur.

$ARMA_{(p,q)}$ modelinin matematiksel gösterimi şu şekildedir;

$$y_t = \sum_{i=1}^p \varphi_i y_{t-i} + \sum_{j=1}^q \theta_j e_{t-j} + e_t$$

Genellikle $ARMA_{(p,q)}$ modelleri $Ly_t = y_{t-1}$ gecikme operatörüyle,

$$\varphi(L)y_t = \theta(L)e_t$$

şeklinde ifade edilir.

Burada;

$$\varphi(L) = 1 - \sum_{i=1}^p \varphi_i L^i \text{ ve } \theta(L) = 1 + \sum_{j=1}^q \theta_j L^j \text{ 'dir.}$$

2.3.4 Entegre otoregresif hareketli ortalamalar modeli (Autoregressive integrated moving average-ARIMA)

ARMA modelleri sadece durağan zaman serilerini modellemek için kullanılır. Ancak uygulamalarda karşılaşılan çoğu zaman serisi durağan değildir. Durağan olmayan zaman serilerini modellemek için ARMA modelinin genelleştirilmiş hali olan ARIMA modeli geliştirilmiştir (Box vd. 1994).

ARIMA modellerinde durağan olmayan seri önce gerekli durağanlaştırma işlemleri (sonlu fark alma vb.) yapılarak durağan hale getirilir (Adhikari ve Agrawal 2013).

Genel $ARIMA_{(p,d,q)}$ ifadesi fark alma operatörü kullanılarak aşağıdaki şekilde gösterilir;

$$\varphi(L)(1 - L)^d y_t = \theta(L)e_t$$

Daha açık gösterim aşağıda verilmiştir:

$$\left(1 - \sum_{i=1}^p \varphi_i L^i\right) (1 - L)^d y_t = \left(1 + \sum_{j=1}^q \theta_j L^j\right) e_t$$

Burada;

p: modelin AR derecesini,

d: fark derecesini,

q: modelin MA derecesini,

göstermektedir.

Uygulamadaki ekonomik veri setlerinde genelde bir kez fark alma, seriyi durağan hale getirmek için yeterli olmaktadır.

2.3.5 Mevsimsel entegre otoregresif hareketli ortalamalar modeli (Seasonal autoregressive integrated moving average-SARIMA)

ARIMA modelleri durağan olmayan ve mevsimsellik içermeyen serileri modellemek için kullanılır. Mevsimsellik içeren zaman serilerini modellemek için Box-Jenkins tarafından SARIMA modelleri geliştirilmiştir. Burada seriyi durağanlaştırmak için mevsimsel fark alma işlemi uygulanırken bir gözlem değerinden, önceki dönemde karşılık gelen gözlem değeri çıkarılır (Adhikari ve Agrawal 2013). Bir yıl periyotlu bir zaman serisi için $s = 12$ ve z_t mevsimsel farkı alınmış seriyi göstermek üzere $z_t = y_t - y_{t-s}$ 'dir. Genel olarak model gösterimi ise aşağıdaki gibidir;

$$SARIMA(p, d, q) \times (P, D, Q)_s$$

Burada,

p : modelin AR derecesini,

d : fark derecesini,

q : modelin MA derecesini,

P : modelin mevsimsel AR derecesini,

D : mevsimsel fark derecesini,

Q : modelin mevsimsel MA derecesini,

s : mevsim periyodunu,

göstermektedir.

Matematiksel gösterim ise aşağıdaki gibidir;

$$\Phi_p(L^s)\phi_p(L)(1-L)^d(1-L^s)^D y_t = \Theta_Q(L^s)\theta_q(L)e_t$$

Mevsimsel farkı alınmış şekilde gösterimi ise,

$$\Phi_p(L^s)\phi_p(L)z_t = \Theta_Q(L^s)\theta_q(L)e_t$$

biçiminde verilir.

2.4 Durağanlık Analizi ve Birim Kök Testleri

MA modelleri her zaman durağan olduğundan ARIMA modellerinin durağanlığı modelin AR kısmı ile ilgilidir. Bir AR süreci $e_t = \varphi(L)y_t$ şeklinde ifade edilirse bu sürecin karakteristik denklemi $\varphi(L) = 0$ olur. Bu karakteristik denklemin bütün kökleri birim çemberin dışına düşüyorsa bu AR süreci durağandır denilir (Adhikari ve Agrawal 2013). Bir başka ifade ile denklemin bütün kökleri mutlak değerce 1'den küçük ise model durağandır denilir (Akdi 2012).

2.4.1 Dickey-Fuller testi ve genişletilmiş Dickey-Fuller testi

Zaman serilerinde durağanlığın tespiti için literatürde birden çok test bulunmaktadır. Bunlardan en yaygın olarak kullanılan testlerden biri Dickey ve Fuller tarafından ilk olarak 1979'da yayınlanmış olan 'Dickey Fuller Testi (DF)'dir. Daha sonra DF testinde otokorelasyon probleminin ortaya çıkmasıyla bu test geliştirilmiş ve 'Genişletilmiş Dickey Fuller Testi (ADF)' adını almıştır. ADF testi serinin birim kök içerdiğini ve durağan olmadığını varsayan H_0 yokluk hipotezinin, alternatif hipoteze karşı test edilmesidir.

Birim köklü seriler AR bileşeni içeren serilerdir (Akdi 2012). Dolayısıyla ADF testi serinin AR kısmıyla ilgilidir. Bir zaman serisinin birim kök içerip içermediğinin anlaşılması için Dickey-Fuller Testi özet olarak şu şekilde yapılır;

$\{Y_t: t \in T\}$ bir zaman serisi olmak üzere AR bileşeni içeren model şu şekilde verilsin;

$$(Y_t - \mu) = \theta(Y_{t-1} - \mu) + e_t, t = 1, 2, \dots, n$$

Burada;

Y_t : t anındaki gözlemi,

θ : AR bileşenin parametresini,

e_t : $WN(0, \sigma^2)$ dağılmış hata terimini,

μ : serinin beklenen değerini,

göstermektedir. Modelin karakteristik denklemlerinden biri mutlak değerce 1 ise seri birim köklüdür (Akdi 2012). $H_0: \theta = 1$ yokluk hipotezinin sınanmasında $\theta = 1$ için μ modelden düşer. Test istatistiğinin değerini hesaplamak için eşitliğin iki tarafından Y_{t-1} çıkarılır ve model;

$$Y_t - Y_{t-1} = (\theta - 1)Y_{t-1} + e_t$$

şeklinde yazılır. Daha sonra $\Delta Y_t = Y_t - Y_{t-1}$ olmak üzere ΔY_t 'lerin Y_{t-1} üzerine regresyonu yapılır. Bu regresyon modeline göre θ 'nın 1'den küçük olup olmadığını test etmek için $n(\hat{\theta}_n - 1)$, $n(\hat{\theta}_{n,\mu} - 1)$ veya $n(\hat{\theta}_{n,\tau} - 1)$ test istatistiklerinin değeri hesaplanır ve Dickey-Fuller tarafından oluşturulmuş olan tablo değerleri ile karşılaştırılır. Hesaplanan değer tablo değerinden küçük ise H_0 hipotezi reddedilir ve incelenen seri durağandır denilir.

Dickey-Fuller testinde kullanılan başlıca model tipleri şunlardır;

- i. Sabit terimsiz model ($\mu = 0$): $\Delta Y_t = \theta Y_{t-1} + e_t$
- ii. Sabit terimin olduğu model ($\mu \neq 0$): $\Delta Y_t = \alpha_0 + \theta Y_{t-1} + e_t$
- iii. Trend ve sabit terimin olduğu model: $\Delta Y_t = \alpha_0 + \alpha_1 t + \theta Y_{t-1} + e_t$

2.4.2 Phillips-Peron testi

Dickey-Fuller Testi hata terimlerinin istatistiksel olarak bağımsız olduğu ve sabit varyansa sahip oldukları varsayımına dayanır. Phillips-Peron testinde bu varsayımlar hafifletilmiş ve Dickey-Fuller Testi geliştirilmiştir.

Genişletilmiş Dickey-Fuller testi, Dickey-Fuller testinde bağımlı değişkenin gecikme farkını ekleyerek hata terimlerindeki muhtemel sıralı korelasyonları düzenlerken, Phillips-Peron testi bu düzenlemeyi parametrik olmayan istatistiksel metotlarla gerçekleştirir (Gujarati ve Porter 2009).

Literatürde durağanlığın tespiti için sıklıkla kullanılan bazı önemli yöntemler aşağıdaki gibi sıralanabilir;

- Ng-Perron Birim Kök Testi
- KPSS (Kwiatkowski, Phillips, Schmidt, Shin) Durağanlık Testi
- Dickey-Hazsa-Fuller Testi (Mevsimsel)
- Hylleberg-Engle-Granger-Yoo (HEGY) Testi (Mevsimsel)
- Beaulieu-Miron Testi (Mevsimsel)
- Enders ve Granger Testi (Doğrusal olmayan)
- Caner ve Hansen Testi (Doğrusal olmayan)

2.5 Model Seçimi

2.5.1 Otokorelasyon (ACF) ve kısmi otokorelasyon fonksiyonu (PACF)

Bir zaman serisi verisine uygun bir model belirlemenin öneminden daha önce bahsedilmişti. Uygun modelin belirlenme aşamasında otokorelasyon ve kısmi otokorelasyon fonksiyonlarının grafikleri AR ve MA süreçlerinin derecelerinin belirlenmesinde bir ölçü olarak kullanılabilir. Otokorelasyon ve kısmi otokorelasyon bir zaman serisindeki gözlemlerin birbirleriyle ilişkisini gösterir.

$\{Y_t: t \in T\}$ bir zaman serisi olmak üzere k . gecikmedeki otokovaryansı şu şekilde tanımlanır;

$$\gamma_k = Cov(y_t, y_{t+k}) = E[(y_t - \mu)(y_{t+k} - \mu)]$$

k . gecikmedeki otokorelasyon katsayısı ise;

$$\rho_k = \frac{\gamma_k}{\gamma_0} \text{dır.}$$

Burada,

μ : zaman serisinin ortalamasını ($\mu = E(Y_t)$),

ρ_k : otokorelasyon fonksiyonunu,

göstermektedir. Ayrıca otokovaryans formülünde $k = 0$ olarak alındığında sıfırıncı gecikmedeki otokovaryansın, yani γ_0 'ın, serinin varyansı olduğu görülebilir.


Herhangi bir dönemdeki gözlem ile k dönem sonraki gözlem arasındaki korelasyonu ölçmek için kullanılan diğer bir ölçü ise kısmi otokorelasyon fonksiyonudur. Yani $Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}$ modelden çıkartıldığında (değerleri önceden bilindiğinde) Y_t ile Y_{t+k} arasındaki korelasyon serinin k . kısmi otokorelasyonudur. Dolayısıyla kısmi otokorelasyon fonksiyonu;

$\phi_k = \text{Corr}(Y_t, Y_{t+k} | Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1})$ şeklinde koşullu otokorelasyondur (Akdi 2012).

Doğal olarak 1. gecikmedeki PACF(1), ACF(1) ile aynıdır.

2.5.2 Box-Jenkins metodu

İstatistikçiler George P. Box ve Gwilym M. Jenkins tarafından önerilen metotta ARIMA modellerinin kurulması için pratik bir yaklaşım öne sürülmüştür. Bu yaklaşım zaman serileri analizinde geniş kullanıma sahiptir. Box-Jenkins metodunun özelliği, öngörüsü yapılacak olan serinin geçmiş dönem gözlemlerinde özel bir düzen varsayımı yapmamasıdır. Box-Jenkins metodunda model sadeliği ilkesine de uygun olarak 3 adımda tekrarlı yaklaşım kullanılır. Bunlar modelin belirlenmesi, parametre tahmini ve tanı kontrolüdür. Bu 3 adım tatmin edici bir model bulununcaya kadar tekrar edilir. Daha sonra seçilen model serinin gelecek öngörüsü için kullanılır. Bu metot şematik olarak aşağıdaki gibi gösterilebilir.



Şekil 2.1 Box-Jenkins metodu ile model seçim aşamaları

2.5.3 Model performansı ölçüm kriterleri

Model seçimindeki en kritik adımlardan birisi en uygun modelin belirlenmesidir. Yaygın olarak kullanılan model seçim ölçütleri Akaike Bilgi Kriteri (AIC) ve Bayesian Bilgi Kriteri (BIC)'dir. Bunlar matematiksel olarak aşağıdaki formüllerle hesaplanır;

$$AIC_{(p)} = n \ln \left(\frac{\sigma_e^2}{n} \right) + 2p$$

$$BIC_{(p)} = n \ln \left(\frac{\sigma_e^2}{n} \right) + p + p \ln(n)$$

Burada,

n : gözlem sayısını,

p : modeldeki parametre sayısını,
 σ_e^2 : örneklem artıklarının kareler toplamını,
göstermektedir.

AIC veya BIC'nin en küçük olduğu model optimum model olarak alınır. Literatürde daha farklı model seçim kriterleri de bulunmaktadır (Adhikari ve Agrawal 2013).

Zaman serileri analizinde seçilen modeller ile yapılan öngörülerin performanslarını ölçmek için birçok farklı ölçüm kriteri bulunmaktadır. Bu çalışmada bunlardan RMSE (Kök Ortalama Hata Kare-Root Mean Squared Error) ve MAPE (Ortalama Mutlak Yüzde Hata-Mean Absolute Percentage Error)'den yararlanılmıştır.

RMSE, bir ölçüm kriteri olarak sıklıkla kullanılan MSE (Mean Squared Error)'nin kareköküdür. Ortalama olarak öngörülerin karesel sapmalarını gösteren bir ölçüdür. Matematiksel formülü ise şu şekildedir;

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2}$$

RMSE, öngörü yapılırken meydana gelen hata hakkında genel bilgi verir.

MAPE ise meydana gelen mutlak hatanın yüzde olarak ifade edildiği bir ölçümdür. Matematiksel formülü aşağıdaki gibidir;

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{e_t}{y_t} \right| \times 100$$

y_t : orijinal değerleri, f_t : öngörülen değerleri, $e_t = y_t - f_t$ öngörü hatası,
 n : gözlem sayısı olmak üzere diğer bazı ölçüm kriterleri şu şekildedir;

- Ortalama Öngörü Hatası (Mean Forecast Error: $MFE = \frac{1}{n} \sum_{t=1}^n e_t$)
- Ortalama Mutlak Hata (Mean Absolute Error: $MEA = \frac{1}{n} \sum_{t=1}^n |e_t|$)

- Ortalama Yüzde Hata (Mean Percentage Error: $MPE = \frac{1}{n} \sum_{t=1}^n \left(\frac{e_t}{y_t} \right) \times 100$)
- Ortalama Hata Kare (Mean Squared Error: $MSE = \frac{1}{n} \sum_{t=1}^n e_t^2$)
- Toplam Hata Kare (Sum of Squared Error: $SSE = \sum_{t=1}^n e_t^2$)
- Theil'in U-istatistiği (The Theil's U-statistics: $U = \frac{\sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2}}{\sqrt{\frac{1}{n} \sum_{t=1}^n f_t^2} \sqrt{\frac{1}{n} \sum_{t=1}^n y_t^2}}$)



3. YAPAY SİNİR AĞLARI

3.1 Yapay Sinir Ağları

Yapay sinir ağları insan beyninin öğrenme kabiliyeti ve biyolojik sinir sisteminden esinlenerek ortaya çıkmış bir analiz yöntemidir. Bu yöntemde bilgisayar sistemi, örneklerden olaylar arasındaki ilişkileri öğrenerek sonraki örnekler hakkında karar verir (Öztemel 2012).

Yapay sinir ağları ilk olarak biyoloji alanındaki çalışmalarda kullanılmak üzere ortaya çıkmasına rağmen daha sonra birçok farklı alandaki çalışmalara konu olmuş ve günümüzde de sıklıkla kullanılan bir makine öğrenmesi tekniğidir. Yapay sinir ağları tekniğinin zaman serileri öngörülerine uygulanırken öne çıkan en önemli özelliklerinden biri gözlemlerin dağılımı ile ilgili hiçbir varsayım yapmayarak doğrusal olmayan modellemeye uygun olmasıdır (Adhikari ve Agrawal 2013).

3.2 Yapay Sinir Ağları Modelleri

Literatürde yapay sinir ağları ile öngörüye yönelik birçok model öne sürülmüştür. Bu modeller zaman serileri analizinde kullanılan diğer klasik modellere yeni bir bakış açısı getirmiştir.

Yapay sinir ağları modelleri zaman serileri analizinde uygulanırken tıpkı insan beyninin öğrenme şeklini taklit ederek eldeki veriye ilişkin belirli düzen ve örüntüleri fark edip tecrübe eder ve veriye ilişkin çıkarımlarda bulunur.

Bir yapay sinir ağı genel olarak 3 katman şeklinde ifade edilir. Her bir katmanda temel işlem elemanları bulunur. Bu elemanlar literatürde daha çok düğüm ya da nöron olarak adlandırılır (Lewis 2017). Bir yapay sinir ağını oluşturan katmanlar şu şekildedir;

Girdi katmanı: Dışarıdan gelen verilerin modele girdiği ilk katmandır. Girdi katmanındaki düğümler ağı besleyen nitelik veya özelliklerin sayısına karşılık gelir.

Gizli katman: Genel olarak orijinal verinin niteliğinde doğrusal olmayan dönüşümlerin yapıldığı katmandır. Gizli katmanda bulunan düğümler, veri içindeki özellikleri girdi ve çıktı arasındaki doğrusal olmayan ilişkiyi tesis edip ortaya çıkarır (Hamzaçebi 2008).

Çıktı katmanı: Çıktı düğümlerinin sayısı kestirilmek ya da sınıflandırılmak istenen öğelerin sayısına karşılık gelmektedir (Lewis 2017).


Zaman serileri analizinde yapay sinir ağları modellerinden bazıları işleyişlerine göre devam eden alt bölümlerdeki gibi gruplandırılmıştır.

3.2.1 İleri beslemeli yapay sinir ağları (Feed forward neural networks- FFNN)


Literatürde yapay sinir ağlarının kullanım alanı oldukça geniştir. Zaman serileri analizinde de son yıllarda geniş kullanım alanına sahip bir yöntem olarak ortaya çıkan yapay sinir ağlarının analizlerde kullanımı için farklı ihtiyaçlara yönelik farklı modeller öne sürülmüştür.

Ağ mimarisi açısından düğümler arasındaki bağlantılara göre iki tür yapıdan bahsedilebilir. Bunlardan bir tanesi ‘ileri beslemeli yapay sinir ağları (FFNN)’ bir diğeri ise ‘geri beslemeli yapay sinir ağları (RNN)’ dir. Eğer ağ yapısında çıktı düğümlerinden girdilere doğru bir ‘geri bildirim’; bir başka ifade ile geri bilgi iletimi söz konusu değil ise bu tür yapılar ileri beslemeli yapay sinir ağı olarak adlandırılır. (Sazlı 2006).

İleri beslemeli yapay sinir ağları şekil 3.1’deki gibi tek katmanlı veya şekil 3.2’teki gibi çok katmanlı olarak modellenebilir.



Şekil 3.1 Tek katmanlı FFNN modeli



Şekil 3.2 Çok katmanlı FFNN modeli

3.2.2 Çok katmanlı algılayıcı modeli (Multi layer perceptron- MLP)

Yapay sinir ağlarının zaman serileri öngörü analizlerinde en çok kullanılan modellerden biri ‘çok katmanlı algılayıcı’ (Multi Layer Perceptron-MLP) modelidir. MLP modeli bir veya birden fazla gizli katmandan oluşan İleri Beslemeli Sinir Ağlarının (Feed Forward Network- FFN) karakterize edilmiş bir biçimdir (Adhikari ve Agrawal 2012). MLP modelinde her bir düğümün birbirine dönümsüz bağımlı olduğu bir girdi, bir çıktı ve bir

veya birden fazla gizli katman bulunur. MLP modeli p girdi ve h gizli düğümlerini göstermek üzere, $y_{t-i} (i = 1, 2, \dots, p)$ girdileri ile y_t çıktıları arasındaki ilişki aşağıdaki formülle gösterilebilir.

$$y_t = G \left(\alpha_0 + \sum_{j=1}^h \alpha_j F \left(\beta_{0j} + \sum_{i=1}^p \beta_{ij} y_{t-i} \right) \right)$$

Burada;

$\alpha_j; \beta_{ij} (i = 1, 2, \dots, p; j = 1, 2, \dots, h)$: bağlantı ağırlıklarını, ,

$\alpha_0; \beta_{0j}$: yanlılık terimini,

F : gizli katman aktivasyon fonksiyonunu,

G : çıktı katmanı aktivasyon fonksiyonunu,


göstermektedir (Adhikari ve Agrawal, 2012).

3.2.3 Geri beslemeli yapay sinir ağları (Recurrent neural networks- RNN)

İleri beslemeli yapay sinir ağlarında bahsedilen çıktı düğümlerinden girdi düğümlerine doğru bir ‘geri bildirim’ söz konusu ise bu tür yapılar ‘geri beslemeli yapay sinir ağları’ (recurrent neural networks- RNN) olarak adlandırılır.

Geri beslemeli yapay sinir ağları, uygulamada geçmişle ilgili oldukça fazla bilgiyi depolayarak çok karmaşık problemleri çözme konusunda ideal bir yaklaşım sunabilmektedir. Örnek olarak bilgisayarların konuşma algılama modülleri gibi karmaşık problemlerin bulunduğu alanlarda kullanılabilir.

Bir RNN modeli görsel olarak şekil 3.3’teki gibi gösterilebilir.



  kil 3.3 RNN modeli

  kil 3.3'te gecikme birimleri gizli katmandaki aktivasyon de erleri veya bir  nceki zaman birimindeki  ıktı de erlerini depolayarak, a a kısa d nemli bir hafıza  zelli i kazandırır (Lewis 2017).

4. UYGULAMA

4.1 Veri

Hava yolu taşımacılığı çağımızın en hızlı ulaşım yöntemi olması nedeniyle günümüz dünyasında zorunlu bir ihtiyaç haline gelmiştir. Özellikle acil durumlarda (doğal afet, salgın hastalık, sağlık nedenleri ile gereken hızlı nakil ihtiyacı vb.) hava yolu taşımacılığının önemi daha fazla ortaya çıkmaktadır.

Hava yolu taşımacılığının emniyetli ve etkin icra edilebilmesi için büyük bir organizasyon yönetimi gerekmektedir. Bunlardan bazıları taşınması yapılacak insan, canlı hayvan ve diğer nesnelerle doğrudan ilişkili olmasına rağmen, perde arkasında daha geniş ve detaylı çalışmalar yürütülmektedir. Bu çalışmaların en önemli kısımlarından biri de hava trafiğinin yönetimidir. Bu yönetim gerçekleştirilirken hava seyrüsefer hizmet sağlayıcılarından hava yolu şirketlerine, yer hizmetleri şirketlerinden terminal işletmecilerine kadar büyük bir organizasyonun yönetimi ve planlanması da elzemdir. Çünkü hava trafiği yönetimi anılan faaliyetleri de doğrudan etkilemektedir. Bütün bu organizasyon ve planlamanın etkin bir şekilde icra edilebilmesi için hava trafiği verileri büyük önem arz etmektedir.

Bu uygulamada amaç Türkiye hava sahasının hava trafik yoğunluğuna ilişkin ARIMA ve yapay sinir ağları yöntemleri ile zaman serileri analizi yapmak ve 2020-2022 yıllarına dair öngörülerde bulunmaktır. Bunun yanı sıra hesaplanan öngörüler, Covid 19 küresel salgınının başlangıcından itibaren gerçekleşen uçak trafiği sayıları ile karşılaştırılıp, söz konusu salgının hava trafik yoğunluğu üzerindeki etkileri ortaya konulmuştur. Böylece çalışmadan çıkarılacak sonuçların ileri dönemlerde küresel salgının etkilerinin araştırılmasında kullanılabilecek bilgiler içermesi planlanmıştır.

Bu amaçla Devlet Hava Meydanları İşletmesi'nin 2010-2019 yılları arasında Türk Hava Sahasını kullanmış aylık sivil uçak trafiği verileri çizelge 4.1'deki gibi gösterilmiştir.

Çizelge 4.1 2010-2019 yılları arasında Türkiye hava sahasını kullanan aylık sivil uçak trafiği sayıları (Anonim 2021)


	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019
O	78896	87196	87904	95922	109538	109538	125318	124678	142422	142339
Ş	72392	79986	84948	91602	103867	108024	124678	122214	130025	130894
M	88262	93331	100070	106909	118690	129606	140506	139054	152531	152144
N	89519	102203	106752	118079	132378	143080	147624	150844	164083	155351
My	109725	119779	121696	135467	150141	164359	162787	162080	173306	174443
H	113758	127506	132942	142495	156857	166806	162883	172397	187250	188273
T	126279	139851	142566	151836	168075	186745	172181	196068	205165	207678
Ağ	125726	135652	141398	156455	179080	192220	182014	200388	204912	207237
Ey	114879	131634	134193	147123	162551	175530	173864	186057	191112	194817
Ek	111414	124961	125848	139077	153224	164061	166820	172860	179438	184129
K	93058	100199	102428	112475	124793	134096	136528	143217	145118	152522
Ar	89217	92887	95741	107533	119777	130828	134705	144160	141858	144603

Çalışmada daha önce genel olarak anlatılan zaman serileri analizi ve ICAO'nun hava trafik öngörülleri için önerdiği ve yayınladığı yöntemlerden biri olan ARIMA (Box-Jenkins) modelinden ve son dönemlerde kullanımı yaygın hale gelen yapay sinir ağları modellerinden yararlanılarak söz konusu veriye ilişkin analiz yapılmış ve geleceğe dair öngörülerde bulunulmuştur.

Bu analizler yapılırken R-Studio istatistik paket programı kullanılmıştır.


4.2 ARIMA Analizi Uygulaması

Türkiye hava sahasını kullanmış sivil uçak trafiklerine ilişkin 2010-2019 yıllarına ait veriler bir zaman serisi grafiği olarak şekil 4.1'deki gibi gösterilebilir.




Şekil 4.1 2010-2019 yılları arası aylık sivil uçak verilerinin grafik gösterimi

Şekil 4.1'deki grafik incelendiğinde, serinin yıllara bağlı olarak bir artış gösterdiği (yani bir trendinin olduğu) ve özellikle belirli aylarda düzenli yükselişler gösterdiği fark edilmektedir. Bu da seride mevsimselliğin bulunduğu dair bir izlenim vermektedir. Bu durumu daha iyi görebilmek için, seriye ait her bir ayın ortalamasının gösterildiği şekil 4.2'ye bakılabilir.




Şekil 4.2 2010-2019 yıllarına ait sivil uçak verilerinin aylık ortalamaları

Ayrıca seride yıllara ait düzenli artış şekil 4.3'te görülmektedir.




Şekil 4.3 2010-2019 yıllarına ait sivil uçak verilerinin yıllara göre ayrılmış gösterimi

İlk olarak serinin durağan olup olmadığına bakılmıştır. Serideki trendin varlığı ile ilgili görsel bulgularla birlikte mevsimsellik etkisinin şekil 4.2’de ön plana çıkması, serinin durağan olmadığına yönelik sezgisel kuşkuları artırmaktadır. Ayrıca bu kuşkuyu destekleyebilecek şekil 4.4’te otokorelasyon ve şekil 4.5’te kısmi otokorelasyon grafikleri verilmiştir.



Şekil 4.4 2010-2019 yıllarına ait sivil uçak verileri serisinin otokorelasyon fonksiyonu grafiği



Şekil 4.5 2010-2019 yıllarına ait sivil uçak verileri serisinin kısmi otokorelasyon fonksiyonu grafiği

Şekil 4.4’te seriye ait otokorelasyon grafiğinde sinüs dalgalanması göze çarpmaktadır. Şekil 4.5’te kısmi otokorelasyon fonksiyonunun grafiği incelendiğinde ise seride mevsimsel etkinin bulunduğu ve durağan olmadığı söylenebilir.

Gözlemsel olarak kuşku uyandıran durağan dışılığı matematiksel olarak gösterebilmek için verilere birim kök testi uygulanmıştır. Bunun için Genişletilmiş Dickey-Fuller

(ADF) Testi seçilmiş, H_0 : *Seri birim kök içermektedir* hipotezi R-studio paket programı yardımıyla sınanmış ve sonuçları şekil 4.6'daki gibi bulunmuştur.

```
#####
# Augmented Dickey-Fuller Test Unit Root Test #
#####

Test regression drift

Call:
lm(formula = z.diff ~ z.lag.1 + 1 + z.diff.lag)

Residuals:
    Min       1Q   Median       3Q      Max
-12746.7 -2846.7  -282.5   2259.3  12230.0

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  5301.57631  2999.11431   1.768  0.080389 .
z.lag.1       -0.02528    0.02020  -1.252  0.213776
z.diff.lag1   -0.20164    0.08208  -2.457  0.015878 *
z.diff.lag2   -0.23358    0.08420  -2.774  0.006689 **
z.diff.lag3   -0.13067    0.08617  -1.516  0.132825
z.diff.lag4   -0.27483    0.08533  -3.221  0.001761 **
z.diff.lag5   -0.18512    0.08474  -2.185  0.031424 *
z.diff.lag6   -0.28327    0.08547  -3.314  0.001311 **
z.diff.lag7   -0.19156    0.08390  -2.283  0.024703 *
z.diff.lag8   -0.33515    0.08426  -3.977  0.000138 ***
z.diff.lag9   -0.18805    0.08775  -2.143  0.034722 *
z.diff.lag10  -0.22338    0.08866  -2.520  0.013456 *
z.diff.lag11  -0.12636    0.08859  -1.426  0.157097
z.diff.lag12   0.60994    0.08659   7.044  3.19e-10 ***

Value of test-statistic is: -1.2518 3.9661


Critical values for test statistics:
      1pct  5pct 10pct
tau2 -3.46 -2.88 -2.57
phi1  6.52  4.63  3.81
```

Şekil 4.6 Genişletilmiş Dickey-Fuller (ADF) testi sonuçları

Hesaplanan test istatistiği = $-1.2518 > \text{kritik değer} = -2.88$ olduğundan H_0 hipotezi reddedilemez ve ‘seri durağan değildir’ denir.


İlgili veriler üzerinde geçerli analiz yapılabilmesi için serinin durağanlaştırılmasının şart olduğundan bahsedilmişti. Durağanlaştırma işlemi için kullanılan teknik, fark alma işlemi olarak tercih edilmiştir. Ancak öncesinde seri mevsimsel etkilerden

arındırılmalıdır. Bunun için R-studio programında TRAMO/SEATS yaklaşımı kullanılmıştır. Serinin bileşenlerine ayrışık grafiği şekil 4.7’de verilmiştir.




Şekil 4.7 2010-2019 yıllarına ait sivil uçak verileri serisinin bileşenlerine ayrıştırılmış hali

Şekil 4.7’de y_cmp serinin orijinal halini, sa_cmp serinin mevsimsel düzeltmesinin yapılmış halini, t_cmp serideki trend bileşenini, s_cmp konjonktürel bileşeni ve son olarak i_cmp düzensiz bileşeni göstermektedir. Bileşenlerin ayrı ayrı gösterildiği grafiklerden mevsimsel düzeltmesi yapılmış seri çekilip şekil 4.8’de gösterilmiştir.




Şekil 4.8 Mevsimsellikten arındırılmış 2010-2019 yıllarına ait sivil uçak verileri serisi

Aşağıda verilen şekil 4.9 incelendiğinde ise, aylık ortalamaların hemen hemen düz bir çizgi haline gelmesi, mevsimsel etkiden arındırma işleminin seri üzerindeki etkisini aylık ortalamalar bazında göstermektedir.



Şekil 4.9 Mevsimsellikten arındırılmış 2010-2019 yıllarına ait sivil uçak verileri serisinin aylık bazda ortalamaları

Mevsimsellikten arındırılmış serinin otokorelasyon ve kısmi otokorelasyon fonksiyonlarının grafikleri şekil 4.10'daki gibi gösterilmiştir. Şekil 4.10 incelendiğinde, kısmi otokorelasyon değerleri birinci gecikmeden sonra hızla düşerek güven sınırları içinde kalmıştır. Ancak otokorelasyon fonksiyonu grafiğine bakıldığında durağanlığın halen sağlanmadığına dair bir ön kanaat oluşmaktadır.



Şekil 4.10 Mevsimsellikten arındırılmış 2010-2019 yıllarına ait sivil uçak verileri serisinin ACF ve PACF grafikleri

Gözlemsel olarak anlaşılan durağan dışılığın matematiksel kontrolünün sağlanması için genişletilmiş Dickey-Fuller (ADF) testi, R-studio paket programı yardımıyla uygulanmıştır. Sonuçlar şekil 4.11'deki gibidir;

```
#####
# Augmented Dickey-Fuller Test Unit Root Test #
#####

Test regression trend

Call:
lm(formula = z.diff ~ z.lag.1 + 1 + tt + z.diff.lag)

Residuals:
    Min       1Q   Median       3Q      Max
-6239  -1610    188   1339   5388

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  8378.90671  4565.73955   1.835   0.0694 .
z.lag.1       -0.07378    0.04585  -1.609   0.1107
tt           44.07420   31.59830    1.395   0.1661
z.diff.lag    -0.18844    0.09869  -1.909   0.0590 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 2311 on 103 degrees of freedom
Multiple R-squared:  0.07754, Adjusted R-squared:  0.05067
F-statistic: 2.886 on 3 and 103 DF, p-value: 0.03926
```


```
Value of test-statistic is: -1.609 4.3153 1.5743

Critical values for test statistics:
      1pct  5pct 10pct
tau3 -3.99 -3.43 -3.13
phi2  6.22  4.75  4.07
phi3  8.43  6.49  5.47
```

Şekil 4.11 İkinci kez gerçekleştirilen Genişletilmiş Dickey-Fuller Testi sonuçları


Görüldüğü üzere $test\ istatistiği = -1.609 > kritik\ değer = -3.43$ olduğundan mevsimsel düzeltmesi yapılmış olan seri de durağan değildir.

Seriye durağan hale getirmek için mevsimsellikten arındırılmış seriye fark alma işlemi uygulanmış ve seri görsel olarak şekil 4.12'deki gibi gösterilmiştir.



Şekil 4.12 Fark alma işlemi uygulandıktan sonra 2010-2019 yıllarına ait sivil uçak verileri serisinin grafik gösterimi

Şekil 4.13’de farkı alınmış serinin otokorelasyon ve kısmi otokorelasyon fonksiyonlarının grafikleri incelendiğinde otokorelasyonların ve kısmi otokorelasyonların gecikmeye bağlı olarak azaldığı ve sıfıra yaklaştığı görülmektedir.



Şekil 4.13 Farkı alınmış 2010-2019 yıllarına ait sivil uçak verileri serisinin ACF ve PACF grafikleri

Ancak görsel gözlem ile net bir karar verilemeyeceğinden dolayı 1. dereceden farkı alınmış serinin durağan olup olmadığına karar verebilmek için genişletilmiş Dickey-Fuller (ADF) testi seriyeye uygulanmış ve sonuçlar şekil 4.14'deki gibi bulunmuştur.

```
# Augmented Dickey-Fuller Test Unit Root Test #
#####

Test regression drift

Call:
lm(formula = z.diff ~ z.lag.1 + 1 + z.diff.lag)

Residuals:
    Min       1Q   Median       3Q      Max
-6458.5 -1483.1   284.8  1403.1  5205.7

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  823.33797   244.76132    3.364  0.00108 **
z.lag.1      -1.36134    0.15390   -8.846  2.7e-14 ***
z.diff.lag    0.11344    0.09867    1.150  0.25290
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 2325 on 103 degrees of freedom
Multiple R-squared:  0.6128,    Adjusted R-squared:  0.6053
F-statistic: 81.5 on 2 and 103 DF,  p-value: < 2.2e-16

Value of test-statistic is: -8.8459 39.1264

Critical values for test statistics:
      1pct  5pct 10pct
tau2  -3.46 -2.88 -2.57
phi1   6.52  4.63  3.81
```

Şekil 4.14 Üçüncü kez gerçekleştirilen genişletilmiş Dickey-Fuller Testi sonuçları

Şekil 4.14'te görüldüğü üzere $test\ istatistiği = -8.8459 < kritik\ değer = -2.88$ olduğundan bu seri durağandır diyebiliriz.

Şekil 4.13 incelendiğinde ilk gecikmeden sonraki hızlı azalmalar MA(1) veya AR(1) modellerini anımsatmaktadır. Aynı zamanda bu grafiklerden serilerin otokorelasyon ve kısmiotokorelasyon değerlerinin azalmakta olduğu; ancak sıfır olmadığı görünmektedir. Bu grafiklerden yola çıkarak bu seriler için seçilmesi gereken modelin bir otoregresif hareketli ortalama zaman serisi modeli olacağı söylenebilir. Aynı zamanda durağan olmayan ancak fark alma işlemiyle durağan hale dönüştürülmüş serilere uygulanan modeller ise otoregresif entegre hareketli ortalama (ARIMA) modelleridir. Bu nedenle burada 7 adet farklı ARIMA modeli incelenmiş, bu modeller arasından AIC değeri en küçük olan model, uygun model olarak seçilmiştir.

İlgili modellerin AIC, RMSE ve MAPE değerlerinin karşılaştırıldığı çizelge 4.2 aşağıdaki gibidir.

Çizelge 4.2 Farklı model denemelerinden elde edilen AIC, RMSE ve MAPE değerleri


Model	AIC	RMSE (Root Mean Square Error)	MAPE (Mean Absolute Percentage Error)
ARIMA(1,0,0)(1,1,1) ₁₂	-441.24	3789.088	2.113225
ARIMA(0,1,1)(0,1,1) ₁₂	-444.56	3993.933	2.106652
ARIMA(1,1,1)(1,1,1) ₁₂	-446.33	3611.427	1.869622
ARIMA(1,1,1)(0,1,1) ₁₂	-446.07	3915.209	2.041757
ARIMA(1,0,0)(0,1,1) ₁₂	-440.4	4053.558	2.244071
ARIMA(0,1,2)(0,1,1) ₁₂	-444.51	3955.186	2.079091
ARIMA(1,1,2)(1,1,1) ₁₂	-444.44	3613.576	1.872375

Çizelge 4.2’de görüldüğü üzere seriye en uygun model olarak ARIMA(1,1,1)(1,1,1)₁₂ görünmektedir. Model parametrelerinin tahmini çizelge 4.3’de gösterilmiştir.

Çizelge 4.3 ARIMA(1,1,1)(1,1,1)₁₂ model parametre tahminleri

AR 1	MA 1	SAR 1	SMA 1
0.5737	-0.832	0.4021	-0.9950

Modelden test amaçlı olarak 2018-2019 yılları öngörülleri ile orijinal veriler karşılaştırılmış ve şekil 4.15’deki gibi gösterilmiştir. Şekil 4.15 incelendiğinde modelden elde edilen öngörülerin, gerçekleşen verilere görsel olarak yakın olduğu söylenebilir.




Şekil 4.15 ARIMA(1,1,1)(1,1,1)₁₂ modeli yardımıyla elde edilen öngörüler ile gerçekleşen durumun karşılaştırması

ARIMA(1,1,1)(1,1,1)₁₂ modeli yardımıyla elde edilen 2020-2022 yıllarına ait öngörüler çizelge 4.4'te gösterilmiştir.

Çizelge 4.4 ARIMA(1,1,1)(1,1,1)₁₂ modeli yardımı ile elde edilen 2020-2022 yıllarına ait öngörüler

	2020	2021	2022
Ocak	142708.6	148327.7	155956.7
Şubat	133628.4	139727.3	147269.2
Mart	156042.0	163349.3	172244.7
Nisan	163560.4	172961.2	183123.5
Mayıs	185020.6	196189.1	207943.9
Haziran	196814.9	207454.0	219356.9
Temmuz	216080.4	227312.4	240164.3
Ağustos	217603.3	229747.8	243092.2
Eylül	203762.8	214791.0	227120.5
Ekim	192756.3	203258.8	214956.1
Kasım	158599.5	166788.6	176195.1
Aralık	151633.9	160002.2	169255.4

Model yardımıyla elde edilen 2020-2022 öngörülleri şekil 4.16'daki gibi gösterilmiştir.



Şekil 4.16 ARIMA(1,1,1)(1,1,1)₁₂ modeli yardımı ile 2022 yılına kadar elde edilen öngörüler

Şekil 4.16'da görüldüğü gibi 2020 yılından itibaren hava sahasını kullanan uçak sayısının artma eğiliminin devam ettiği, mevsimsel dalgalanmaların da aynı oranda korunduğu söylenebilir.

4.3 Yapay Sinir Ağları Analiz Uygulaması

Zaman serileri analizinde literatürde birçok farklı yöntem bulunmaktadır. Bununla birlikte yapay sinir ağlarının zaman serileri analizlerinde kullanımı da son yıllarda yaygınlaşmıştır. Yapay sinir ağlarının en önemli gücü esnek doğrusal olmayan modelleme kabiliyetidir (Zhang 2003).

Bu çalışmada, daha önce doğrusal bir zaman serileri analizi yöntemi olan Box-Jenkins metoduyla 2010-2019 yıllarına ait sivil uçak verileri kullanılarak zaman serileri analizi

yapılmıştı. Bu kısımda ise aynı verilerden yararlanılarak yapay sinir ağı yöntemi ile analiz yapılmış ve 2020-2022 yıllarına ait öngörüler yeniden hesaplanmıştır.

Yapay sinir ağı yöntemlerinin zaman serilerine uygulanması sırasında model seçimi ile ilgili genel bir yöntem bulunmamaktadır. Bu sebeple ileri beslemeli yapay sinir ağı modeli (FFNN) için birçok farklı parametre R-studio paket programı yardımı ile denenmiş ve en uygun modele $NNAR(p,P,k)_m = NNAR(1,1,2)_{12}$ olarak karar verilmiştir. Burada;

p: girdi katmanındaki düğümleri (mevsimsel olmayan serilerde AR_p modelinin derecesine karşılık gelir),

P: girdi olarak kullanılan mevsimsel gecikmeleri,

k: gizli katmandaki düğüm sayısını


göstermektedir.

Yapay sinir ağı FFNN modeli ile söz konusu veriye ilişkin 2020-2022 yıllarına dair yapılan öngörüler çizelge 4.5'teki gibi bulunmuştur.

Çizelge 4.5 FFNN modeli yardımıyla hesaplanan 2020-2022 yıllarına ait öngörüler

	2020	2021	2022
Ocak	149458	156704	164492
Şubat	140603	149810	158730
Mart	156097	160839	166315
Nisan	161584	167353	172986
Mayıs	176877	180158	183980
Haziran	190470	192764	195205
Temmuz	204972	204208	204391
Ağustos	207925	208107	208229
Eylül	201701	205680	207758
Ekim	193500	200494	204962
Kasım	165865	178877	190225
Aralık	154544	165244	176482


Söz konusu öngörülerin grafik halinde gösterimi şekil 4.17’de gösterilmiştir.



Şekil 4.17 FFNN NNAR(1,1,2)₁₂ modeli yardımıyla hesaplanan 2020-2022 yıllarına ait öngörülerin grafik gösterimi

Çizelge 4.5 ve şekil 4.17 incelendiğinde FFNN NNAR(1,1,2)₁₂ modeli yardımıyla elde edilen öngörülerin geçmişteki trend ve mevsimsel dalgalanmaları koruduğu ancak özellikle yaz aylarındaki verileri öngörürken son yıllardaki düşük artıştan etkilendiği söylenebilir. Öte yandan kış aylarındaki artış trendini yansıttığı da görülmektedir.

FFNN NNAR(1,1,2)₁₂ modeli ile ARIMA(1,1,1)(1,1,1)₁₂ modelinden elde edilen öngörülerin karşılaştırıldığı grafik şekil 4.18’deki gibi gösterilmiştir.



Şekil 4.18 FFNN NNAR(1,1,2)₁₂ modeli ile ARIMA(1,1,1)(1,1,1)₁₂ modelinden elde edilen öngörülerin karşılaştırması

Şekil 4.18 incelendiğinde, FFNN modeli ile elde edilen öngörüler ile ARIMA modeli ile elde edilen öngörülerin arasında özellikle yaz aylarındaki öngörülerde belirgin bir fark bulunduğu görülmektedir. Şekil 4.16’da ARIMA modeli ile elde edilen öngörülerin geçmiş dönem verilerinin salınımlarına daha uygun olduğu ilk bakışta göze çarpmaktadır.


Çizelge 4.6’da bu çıkarımı destekleyen karşılaştırmalı RMSE ve MAPE değerlerinin yer aldığı performans değerlendirme çizelgesi gösterilmiştir.

Çizelge 4.6 FFNN NNAR(1,1,2)₁₂ modeli ile ARIMA(1,1,1)(1,1,1)₁₂ modelinin performanslarının karşılaştırılması

Model	RMSE (Root Mean Square Error)	MAPE (Mean Absolute Percentage Error)
FFNN NNAR(1, 1, 2)₁₂	5770.995	3.316016
ARIMA(1, 1, 1)(1, 1, 1)₁₂	3611.427	1.869622


Çizelge 4.6'dan anlaşılaçağı üzere, FFNN modeline göre ARIMA modelinin RMSE ve MAPE değeri daha küçük olduğundan ARIMA modelinin daha iyi öngörü sağladığı söylenebilir.

MLP modelinin, tek gizli katmanlı FFNN modelinin özel bir hali olduğundan daha önce bahsedilmişti. Daha önce üzerinde çeşitli analizler yapılan söz konusu veriye uygun bir MLP modeli belirlenip analiz yapılarak gelecek öngörüsü tekrar yapılmıştır. Buradan yola çıkarak ilgili MLP modelinin görselleştirilmiş hali şekil 4.19'daki gibidir;



Şekil 4.19 MLP modeli

Şekil 4.19’da görüldüğü gibi model, 1 gizli katman ve gizli katmandaki 5 düğümden oluşmaktadır. Girdi katmanında ise 16 düğüm bulunmaktadır. Gecikme dereceleri sırasıyla 1,2,3,5 ve 12 olarak belirlenip her bir öngörü sonucu medyan operatörüyle bir araya getirilerek şekil 4.20’deki öngörüler elde edilmiştir.



Şekil 4.20 MLP modeli yardımıyla elde edilen öngörüler

Öngörülerin nümerik gösterimi çizelge 4.7’deki gibidir.

Çizelge 4.7 MLP modeli yardımı ile elde edilen öngörüler

	2020	2021	2022
Ocak	143808	151766	159367
Şubat	135291	145170	151453
Mart	156153	163111	170172
Nisan	162373	170687	176064
Mayıs	182873	188370	194889
Haziran	192729	197062	206599
Temmuz	207467	214472	224052
Ağustos	207735	214081	224063
Eylül	198034	203981	212732
Ekim	188742	192887	202005
Kasım	158136	164185	171805
Aralık	152121	159152	168142


Çizelge 4.7 ve şekil 4.20 birlikte incelendiğinde MLP modeli yardımıyla elde edilen öngörülerin geçmiş dönem mevsimsel dalgalanmaları ve trendi koruduğu göze çarpmaktadır.

MLP model performansının daha önce yapılan iki analiz yöntemi ile karşılaştırılmış ve çizelge 4.8’de gösterilmiştir.

Çizelge 4.8 FFNN NNAR(1,1,2)₁₂, ARIMA(1,1,1)(1,1,1)₁₂ ve MLP modelleri ile yapılan analizlerin performanslarının karşılaştırılması

Model	RMSE (Root Mean Square Error)	MAPE (Mean Absolute Percentage Error)
FFNN NNAR(1, 1, 2)₁₂	5770.995	3.316016
ARIMA(1, 1, 1)(1, 1, 1)₁₂	3611.427	1.869622
MLP(1, 2, 3, 5, 12) Median	1898.783	1.0238

Çizelge 4.8’den anlaşılabacağı üzere MLP modeli, FFNN NNAR ve ARIMA modellerine göre RMSE ve MAPE değerleri göz önüne alındığında daha iyi sonuçlar verdiği görülmüştür. MLP ve ARIMA(1,1,1)(1,1,1)₁₂ modellerinden elde edilen öngörülerin görsel olarak karşılaştırıldığı grafik şekil 4.21’de sunulmuştur.




Şekil 4.21 MLP ve ARIMA(1,1,1)(1,1,1)₁₂ modelleri yardımıyla elde edilen öngörülerin karşılaştırılması

4.4 Küresel Salgının Hava Trafik Yoğunluğuna Etkisi

2020 yılı başlarında tüm dünyada etkisini gösteren Covid 19 salgınının en fazla etkilediği sektörlerden biri de havacılık sektörüdür. Devletler söz konusu salgını kontrol altına almak ve bulaş riskini azaltabilmek adına birçok önlem almış, bu önlemlerin büyük bir kısmı ise seyahat kısıtlamaları şeklinde gerçekleşmiştir. Alınan seyahat kısıtlamaları hava yolu taşımacılığını doğrudan etkilemiştir. Daha önce de değinildiği gibi teknolojik gelişmelerle paralel olarak büyüyen havacılık sektörünün tüm paydaşları gelecek planlarını revize etmek zorunda kalmışlardır.


Hava trafiğinin yönetiminden sorumlu olan kuruluşlar için küresel salgının etkilerini daha iyi analiz etmek, bu etkilerin getirdiği olumsuzlukları kavramak ve gelecek için iyileştirme faaliyetlerini daha sağlıklı yapmak adına bu çalışmada elde edilen gelecek öngörülleri ile salgın sebebiyle gerçekleşen hava trafiği yoğunluğunun karşılaştırılmasında yarar görülmüştür. Aşağıda, şekil 4.22’de 2010-2019 yılları arasında hava trafik yoğunluğunun nasıl bir seyir izlediği ve bu verilerin

ARIMA(1,1,1)(1,1,1)₁₂ modeli yardımı ile analizi sonucunda salgın hastalık etkisi olmasaydı 2020-2022 yılları arasında nasıl bir yol izleyeceği grafik gösterimi ile sunulmuştur. Ayrıca bu gösterimde Ocak 2020 tarihinden Eylül 2021 tarihine kadar gerçekleşen hava trafik yoğunluğu da bulunmaktadır.



Şekil 4.22 ARIMA(1,1,1)(1,1,1)₁₂ modeli yardımıyla elde edilen öngörüler ile gerçekleşen hava trafik yoğunluğunun görsel karşılaştırılması

MLP modeli yardımı ile elde edilen öngörüler ile gerçekleşen hava trafik yoğunluğunun görsel olarak karşılaştırıldığı grafik ise şekil 4.23'te sunulmuştur.



Şekil 4.23 MLP modeli yardımı ile elde edilen öngörüler ile gerçekleşen hava trafik yoğunluğunun görsel karşılaştırılması

Şekil 4.22 ve şekil 4.23 incelendiğinde Türkiye’de teknolojik gelişmelerle paralel olarak artmakta olan hava trafik yoğunluğu açıkça görülmektedir. Ancak 2020 yılının başlarından itibaren küresel salgın sebebiyle alınan seyahat kısıtlamalarının hava trafik yoğunluğunu son derece olumsuz etkilediği göze çarpmaktadır. Bunun yanı sıra hava yolu ulaşımına olan ihtiyacın devam ettiği ve kısıtlamaların hafifletildiği zaman dilimlerinde hava trafik yoğunluğunun tekrar artış gösterdiği söylenebilir. Buradan küresel salgının etkilerinin tamamen geçmesi halinde hava trafik yoğunluğunun tekrar eski düzeye dönme eğiliminin olduğu sonucu çıkarılabilir.

5. SONUÇ

Hava yolu ulaşımı en hızlı ulaşım çeşidi olması sebebiyle günümüz dünyasında vazgeçilmesi ciddi sorunlar doğuracak bir ulaşım çeşididir. Bununla birlikte hava yolu ulaşımının güvenli ve düzenli bir şekilde yürütülebilmesi için büyük bir organizasyon gerekmektedir. Bu organizasyonun neredeyse tüm kademelerini etkileyen hava trafik yoğunluğu verilerinin analiz edilmesi önem arz etmektedir.

Bu amaçla çalışmanın ilk bölümünde ulaşım çeşitleri ve hava trafiği ile ilgili tanım ve açıklamalar yapılmıştır. Sonrasında çalışma esnasında kullanılan zaman serileri analizi ile ilgili tanım, yöntem ve modellerden bahsedilmiştir. Daha sonra son yıllarda kullanımı yaygınlaşan bir yöntem olan yapay sinir ağları metotları üzerinde durulmuştur.

Çalışmanın uygulama bölümünde ise Türk hava sahasını kullanan sivil uçak trafiği verilerine ilişkin zaman serisi analizi yapılarak uygun bir ARIMA modeli ve yapay sinir ağları modelleri oluşturulmuş ve geleceğe dönük öngörülerde bulunulup model performansları RMSE ve MAPE kriterleri göz önüne alınarak karşılaştırılmıştır. Çalışmada yapılan uygulamanın sonuçları şu şekilde özetlenmiştir:

- Serinin otokorelasyon ve kısmi otokorelasyon grafikleri incelenerek durağan dışılık ve mevsimsellik saptanmış, bu mevsimsellik giderilip durağanlığa ilişkin ADF (Genişletilmiş Dickey-Fuller) birim kök testi uygulanmıştır.
- Durağan dışılığı gidermek için fark alma işlemi gerçekleştirilmiş ve birinci dereceden fark alma işleminden sonra serinin durağan hale geldiği tespit edilmiştir.
- Model tahmini yapılırken ise ACF ve PACF grafikleri yardımıyla ipuçları elde edilmiş, bu bilgiler ışığında R-studio paket programı yardımıyla birçok model denemesi yapılmıştır. Yapılan bu denemelerin analizleri sırasında AIC, RMSE ve MAPE kriterleri dikkate alınmış ve en uygun modele bu şekilde karar verilmiştir.

- Zaman serileri analizi ile oluşturulan uygun ARIMA modeli ile ülkemizde 2010-2019 yılları arasında gerçekleşen sivil uçak trafiğine ilişkin veriler ilk olarak ARIMA(1,1,1)(1,1,1)₁₂ şeklinde modellenmiştir.
- Oluşturulan ARIMA(1,1,1)(1,1,1)₁₂ modeli yardımıyla öncelikle elde edilen öngörülerin 2018-2019 arasında gerçekleşen verilere uyup uymadığı görsel olarak değerlendirilmiştir.
- Yapılan analizlerin sonucunda 2020-2022 yıllarına ait öngörüler oluşturulmuştur. Hesaplanan öngörüler neticesinde 2020 yılı başlarında dünyada etkili olan Covid 19 salgınının hava trafik yoğunluğuna olan olumsuz etkisi daha açık bir şekilde ortaya konmuştur. Bununla birlikte öngörüler ile gerçekleşen hava trafik yoğunluğu karşılaştırılmıştır.
- İlgili veriler ayrıca bir yapay sinir ağları yöntemi olan FFNN metodundan yararlanılarak R-studio paket programında bir çok farklı model parametreleri denenerek FFNN NNAR(1,1,2)₁₂ şeklinde modellenmiştir.
- FFNN NNAR(1,1,2)₁₂ modeli yardımıyla 2020-2022 yıllarına ait öngörüler hesaplanmıştır. Hesaplanan öngörülerin daha önce ARIMA modeli yardımıyla hesaplanan öngörülerle karşılaştırması yapılmış ve ARIMA modelinden elde edilen öngörülerin RMSE ve MAPE değerleri göz önüne alındığında daha etkin ve doğru sonuçlar verdiği görülmüştür.
- Daha sonra FFNN metodunun özel bir hali olan MLP modeli, 16 düğümden oluşan bir girdi, 5 düğümden oluşan bir gizli katman şeklinde kurulmuştur.
- Oluşturulan MLP modeli 1,2,3,5 ve 12 gecikme dereceleri kullanılarak 2020-2022 yıllarına dair öngörüler elde edilmiştir.
- MLP modeli ile daha önce analizi yapılan FFNN NNAR ve ARIMA modellerinin performans değerlendirmesi RMSE ve MAPE değerleri karşılaştırılarak yapılmıştır.
- MLP modeli yardımı ile elde edilen öngörüler ile ARIMA(1,1,1)(1,1,1)₁₂ modeli ile elde edilen öngörülerin görsel karşılaştırması yapılmış ve MLP modelinden

elde edilen öngörülerin RMSE ve MAPE değerleri göz önüne alındığında daha iyi sonuçlar verdiği görülmüştür.

► Oluşturulan modeller yardımıyla elde edilen 2020-2022 yıllarına ait öngörüler ile küresel Covid 19 salgınının etkilerinin daha iyi görülebilmesi için Eylül 2021 tarihine kadar gerçekleşen sivil hava trafiği karşılaştırılmıştır. Görsel olarak da sunulan bu karşılaştırmaların sonucunda küresel pandeminin Türkiye hava sahasını kullanan sivil hava trafiğine olumsuz etkisi açıkça görülmüştür.



KAYNAKLAR

- Adhikari, R ve Agrawal, R.K. 2013. An Introductory Study on Time Series Modeling and Forecasting. LAP Lambert Academic Publishing, Bengaluru, India.
- Adhikari, R ve Agrawal, R. K. 2012. Forecasting Strong Seasonal Time Series with Artificial Neural Networks. Journal of Scientific&Industrial Research, 71, 657-666.
- Akdi, Y. 2012. Zaman Serileri Analizi (Birim Kökler ve Kointegrasyon). Gazi Kitabevi Tic. Ltd. Şti, Ankara.
- Anonim. 2011. DHMİ Terimler Sözlüğü, Ankara.
- Anonim. 2021. Web Sitesi: <https://www.mfa.gov.tr>, Erişim Tarihi: 20.05.2021.
- Anonim. 2011. DHMİ Terimler Sözlüğü, Ankara.
- Anonim. 2021. Web Sitesi: <https://www.dhmi.gov.tr>, Erişim Tarihi: 20.06.2021.
- Anonim. 2021. Web Sitesi: <https://www.dhmi.gov.tr/Sayfalar/Istatistikler.aspx>, Erişim Tarihi: 25.10.2021.
- Anonymous. 2020. Web Sitesi: <https://en.wikipedia.org/wiki/Transport>, Erişim Tarihi: 15.06.2021.
- Anonymous. 2013. Web Sitesi: <https://www.wdl.org/en/item/11372/>, Erişim Tarihi: 16.06.2021.
- Anonymous. 2010. Journal: Airways, St Petersburg-Tampa Airboat Line: World's First Scheduled Airline, 75(6); 49-52.
- Anonymous. 2017. Web site: <https://www.statistics.su.se/english/research/time-series-analysis/a-brief-history-of-time-series-analysis-1.259451>, Erişim Tarihi: 21.05.2021
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C. 1994. Time Series Analysis Forecasting and Control. Prentice-Hall International, Inc, 12-23, New Jersey, USA.
- Duru, Ö. 2007. Zaman Serileri Analizinde ARIMA Modelleri ve Bir Uygulama. Yüksek Lisans Tezi. İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı, 5, İstanbul.
- Gujarati, D.N., Porter, D. C. 2009. Basic Econometrics. The McGraw-Hill Companies, Inc, New York, USA.
- Hamzaçebi, A. 2008. Improving Artificial Neural Networks' Performance in Seasonal Time Series Forecasting. Information Sciences, 178, 4550-4559.
- Kerkkanen, A., Korpela, J., Huiskonen, J. 2009. Demand Forecasting Errors in Industrial Context: Measurement and Impacts. International Journal Production Economics, 118, 43-48.

- Lawler, G. 2006. Introduction to Stochastic Processes. Chapman&Hall/CRC, 1, Boca Raton, USA.
- Lewis, N. D. 2017. Neural Networks for Time Series Forecasting with R. Copyright N.D. Lewis, 20-21. UK.
- Lütkepohl, H. ve Kratzig, M. 2004. Applied Time Series Econometrics. Cambridge University Press, 1-5, New York.
- Mills, T. C. 2019. Applied Time Series Analysis a Practical Guide to Modeling and Forecasting. Elsevier Academic Press, 1-4, Loughborough, United Kingdom.
- Montgomery, D. C., Jennings, L. C., Külahçı, M. 2015. Introduction to Time Series Analysis and Forecasting. Wiley, 1-77, New Jersey, USA.
- Öztemel, E. 2012. Yapay Sinir Ağları. Papatya Yayıncılık, 29, İstanbul.
- Sampson, M. 2001. Time Series Analysis. Loglinear Publishing, 6, Quebec, Canada.
- Sazlı, M. H. 2006. A Brief Review of Feed-Forward Neural Networks. Communications Faculty of Sciences University of Ankara Series, 50, 11-17.
- Şen, H. ve Polat, H. 2015. Havayolu Taşımacılığı Kanunlarındaki Değişikliğin Türkiye’deki Havayolu Yolcu Taşımacılığı Üzerine Etkilerinin Araştırılması. Alphanumeric Journal, 3(1),089-098.
- Zhang, P., G. 2003. Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. Neurocomputing 50, 159-175.