



BİNGÖL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI

ARIMA MODELİYLE HASTA TALEP TAHMİNİ:
BİNGÖL AĞIZ VE DİŞ SAĞLIĞI MERKEZİ ÖRNEĞİ

MÜCAHİDE GÜNGÖR OFLAZ

YÜKSEK LİSANS TEZİ

Danışman
Doç. Dr. ERDİNÇ KOÇ

Bingöl – 2023

BİNGÖL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI

**ARIMA MODELİYLE HASTA TALEP TAHMİNİ:
BİNGÖL AĞIZ VE DİŞ SAĞLIĞI MERKEZİ ÖRNEĞİ**

MÜCAHİDE GÜNGÖR OFLAZ

YÜKSEK LİSANS TEZİ

Danışman
Doç. Dr. ERDİNÇ KOÇ

Bingöl - 2023

İÇİNDEKİLER

İÇİNDEKİLER	iv
BİLİMSEL ETİK BİLDİRİMİ.....	v
ÖNSÖZ	vii
ÖZET.....	viii
ABSTRACT.....	ix
SİMGELER VE KISALTMALAR.....	x
TABLolar LİSTESİ.....	xiii
ŞEKİLLER LİSTESİ	xiv
GİRİŞ	1
1. SAĞLIK VE SAĞLIK HİZMETLERİ	3
1.1. Sağlık.....	3
1.2. Sağlık Hizmetleri.....	4
1.3. Hastane	6
1.3.1. Hastane Hizmetleri ve Özellikleri.....	7
1.3.2. Mülkiyetlerine Göre Hastaneler	11
1.3.3. İşlevlerine Göre Hastaneler.....	12
2. TALEP TAHMİNİ VE TAHMİN YÖNTEMLERİ.....	14
2.1. Talep Tahmini Amacı ve Önemi.....	15
2.2. Talep Tahmin Yöntemleri	15
2.2.1. Kalitatif Yöntemler	15
2.2.1.1. Odak Grup Toplantısı:.....	16
2.2.1.2. Derinlemesine Görüşme:.....	17
2.2.1.3. Etnografik Gözlem	18
2.2.1.4. Çalıştay.....	19
2.2.1.5. İkincil Veri Kaynağı.....	19
2.2.1.6. Delphi Tekniği	19
2.2.2. Kantitatif Yöntemler	20
2.2.2.1. Zaman Serisi Analizleri	21
2.2.2.1.1. Zaman.....	21
2.2.2.1.2. Zaman Serileri.....	21
2.2.2.1.3. Zaman Serilerinin Amacı	22
2.2.2.1.4. Zaman Serilerinin Türleri.....	23
2.2.2.1.4.1. Genel Eğilim(Trend) Bileşeni;	23
2.2.2.1.4.2. Mevsimsellik;	24
2.2.2.1.4.3. Çevrimsel (Döngüsel) Bileşen;	25

2.2.2.1.4.4. Düzensiz (Rastgele) Bileşen;	26
2.2.2.1.5. Zaman Serisi Analizinin Kullanım Amaçları.....	27
2.2.2.1.5.1. Aykırı Verilerin Tespiti.....	27
2.2.2.1.5.2. Tahmin	27
2.2.2.1.5.3. Eksik Verileri Tamamlama	28
2.2.2.1.5.4. Hata Düzeltme.....	28
2.2.2.1.6. Zaman Serilerinin Sınıflandırılması.....	29
2.2.2.1.6.1. Sürekli ve Kesikli Zaman Serileri	29
2.2.2.1.6.2. Durağan ve Durağan Olmayan Zaman Serileri.....	30
2.2.2.1.7. Mevsimsel ve Mevsimsel Olmayan Zaman Serileri	33
2.2.2.1.7.1. Hareketli Ortalama	33
2.2.2.1.7.2. Üstel Düzleştirme Teknikleri	34
2.2.2.1.7.2.1. Ayrıştırma (Decomposition) Yöntemi	34
2.2.2.1.7.2.2. Tramo/Seats Yöntemi	35
2.2.2.2.1. Regresyon Analizi.....	36
2.2.2.2.2. Korelasyon Analizi.....	38
2.2.2.2.3. Box Jenkins Yöntemleri (Arıma).....	39
2.2.2.2.3.1. Otoregresiv Modeller AR(p) Süreci.....	42
2.2.2.2.3.2. AR(1) Süreci	42
2.2.2.2.3.3. AR(2) Süreci	44
2.2.2.2.3.4. Hareketli Ortalama Ma(q) Süreci.....	46
2.2.2.2.3.5. MA(1) Süreci	47
2.2.2.2.3.6. MA(2) Süreci	49
2.2.2.2.3.7. Durağan Olmayan Modeller (ARIMA).....	50
2.2.2.2.3.8. Mevsimsel Modeller	52
2.2.2.2.3.9. Model Belirleme Aşamaları	53
2.2.2.2.3.9.1. Box –Pierce istatistiği;	54
2.2.2.2.3.10. Modelin Uygunluğunun Testi	54
2.2.2.3. Yapay Sinir Ağları Yöntemi	56
2.3. Talep Tahmini Aşamaları.....	56
2.3.1. Talebi Etkileyen Faktörleri Belirleyin	57
2.3.2. Veri Düzenleme Ve Birleştirme.....	57
2.3.3. Tahmin Döneminin Belirlenmesi.....	57
2.3.4. Talep Tahmin Yönteminin Seçimi.....	58
2.3.5. Talep Tahmin Hatasının Belirlenmesi	59
2.3.6. Tahmin Yoluyla Elde Edilen Sonuçların İncelenmesi:	62

3. LİTERATÜR TARAMASI.....	63
4. MATERYAL VE YÖNTEM.....	69
4.1. Materyal	69
4.2. Yöntem.....	69
4. 3. Talep Tahmini Uygulaması.....	71
4.3.1. Problemin Tanımı	71
4.3.2. Çalışmanın Amacı.....	72
4.3.3. Çalışmanın Önemi.....	72
5. BULGULAR.....	75
6. SONUÇ	89
KAYNAKÇA.....	91
EKLER.....	98
ÖZ GEÇMİŞ	Hata! Yer işareti tanımlanmamış.

BİLİMSEL ETİK BİLDİRİMİ

Yüksek Lisans tezi olarak hazırladığım *Arıma Modeliyle Hasta Talep Tahmini: Bingöl Ağız Ve Diş Sağlığı Merkezi Örneği* adlı çalışmanın öneri aşamasından sonuçlanmasına kadar geçen süreçte bilimsel etiğe ve akademik kurallara özenle uyduğumu, tez içindeki tüm bilgileri bilimsel ahlak ve gelenek çerçevesinde elde ettiğimi, tez yazım kurallarına uygun olarak hazırladığım bu çalışmamda doğrudan veya dolaylı olarak yaptığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu beyan ederim.



03/ 08/ 2023

İmza

Mücahide GÜNGÖR OFLAZ

BİNGÖL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ MÜDÜRLÜĞÜNE

Mücahide GÜNGÖR OFLAZ tarafından hazırlanan *Arıma Modeliyle Hasta Talep Tahmini: Bingöl Ağız Ve Diş Sağlığı Merkezi Örneği* başlıklı bu çalışma, 03.08.2023 tarihinde yapılan tez savunma sınavı sonucunda *[oybirliği]* başarılı bulunarak jürimiz tarafından *İşletme* Anabilim Dalı'nda Yüksek Lisans tezi olarak kabul edilmiştir.

TEZ JÜRİSİ ÜYELERİ (Unvanı, Adı ve Soyadı)

Başkan	: Prof. Dr. Sait PATIR	İmza:
Danışman	: Doç. Dr. Erdi KOÇ	İmza:
Üye	: Yrd. Doç. Dr. Seda İŞGÜZAR	İmza:

ONAY

Bu Tez, Bingöl Üniversitesi Sosyal Bilimler Enstitüsü Yönetim Kurulunun/.../ 2023 tarih ve sayılı oturumunda belirlenen jüri tarafından kabul edilmiştir.

Doç. Dr. MEHMET ZAFER ERTEKİN
Enstitü Müdürü

ÖNSÖZ

Arıma Modeliyle Hasta Talep Tahmini: Bingöl Ağız Ve Diş Sağlığı Merkezi Örneği konusu, günümüzde tüm sektörlerde gelecekte neler olabileceğine dair tahmin yapılması ve bu tahminlere göre işletmelerin yol haritalarını belirlemeleri çok büyük önem kazanmıştır. Bu çalışmamızda talep tahmininde kullanılan modellerden biri olana ARIMA modelini Minitab programı kullanarak açıklamaya çalışacağım.

Bu çalışmanın hazırlanmasında yardımlarını esirgemeyen danışman hocam *Doç. Dr. Erdinç KOÇ*'a; tezin yazım aşamasında ve tashihinde katkılarını esirgemeyen *Eşim Ali OFLAZ*'a ve eğitim hayatım boyunca yetişmemde katkısı olan tüm hocalarıma teşekkürlerimi sunmayı bir borç bilirim.

Çalışmamı tamamlamam konusunda moral ve motivasyonumu üst düzeyde tutmama yardımcı olan annem Emine GÜNGÖR, babam Mehmet GÜNGÖR ve kayın validem Saniye OFLAZ'a şükranlarımı sunarım.

03/08/2023

Mücahide GÜNGÖR OFLAZ

ÖZET

Sağlık, insan yaşamının en temel gereksinimlerinden biri olarak hayati bir rol oynar. İyi sağlık, bireylerin yaşamlarını sürdürmelerini sağlar, verimli çalışmalarına ve ekonomiye katkıda bulunmalarına olanak tanır. Aynı zamanda eğitim, yaşam kalitesi, sosyal ilişkiler ve toplumsal istikrar gibi bir dizi alanı olumlu etkiler. Sağlık, bireylerin potansiyellerini gerçekleştirmelerini desteklerken toplumların gelişimini ve sürdürülebilirliğini sağlar. İnsanların sağlık ihtiyaçlarının zamanında karşılanabilmesi; gerekli malzemelerin zamanında temin edilmesi ve sağlık personelinin yeterli sayıda bulunmasını planlanması sağlık ihtiyaçlarının karşılanabilmesi için önemlidir. Bu nedenle, doğru analizler yapılarak ileriye dönük tahminlerin yapılması, sağlık ihtiyaçlarının geliştirilmesi, iyileştirilmesi ve taleplere cevap verebilmek için atılabilecek adımlardan bir tanesidir.

Özellikle zaman serileri ile yapılan araştırmalar sayesinde, farklı yöntemler kullanılarak ileriye dönük tahminler yapılabilmektedir. Bu çalışma Box-Jenkins yöntemi yani ARIMA modeli kullanılarak, Bingöl Ağız ve Diş Sağlığı Merkezi'ne gelen 6 yıllık hasta sayılarının verilerine uygulanarak gerçekleştirilmiştir. Analizler için Minitab 21 adlı Paket programı kullanılarak sonuçlar elde edilmiştir.

Minitab 20 programı kullanılarak yapılan korelogram ve Q istatistik testi sonuçları, hasta verilerine uygulanan, birinci fark alma işleminden sonra serinin durağanlığı sağlandığı gözlemlenmiştir. Bu sayede, ARIMA(1,1,1) modeli en uygun model olarak belirlenmiştir. Yapılan zaman serisi analizi, malzeme tedariki, doktorların izinlerinin planlanması ve ihtiyaç duyulan personelin temini gibi işletme faaliyetleri için önemli bir kaynak olmuştur.

Bu çalışmada elde edilen sonuçlar doğrultusunda hastanenin ihtiyaç duyduğu malzeme tedarikinin, doktorların izinlerinin planlanmasının ve personel temininde daha doğru ve verimli kararlar alınabilmesi mümkün olabilecektir. Bu da işletmenin daha etkili bir şekilde yönetilmesine yardımcı olacaktır. Sonuç olarak, yapılan zaman serisi analizinin hastanenin faaliyetlerini destekleyen önemli bir araç olduğu ifade edilebilir.

Anahtar Kelimeler: Talep tahmini, zaman serileri.

ABSTRACT

Health plays a vital role as one of the most basic necessities of human life. Good health enables individuals to live their lives, to work productively and to contribute to the economy. It also positively affects a number of areas such as education, quality of life, social relations and social stability. Health ensures the development and sustainability of societies while supporting individuals to realize their potential. The ability to meet people's health needs in a timely manner; It is important to provide the necessary materials on time and to plan the availability of sufficient number of health personnel in order to meet the health needs. For this reason, making forward-looking forecasts by making accurate analyzes is one of the steps that can be taken to develop and improve health needs and to respond to demands.

Especially thanks to the researches made with time series, forward-looking estimations can be made by using different methods. This study was carried out using the Box-Jenkins method, that is, the ARIMA model, by applying it to the data of the 6-year patient numbers coming to Bingöl Oral and Dental Health Center. The results were obtained by using the Minitab 21 Package program for the analysis.

It was observed that the results of the correlogram and Q statistics test performed using the Minitab 21 program, provided the stationarity of the series after the first difference applied to the patient data. Thus, the ARIMA(1,1,1) model was determined as the most suitable model. The time series analysis has been an important resource for business activities such as supplying materials, planning doctors' leave, and recruiting needed personnel.

In line with the results obtained in this study, it will be possible to make more accurate and efficient decisions in the supply of materials needed by the hospital, the planning of doctors' leave and the recruitment of personnel. This will help the business to be managed more effectively. As a result, it can be stated that the time series analysis is an important tool that supports the activities of the hospital.

Keywords: Demand forecasting, time series.

SİMGELER VE KISALTMALAR

ACF	: Otokorelasyon Fonksiyonu
AR	: Auto Regressive (Otoregresif Süreç)
ARIMA	: Durağan Olmayan Doğrusal Stokastik Modeller
ARMA	: Otoregresif Hareketli Ortalama Süreci
C	: Konjonktür Dalgalanmalar
COV	: Kovaryans
E	: Ortalama
GYODER	: Gayrimenkul ve Gayrimenkul Yatırım Ortaklığı Derneği
I	: Düzensiz Bileşeler
KOSGEB	: Küçük ve Orta Ölçekli Sanayi Geliştirme ve Destekleme İdaresi Başkanlığı
MA	: Moving Average (Hareketli Otoregresif Süreç)
MSE	: Ortalama Kare Hata
PACF	: Kısmi Otokorelasyon Fonksiyonu
R ²	: Determinasyon Katsayısı
S	: Mevsimsel Bileşenler
T	: Trend
TÜİK	: Türkiye İstatistik Kurumu
YSA	: Yapay Sinir Ağları
VAR	: Varyans
ARIMAX	: Otoregresif Bütünleşik Hareketli Ortalama
t	: Belli bir zaman
Ø	: Çap
μ	: Sabit ortalama
σ ²	: Sabit Varyans
γ	: Kovaryans

Θ	: Faz açısı
α	: Ortalama Standart Sapma
α_t	: Hata Değişkeni
Θ_p	: Model Parametresi
Θ_q	: Fark Alma Operatörü
χ^2	: X-Kare
d	: Fark Alma
D	: Mevsimsel Fark Alma
p	: Model Derecesi
q	: Model Derecesi
w_t	: Farkı Alınmış seri
x_t	: Gözlem Değeri
z	: Gemiş Veriler
z_t	: t zamanındaki geçmiş veriler
y_t	: Serinin Geçikme Değeri
e_t	: Sıfır Ortalamaya Sahip Bağımsız Olarak Dağılmış Tesadüfi Değişkenleri
MAPE	: Ortalama Mutlak Yüzde Hata
MAD	: Tahmin hatası ortalama mutlak sapması
B	: Geçikme Operatörü
Q	: Ljung –Box istatistiği
n	: Gözlem sayısı
m	: Test edilecek otokorelasyon katsayısı
θ_i	: Bilinmeyen parametre
∇S^D	: Mevsimsel fark alma operatörü
∇^d	: d ‘ inci dereceden fark alma operatörü
δ	: Sabit terim olup stokastik süreç olan Y_t ’nin ortalamasıdır.
ϕ	: Bilinmeyen otoregressif parametreler
σ_e^2	: Otokorelasyonsuz rassal değişkendir.
X	: Dönem numaraları
y	: Geçmiş talep değerleri

- n : Geçmiş talep dönemi sayısı
LBQ : Ljung-Box Q
 n : veri noktaları sayısı
 Y_i : gerçek değeri
 $\hat{Y}_i$: tahmini değeri



TABLolar LİSTESİ

	Sayfa No
Tablo 1.1. 2002-2021 Tarihleri Arasındaki Sağlık Personeli Sayıları	8
Tablo 1.2. 2002-2021 Tarihleri Arasındaki Hastane Talep Sayıları	8
Tablo 1.3. 2002-2021 Tarihleri Arasındaki Hastane Sayıları	9
Tablo 1.4. 2002-2021 Tarihleri Arasındaki Hastane, Hekim ve Hasta Sayılarının Bir Önceki Yıla Göre Artış Oranları	9
Tablo 4.1. LBQ (Ljung-Box Q) Değerleri	78
Tablo 4.2. 1. Fark Alma İşleminde Sonra LBQ (Ljung-Box Q) Değerleri	80
Tablo 4.3. ARIMA(1,1,1) modelinin geçerlilik değerleri	81
Tablo 4.4 ARIMA(1,1,0) modelinin geçerlilik değerleri	82
Tablo 4.5 ARIMA(0,1,1) modelinin geçerlilik değerleri	83
Tablo 4.6 ARIMA(1,1,1) modelinin istatistik test sonucu	84
Tablo 4.7. ARIMA(1,1,1) Modeline Göre Gelecek Dönemlerin Tahmin Tablosu	87
Tablo 4.8. ARIMA(1,1,1) Modeline Göre Eldeki Verileri Kullanarak 6. Yıl Tahmin Tablosu	87

ŞEKİLLER LİSTESİ

	Sayfa No
Şekil 2.1 Doğrusal Trend	24
Şekil 2.2 Doğrusal olmayan Trend	24
Şekil 2. 3 Dondurma Satışlarına Dair Mevsimsellik Grafiği	25
Şekil 2.4 Çevrimsel Bileşen	26
Şekil 2.5 Düzensiz Bileşen	26
Şekil 2.6 White Noise (Beyaz Gürültü) Serinin Grafiği	30
Şekil.2.7. Random Walk (Rastgele Yürüyüş) Grafiği	32
Şekil 2.8. AR(1) modeli için ACF ve PACF Grafiği	44
Şekil 2.9. AR(2) modeli için ACF ve PACF Grafiği	45
Şekil 2.10. MA(1) modeli için ACF ve PACF Grafiği	48
Şekil 2.11. MA(2) modeli için ACF ve PACF Grafiği	50
Şekil 2.12. Box- Jenkins yönteminde model belirleme	53
Şekil 4.1. Grafik Çizdirme Ekranı	75
Şekil 4.2. Hasta Sayılarının Aylara Göre Dağılımı	76
Şekil 4.3. ACF Grafiği Ekran Ayarı	77
Şekil 4.4. Hasta Sayısı İçin ACF Grafiği	77
Şekil 4.5. Hasta Sayısı İçin Fark aldırma	79
Şekil 4.6. 1.Fark alma işleminden sonra ACF Grafiği	79
Şekil 4.7. 1.Fark alma işleminden sonra PACF grafiği ve ekrana yazdırılması	81
Şekil 4.8 ARIMA(1,1,1) Modelinin Çizdirilmesi	81
Şekil 4.9. ARIMA(0,1,0) Modelinin Çizdirilmesi	83
Şekil 4.10. ARIMA(1,1,1) Modeli için Gelecek Tahmin grafiği	85
Şekil 4.11. ARIMA(1,1,1) Modeli için ACF ve PACF kalıntı grafiği	86
Şekil 4.12. ARIMA(1,1,1) Modeli için kalıntı grafiği	86

GİRİŞ

Geleceğin tahmin edilmesi, insanlar, şirketler ve kurumlar için stratejik planlama, risk yönetimi, inovasyon, kaynak yönetimi, piyasa reaksiyonu, yatırım kararları, stratejik ortaklıklar ve uzun vadeli vizyon oluşturma gibi alanlarda önemlidir. Bu tahminler, belirsizliği azaltarak daha bilinçli kararlar almayı, rekabet avantajını sürdürmeyi ve sürdürülebilir büyümeyi desteklemeyi sağlar. Gelecek Sözlükteki anlamıyla, henüz gelmemiş olan, yaşanacak zaman dilimi, ileride olması beklenen olayların ve koşulların bütünüdür (TDK, 2009). Eski çağlarda insanlar, doğru tahminlerde bulunabilmek için medyum ve falcılardan, daha sonra da yıldızlardan yardım almışlardır.

Kurumların çoğu için tahminde bulunmak iş stratejisini belirlemekte, maliyeti azaltmakta, kârı maksimize etmekte, iş gücünü belirlemekte kilit unsur olmuştur. Kurumların geliştirilmesi ve rekabetçi bir duruma gelebilmesi için de satış ve stok tahminlerinde bulunmak, karar verme sürecinde kullanılacak bir etken olmuştur (Stadler vd., 2000). Geleceği tahmin etmek, bir işletmenin çevresel uyum yeteneğini artırmak, içsel değerlendirmeler yapmak aynı zamanda işletmenin tüm seviyelerinde ortak bir vizyon oluşturarak koordinasyonu geliştirir ve hedef birliğini destekleyerek stratejik yönetimin hazırlanmasında etkili olmaktadır (Çıkmak, 2012).

Hastaneler ve sağlık kuruluşları, insan hayatı için büyük öneme sahiptir; çünkü sağlık hizmetleri, hastalıkların önlenmesi, teşhis edilmesi ve tedavi edilmesi gibi kritik alanlarda faaliyet göstererek yaşamları korur ve iyileştirir. Bu kuruluşlar, acil durum müdahalelerinden rutin sağlık kontrollerine kadar geniş bir yelpazede hizmet sunarak toplumun genel sağlığını destekler, hastaların yaşam kalitesini artırır ve sağlıklı bir toplumun oluşturulmasına katkıda bulunur. Hastaneler ve sağlık kuruluşları hizmet sektörlerinin içinde sahip oldukları pay bakımından da çok büyük öneme sahiptirler. Hem sağlık hem de maddi açıdan bu kadar öneme sahip hastanelerin verimli ve etkin bir şekilde varlıklarını sürdürebilmeleri ve teknolojiyi takip ederek taleplere hızlı bir şekilde cevap verebilmeleri için ihtiyaçların doğru tahmin edilmesi ve zamanında temin edilmesi gerekmektedir (Taşlıyan ve Gök, 2012).

Sağlık hizmetlerinin etkinliği içinde, insanları tatmin edecek bir yaşam sürmeleri, gelişen teknolojilere ve bilime uyum sağlayarak, yapılacak yenilikler için ayrılan bütçeler, ülkenin sağlığa verdiği önemin bir göstergesidir. Bu yenilikler hastanelerinin etkin ve verimli şekilde çalışmasını sağlamak ve kaliteli sağlık hizmeti sunmak için gereklidirler (Taşlıyan ve Gök, 2012). Sağlık alanında tüketicilere çeşitli hizmetlerin hızlı bir şekilde sunulması doğru malzeme alımı ve uygun ekipman temini ile yakından ilişkilidir. Bu unsurlar, hastaların hızlı bir şekilde teşhis edilmesi, tedavi edilmesi ve bakım almasını sağlamada kritik bir rol oynar. Sağlık hizmetlerinde kullanılan güvenilir ve kaliteli malzeme ve ekipmanlar, tıbbi prosedürlerin verimli bir şekilde gerçekleştirilmesini desteklerken, acil durum müdahalelerini hızlandırır ve hastaların güvenliğini artırır. Ayrıca, uygun malzeme alımı ve ekipman temini, enfeksiyon kontrolü, teknolojik ilerleme ve iş akışının optimize edilmesi gibi önemli alanlarda da sağlık hizmetlerinin kalitesini ve etkinliğini artırmada hayati bir rol oynar (Taşlıyan ve Gök, 2012).

Çalışmada, Bingöl ilinde yer alan Bingöl Ağız ve Diş Sağlığı Merkezi' nin hastalarına daha iyi hizmet sunabilmek, malzeme tedarikini zamanında sağlayabilmek ve doktorların sayısını ihtiyacı karşılayacak şekilde bulundurmak için gelecekte oluşabilecek hasta sayılarının talebini tahmin edilmeye çalışılacaktır. Doğru tahminlerde bulunabilmek içinde izlenecek yolların ve yapılacak analiz çeşidinin doğru olarak seçilmesi gerekmektedir. Çalışmada öncelikle izlenecek yolların tespiti yapılmış ve daha sonrada yapılacak analizin çeşidine karar verilerek 2022 yılında hastane talebine ilişkin tahminler ortaya konulacaktır.

1. SAĞLIK VE SAĞLIK HİZMETLERİ

Dünya Sağlık Örgütüne göre Sağlık, insanların iyi hissetmeleri, hastalıklarını tedavi etmeleri ve sağlıklarını korumaları için gereklidir. Günümüz de sağlık, bireylerin en değerli varlığı olarak önemini koruyor. İnsanların sağlıklı ve mutlu bir yaşam sürdürebilmesi için etkili sağlık hizmetleri sunulması büyük bir gerekliliktir. Bu hizmetlerin en önemli yapı taşlarından biri de hastanelerdir. Hastaneler, sağlık alanında sağlanan çeşitli hizmetlerle, hastaların ihtiyaçlarına yönelik çözümler sunarak toplumun genel sağlık düzeyini yükseltmeyi amaçlar. Bu yazıda, sağlık ve hastane kavramlarının farklı boyutlarını, sağlık hizmetlerini ve hastane çeşitlerinin neler olduğu anlatılmaya çalışılacaktır.

1.1. Sağlık

Literatürde birçok sağlık tanımına rastlanmaktadır. Bunlar; sağlık, yalnızca hastalık ve sakatlığın yokluğundan ibaret değildir. Dünya Sağlık Örgütü'ne (1948) göre, sağlık; bedensel, zihinsel ve sosyal yönden tam bir iyilik hali olarak tanımlanır ve sağlıklı olmak için gerekli olan tüm faktörlerin mükemmel olması gerekmektedir. Dünya Sağlık Örgütü'nün 1986 yılında yayınladığı bildiriye göre ise; sağlık, fiziksel, ruhsal ve sosyal bakımdan tam bir refah halidir ve yalnızca hastalığın yokluğundan daha fazlasını içermektedir.

Seçim'in (1991) vurguladığına göre, sağlık kavramı yalnızca hastalık ve sakatlığın yokluğu değil, aynı zamanda insanın fiziksel, ruhsal ve sosyal yönden tam bir iyilik halinde olmasını ifade eder. Bu görüş, bireyin yaşam kalitesini artıran faktörlerin dengeli bir şekilde bir araya gelmesinin önemini vurgular. Benzer şekilde, Fişek (1983), sağlığı sadece hastalık ve yaralanma eksikliği olarak değil, bedenin ve zihnin en üst düzeyde işlev gördüğü bir durum olarak tanımlar. Çakır (2017) ise sağlığın yalnızca tedavi değil, aynı zamanda koruyucu tedbirlerin alınmasını ve sağlıklı bir yaşam tarzının benimsenmesini içerdiğini belirtir. Bu bağlamda, sağlıklı beslenme, düzenli egzersiz, stres yönetimi ve olumsuz alışkanlıklardan kaçınma gibi önlemler sağlığın tam anlamıyla korunması için gereklidir.

1.2. Sağlık Hizmetleri

Sağlık hizmetleri, insanların fiziksel, zihinsel ve sosyal sağlıklarını korumak, geliştirmek ve tedavi etmek için sunulan çeşitli hizmetleri içerir (Önder, 2017). Bu hizmetler hastaneler, klinikler, sağlık merkezleri, aile hekimleri ve toplum sağlık merkezleri gibi farklı sağlık kurumları ve profesyoneller tarafından sunulmaktadır. Sağlık hizmetlerinin çeşitleri arasında tanı ve tedavi, acil bakım, rehabilitasyon, aşılar, taramalar, sağlık danışmanlığı ve psikolojik destek yer almaktadır. Bu hizmetler, hastalıkların teşhis edilmesi, tedavi edilmesi, sağlıklı bir yaşam tarzının teşvik edilmesi ve sağlık sorunlarının önlenmesi amacıyla sunulmaktadır. Sağlık hizmetleri kısaca aşağıda açıklanmıştır (Önder, 2017).

Hastaneler: Genellikle doktorlar, hemşireler ve diğer sağlık uzmanları tarafından yönetilen tıbbi hizmetlerin sunulduğu büyük sağlık kuruluşlarıdır. Acil servisler, ameliyathaneler, doğumhaneler ve yoğun bakım üniteleri gibi bölümleri bulunur.

Klinikler: Küçük sağlık kuruluşlarıdır ve genellikle belirli bir hastalığın tedavisi veya sağlık sorununun teşhisi için uzmanlaşmıştır. Örneğin, göz klinikleri, diş klinikleri ve fizik tedavi klinikleri gibi.

Sağlık Merkezleri: Birçok sağlık hizmetini sunan merkezlerdir. Fiziksel sağlık, psikolojik sağlık, diyet, fitness, bağımlılık tedavisi, aile planlaması ve diğer konularda hizmetler sunabilirler.

Aile Hekimleri: Sağlık sorunlarının teşhisi, tedavisi ve yönetimi için temel sağlık hizmeti sunan doktorlardır. Genellikle bir bölgedeki birçok aileyi takip ederler ve gerektiğinde diğer sağlık uzmanlarına sevk edebilirler.

Toplum Sağlık Merkezleri: Sosyal ve ekonomik zorluklar nedeniyle sağlık hizmetlerine erişimde zorluk çeken topluluklar için tasarlanmış sağlık hizmeti sunan merkezlerdir. Genellikle düşük gelirli, göçmen veya azınlık topluluklarına yöneliktirler.

Evde Sağlık Hizmetleri: Kronik hastalıkları veya yetersizlikleri olan insanlara evlerinde sağlık hizmeti sunan hizmetlerdir. Hemşireler, fizyoterapistler ve diğer sağlık uzmanları ev ziyaretleri yaparak tıbbi bakım ve rehabilitasyon hizmetleri sunarlar.

Sağlık hizmetleri çeşitleri şu şekilde sıralanmaktadır (Önder, 2017).

-Genel pratisyen hekim hizmetleri: Genel sağlık sorunları, hastalıklar ve yaralanmalar için birinci basamak sağlık hizmeti sunan hekimler tarafından verilen hizmetlerdir.

-Uzman hekim hizmetleri: Belirli bir tıbbi alan veya konuda uzmanlaşmış hekimler tarafından verilen hizmetlerdir. Örnekler arasında kardiyologlar, nörologlar, gastroenterologlar ve psikiyatristler tarafından verilen hizmetler yer alır.

-Diş hekimi hizmetleri: Diş hastalıklarının teşhisi, önlenmesi ve tedavisi için diş hekimleri tarafından sunulan hizmetlerdir.

-Rehabilitasyon hizmetleri: Fiziksel yaralanmalar, engellilikler veya nörolojik hastalıklar gibi durumlarla başa çıkmak için fizyoterapistler, konuşma terapistleri, iş terapistleri ve diğer sağlık profesyonelleri tarafından verilen hizmetlerdir.

-Acil tıp hizmetleri: Acil durumlarda sunulan sağlık hizmetleri. Bu hizmetler ambulans, acil servis ve yoğun bakım gibi hizmetleri içerir.

-Laboratuvar testleri: Kan, idrar, doku veya diğer biyolojik örneklerin analiz edilmesiyle ilgili testlerdir. Bu testler hastalıkların teşhisi, tedavisi ve takibi için önemlidir.

-Cerrahi hizmetler: Cerrahi müdahalelerin yapılması ve takibi için hastaneler ve diğer sağlık kurumları tarafından sunulan hizmetlerdir.

-Ruh sağlığı hizmetleri: Zihinsel hastalıkların teşhisi ve tedavisi için psikiyatristler, psikologlar ve diğer ruh sağlığı uzmanları tarafından sunulan hizmetlerdir.

-Halk saęlıęı hizmetleri: Toplum saęlıęı iin sunulan hizmetlerdir. Bu hizmetler arasında aşılama kampanyaları, enfeksiyon hastalıkları kontrolü, sigara ve alkol kullanımının önlenmesi ve saęlıklı yaşam tarzları teşvik edilmesi yer alır.

Saęlık hizmetleri, hastaların saęlığını korumak ve iyileştirmek iin bir araya gelen bir ekip işidir. Bahsedilen saęlık hizmetlerini doktorlar, hemşireler, teknisyenler, terapistler, diyetisyenler, temizlik görevlileri gibi saęlık alışanları sunmaktadır. Her biri, hastanın saęlığına katkıda bulunmak iin farklı bir rol üstlenir (Kavuncubaşı ve Kısa, 2002).

Başarılı bir saęlık hizmeti iin, tüm ekibin birbirleriyle uyumlu alışması ve birbirlerinin alışmalarına saygı göstermelidirler. Her biri, saęlık hizmetlerinin ayrılmaz bir parçasıdır ve birinin görevini ihmal etmesi, tüm ekibin performansını etkileyebilir. Örneęin, bir cerrah ameliyatı başarıyla gerçekleştirebilir, ancak hemşirelerin hasta bakımı ve anestezi ekibinin görevi tamamlanmadığı takdirde hastanın iyileşmesi mümkün olmayabilir. Temizlik görevlileri de, sterilizasyon ve hijyen konusunda dikkatli alışarak, hastalıkların yayılmasını önleyebilir ve saęlık hizmetlerinin kalitesini artırabilir.

1.3. Hastane

Hastane, tıbbi bakım ve tedavi hizmetleri saęlayan ve genellikle tıbbi personel, ekipman ve tıbbi malzemelerin bulunduğu bir saęlık kuruluşudur. Hastaneler genellikle yataklı tedavi (hasta yatışı) ve ayakta tedavi hizmetleri sunarlar (https://www.who.int/health-topics/hospitals#tab=tab_1). Hastaneler, tıbbi bakım, tedavi, teşhis ve rehabilitasyon hizmetleri sunan saęlık kuruluşlarıdır. Hastaneler, hem acil durumlar hem de planlı tıbbi bakım ve tedavi ihtiyaçları iin hizmet verirler (T.C.S.B., 2020)

Hastaneler, acil durumlar, ciddi yaralanmalar ve hastalıklar, cerrahi operasyonlar, doğumlar, tıbbi muayeneler ve teşhisler gibi bir dizi tıbbi hizmeti saęlarlar. Ayrıca, rehabilitasyon ve uzun süreli bakım gibi hizmetler de sunabilirler.

Hastaneler, genellikle bölümlere ayrılır ve her bölüm belirli bir tıbbi uzmanlık alanına veya hizmet türüne odaklanır. Örneęin, kardiyoloji bölümü kalp hastalıklarıyla ilgilenirken, onkoloji bölümü kanser tedavisi sunar.

Hastaneler, hastaların sađlık durumlarını deđerlendirmek, teŗhis koymak ve tedavi etmek iin tıbbi teknolojiler, ilalar ve prosedürler kullanılarak sađlık hizmetlerinin tıbbi etik ve yasal gereksinimlerine uygun olarak sunulmasını sađlayan standartlar ve yönetmelikler tarafından yönetilirler (Kavuncubaŗı ve Kısa, 2002).

1.3.1. Hastane Hizmetleri ve Özellikleri

Günümüzde sađlıklı yaŗam herkesin kabul ettiđi bir ihtiyatır. Hastaneler, tıbbi hizmetlerin çođunu topluma sunmak iin kurulmuŗtur. Bu hedeflere ulaŗmak iin hastaneler, teknik ve tıbbi aıdan son derece karmaŗık eŗitli süreçlerin birbiriyle entegre edildiđi ana kurumlardan biridir (Walshe ve Smith, 2006).

Sanayileŗme, kentleŗme ve sürekli artan nüfus yoğunluđu gibi etkenler, insanların daha sađlıklı bir yaŗam sürdürme arzusunu arttırmıŗtır. Tüm bu faktörler bir arada düşünöldüğünde ve hasta sayısındaki artışlar, doktor randevularının zor alınması, halk sađlığı kampanyalarının yoğunlaŗması gibi faktörler insanların sađlık hizmetlerine olan talebinin arttıđını göstermektedir. Ayrıca, medyada sađlık konularına daha fazla ilgi ve harcanan sađlık harcamalarındaki artış da talebin yükseldiđine iŗaret edebilmektedir. Sađlık kuruluşlarının genişlemesi ve online sađlık hizmetlerinin popölerliđi de bu durumu destekler. Tüm bu göstergeler, insanların sađlık hizmetlerine olan talebin arttıđını ve sađlık kuruluşlarının da buna yanıt vermek iin büyüdüđu söylenebilir. Tablo 1.1, Tablo 1.2 ve Tablo 1.3’de ki veriler incelendiđinde sađlık personeli ve hasta sayılarının 2002 yılından 2021 yılına kadar olan sürede 3(ü) katından daha fazla arttıđı hastane sayısının ise 1,5 kat kadar arttıđı gözlemleniyor. Bu nedenle tedavi ve düzenli tıbbi bakım ancak en son tıbbi teknolojiye ve laboratuvar olanaklarına sahip hastanelerde alınabilir. Hastanelere olan talebin sürekli artması ekonomide iŗ kayıplarına yol aacađından hastaların vakit kayıpları yaŗamamaları iin gerekli tedavilerin en kısa sürede sađlanması önem kazanmıŗtır. Hastaneye baŗvuran herkesin vaktinin bir kısmını burada geireceđi göz önünde bulundurulduğunda hasta, zaman, ekipman ve doktorların koordineli bir řekilde alıŗması gerekmektedir (Ramsom, Joshi ve Nash, 2022).

Tablo 1.1. 2002-2021 Tarihleri Arasındaki Sağlık Personeli Sayıları

Sağlık Personeli	2002	2017	2018	2019	2020	2021
Uzman Hekim	45,457	80,951	82,894	85,199	88,127	93,517
Pratisyen Hekim	30,900	44,649	44,053	46,843	49,760	53,035
Asistan Hekim	15,592	24,397	26,181	28,768	33,372	37,017
Toplam Hekim	91,949	149,997	153,128	160,810	171,259	183,569
Toplam Dış Hekimi	16,371	27,889	30,615	32,925	34,830	39,851
Hemşire	72,393	166,142	190,499	198,103	227,292	232,442
Ebe	41,479	53,741	56,351	55,972	59,040	57,908
Diğer Sağlık Çalışanları	50,106	155,417	177,409	182,456	206,103	219,630
Diğer Personel Ve Hizmet Alımı	83,964	339,241	376,367	369,660	408,581	481,311
Toplam Personel	448,211	1042,424	1137,497	1160,736	1278,364	1398,28

Kaynak: Sağlık Hizmetleri Genel Müdürlüğü

Not: 2021 yılında “Asistan Hekim” sayısına 2,520 yan dal asistan hekim, “Toplam Dış Hekimi” sayısına 2,581 asistan dış hekim sayıları dâhil edildi. Sağlık Bakanlığı personel sayılarına, Sağlık Bakanlığı merkez teşkilatında çalışan sağlık personeli dâhil değildir.

Tablo 1.1’de 2002 ile 2021 yılları arasında Türkiye’deki sağlık sektöründe ciddi bir büyüme ve gelişme yaşandığı görülmektedir. Uzman hekimlerden pratisyen hekimlere, dış hekimlerinden hemşirelere ve diğer sağlık çalışanlarına kadar birçok kategoride istihdam artışı kaydedilmiştir. Aynı zamanda, sağlık hizmetlerini destekleyen diğer personel ve hizmet alımı da önemli bir oranda artmıştır. Bu veriler, ülkedeki sağlık sisteminin genişlemesini ve çeşitlenmesini yansıtarak, toplum sağlığının daha etkin bir şekilde desteklendiğini göstermektedir.

Tablo 1.2. 2002-2021 Tarihleri Arasındaki Hastane Talep Sayıları

Hastaneler	2002	2017	2018	2019	2020	2021
Sağlık Bakanlığına Bağlı Hastanelere Gelen Hasta Sayıları	109,793,180	350,347,005	377,045,707	387,622,848	239,981,820	305,040,174
Üniversite Hastanelerine Gelen Hasta Sayıları	8,823,361	38,963,933	42,665,139	46,211,148	31,725,506	40,102,992
Özel Hastanelere Gelen Hasta Sayıları	5,697,170	72,208,615	74,675,065	72,669,168	60,906,243	69,311,238
Toplam Hasta Sayıları	124,313,711	461,519,553	494,385,911	506,503,164	332,613,569	414,454,404

Kaynak: Sağlık Hizmetleri Genel Müdürlüğü, Sağlık Hizmetleri Genel Müdürlüğü

Tablo 1.2 ‘de 2002 ile 2021 yılları arasındaki verilere göre, Türkiye’deki hastane türlerine gelen hasta sayılarında önemli bir değişim görülmektedir. Sağlık Bakanlığına bağlı hastaneler 109 milyon hasta sayısından 2021’de 305 milyon hasta sayısına yükselirken,

üniversite hastaneleri 8 milyon hasta sayısından 2021'de 40 milyon hasta sayısına, özel hastaneler ise 5 milyon hasta sayısından 2021'de 69 milyon hasta sayısına ulaşmıştır. Toplam hasta sayıları ise 124 milyondan 414 milyon hastaya yükselmiştir. Bu veriler, sağlık hizmetlerinin çeşitlenmesi ve toplumun farklı hastane seçeneklerine artan talebini yansıtarak, sağlık sektöründeki büyümeyi vurgulamaktadır.

Tablo 1.3. 2002-2021 Tarihleri Arasındaki Hastane Sayıları

Hastaneler	2002	2017	2018	2019	2020	2021
Sağlık Bakanlığına Bağlı Hastaneler	774	883	891	898	905	912
Üniversite Hastaneleri	50	70	72	73	74	76
Özel Hastaneler	271	574	595	615	636	657
Toplam Hastane Sayısı	1095	1527	1558	1586	1615	1645

Kaynak: TÜİK 2002, SHGM 2002 -2021 yılı verileri

Tablo 1.3’de 2002 ile 2021 yılları arasındaki hastane sayılarındaki değişiklikleri yansıtan bu verilere göre, Türkiye’deki hastane altyapısının sürekli bir büyüme eğilimi içinde olduğu görülmektedir. Sağlık Bakanlığına bağlı hastaneler, 2002’de 774’ten başlayarak 2021’de 912’ye yükselmiştir. Üniversite hastaneleri ise aynı dönemde 50’den başlayarak 2021’de 76’ya çıkmıştır. Özel hastaneler ise 2002’de 271 iken, 2021’de 657’ye ulaşmıştır. Toplam hastane sayısı da 2002’de 1,095’ten başlayarak 2021’de 1,645’e çıkmıştır. Bu veriler, Türkiye’nin sağlık altyapısındaki sürekli büyümeyi ve gelişmeyi yansıtarak, sağlık hizmetlerine daha geniş bir erişim sağlandığını göstermektedir.

Tablo 1.4. 2002-2021 Tarihleri Arasındaki Hastane, Hekim ve Hasta Sayılarının Bir Önceki Yıla Göre Artış Oranları

	2002	2021	Yüzdelik Oran
Toplam Personel	448,211	1,398,28	311,96914
Toplam Hastane Sayısı	1,095	1,645	150,22831
Toplam Hasta Sayıları	124,313,711	414,454,404	333,39396

Tablo 1.4’ de ki verilere göre, 2002 ile 2021 yılları arasında Türkiye’nin sağlık sektöründe büyük oransal büyüme yaşandığı görülmektedir. Toplam personel sayısında %311,97’lik artış, sağlık hizmetlerinin genişlemesine ve istihdamın büyük ölçüde artmasına işaret

etmektedir. Aynı dönemde toplam hastane sayısındaki %150,23'lük artış, hastane altyapısının güçlendiğini ve çeşitlendiğini yansıtarak sağlık hizmetlerinin daha geniş bir kesime sunulduğunu göstermektedir. Toplam hasta sayısındaki %333,39'luk artış ise sağlık hizmetlerine olan talebin büyük ölçüde arttığını ve toplumun sağlık hizmetlerine daha geniş bir şekilde erişebildiğini göstermektedir. Bu veriler, Türkiye'nin sağlık sektöründeki büyümeyi ve sağlık hizmetlerinin iyileşmesini yansıtarak, toplum sağlığının güçlendiğini göstermektedir. Hastanelerin sayısının arttığı gibi sağlık hizmetleri kapsamında sunulan ve hastaların sağlık sorunlarını çözmek için farklı alanlarda uzmanlık gerektiren hizmetleri de artmıştır. Bu hizmetlerin özellikleri şunlardır (Ransom, Joshi ve Nash, 2022).

-Çok çeşitli hizmetler sunar: Hastane hizmetleri, acil tıbbi müdahale, teşhis, tedavi, cerrahi, rehabilitasyon, psikolojik destek gibi çok çeşitli hizmetleri içerir.

-Uzmanlık gerektiren bir sektördür: Hastane hizmetleri, tıbbi bilgi ve beceri gerektirir ve uzmanlık alanlarına göre farklı bölümlerde sunulur. Örneğin, bir hastanenin kalp-damar cerrahisi, nöroloji, çocuk sağlığı ve hastalıkları, onkoloji, dâhiliye vb. bölümleri olabilir.

-Hizmetler, 7/24 kesintisiz sunulur: Hastane hizmetleri, acil durumlar da dâhil olmak üzere 7 gün 24 saat kesintisiz sunulur. Acil tıbbi durumlarda hastaneler hayat kurtarıcı bir rol oynar.

-İleri teknolojiler kullanılır: Hastane hizmetleri, tıbbi teknoloji alanındaki gelişmeleri takip eder ve en son teknolojileri kullanır. Bu, teşhis ve tedavi süreçlerinin daha hızlı ve daha doğru olmasını sağlar.

-Çok sayıda personel çalışır: Hastanelerde doktorlar, hemşireler, cerrahlar, terapistler, teknisyenler, yöneticiler vb. olmak üzere çok sayıda personel çalışır. Bu personel, hastalara kaliteli hizmet sunmak için koordineli bir şekilde çalışır.

-Hastaların ihtiyaçlarına uygun hizmetler sunulur: Hastane hizmetleri, hastaların ihtiyaçlarına uygun hizmetleri sunar. Bunlar, yatan hastaların temel ihtiyaçlarından, özel tıbbi gereksinimlere kadar her şeyi kapsar.

-Hastaların gizliliğine saygı gösterilir: Hastane hizmetleri, hastaların gizliliğine saygı gösterir. Tıbbi bilgiler, sadece hastanın rızası veya kanunen izin verilen durumlarda paylaşılır.

-Hastane hizmetleri, insanların sağlık sorunlarına çözüm bulmak için çok önemlidir ve birçok insanın hayatını kurtarır.

Hastaneler mülkiyetlerine, işlevlerine ve hizmet dalları gibi sahip oldukları özelliklere göre incelenebilmektedir (Ataman, Kurşunluoğlu Yarımoğlu, 2018).

1.3.2. Mülkiyetlerine Göre Hastaneler

Mülkiyetlerine göre hastaneler genellikle üç kategoriye ayrılır (Ataman, Kurşunluoğlu Yarımoğlu, 2018).

-Kamu Hastaneleri: Devlet tarafından finanse edilen ve yönetilen hastanelerdir. Bu hastaneler genellikle halkın sağlık hizmetlerine erişimini kolaylaştırmak için kurulmuştur. Kamu hastaneleri, ücretsiz veya düşük maliyetli sağlık hizmetleri sunar.

-Özel Hastaneler: Özel şirketler, vakıflar veya bireyler tarafından finanse edilen ve yönetilen hastanelerdir. Bu hastaneler, ücretli sağlık hizmetleri sunarlar ve genellikle daha lüks ve konforlu hizmetler sunarlar. Özel hastaneler, kamusal sağlık hizmetlerine alternatif olarak hizmet verirler.

-Üniversite Hastaneleri: Üniversiteler tarafından finanse edilen ve yönetilen hastanelerdir. Bu hastaneler, hem araştırma hem de sağlık hizmetleri sunarlar. Ayrıca, tıp öğrencilerine ve sağlık personeline uygulamalı eğitim sağlarlar. Üniversite hastaneleri genellikle kamu hastaneleri gibi ücretsiz veya düşük maliyetli sağlık hizmetleri sunarlar.

1.3.3. İşlevlerine Göre Hastaneler

Hastaneler, sağlık hizmetlerinin birçok dalına yönelik olarak faaliyet gösteren kuruluşlardır. Sağlık hizmeti verilen alana, hastalıklara ve tedavi yöntemlerine göre farklılaşabilir. Bazı hastane türleri şunlardır (Arslan, 2020; Ramsom, Joshi ve Nash, 2022).

-Genel Hastaneler: Genel hastaneler, tıbbi tanı, tedavi ve cerrahi müdahaleler gibi birçok hizmet dalında faaliyet gösteren hastanelerdir. Çoğu genel hastane, acil servis, yoğun bakım üniteleri, doğumhane ve ameliyathane gibi bölümlere sahiptir.

-Çocuk Hastaneleri: Çocuk hastaneleri, çocuk sağlığına özel ilgi gösteren ve çocuklara özel hizmetler sunan hastanelerdir. Bu hastaneler, genellikle çocuk hastalıkları, doğum ve bebek bakımı gibi konulara odaklanırlar.

-Kadın Hastaneleri: Kadın hastaneleri, kadın sağlığına özel ilgi gösteren ve kadınlara özel hizmetler sunan hastanelerdir. Bu hastaneler, genellikle kadın hastalıkları, doğum ve jinekolojik cerrahi müdahaleler gibi konulara odaklanırlar.

-Kalp ve Damar Hastaneleri: Kalp ve damar hastaneleri, kardiyoloji ve kardiyovasküler cerrahi alanlarına özel ilgi gösteren hastanelerdir. Bu hastaneler, kalp ve damar hastalıklarının teşhisi, tedavisi ve cerrahi müdahaleleri gibi konulara odaklanırlar.

-Onkoloji Hastaneleri: Onkoloji hastaneleri, kanser hastalarına özel hizmetler sunan hastanelerdir. Bu hastaneler, kanserin teşhisi, tedavisi ve takibi gibi konulara odaklanırlar.

-Rehabilitasyon Hastaneleri: Rehabilitasyon hastaneleri, sakatlanmış veya hastalanmış kişilerin tedavisine odaklanan hastanelerdir. Bu hastaneler, fizik tedavi, rehabilitasyon, nöroloji ve ortopedi gibi konulara odaklanırlar.

-Ruh Sağlığı Hastaneleri: Ruh sağlığı hastaneleri, psikolojik bozuklukları olan kişilere özel hizmetler sunan hastanelerdir. Bu hastaneler, psikiyatri, psikoloji, sosyal hizmetler ve danışmanlık gibi konulara odaklanırlar.

-Enfeksiyon Hastalıkları Hastaneleri: Özellikle bulaşıcı hastalıkların tedavisi ve kontrolü için özel olarak tasarlanmıştır.

-Üniversite Hastaneleri: Tıp fakültelerine bağlı olarak çalışan hastanelerdir ve eğitim, araştırma ve hasta bakımı sunarlar.

-Ağız ve diş sağlığı merkezleri: Diş hekimliği hizmetlerinin sunulduğu özel veya devlet kuruluşlarıdır. Bu merkezlerde, ağız ve diş sağlığı ile ilgili birçok hizmet sunulur. Bu hizmetler arasında diş temizliği, diş beyazlatma, dolgu, kanal tedavisi, diş çekimi, protezler gibi tedaviler yer alır. Ayrıca, ağız ve diş sağlığı merkezleri ağız ve diş hastalıklarının önlenmesi ve tedavisi için de eğitim ve danışmanlık hizmetleri sunarlar. Bu merkezlerde, alanında uzman diş hekimleri ve diş sağlığı uzmanları hizmet verir. Ağız ve diş sağlığı merkezleri, genellikle modern tıbbi cihazlar ve ekipmanlarla donatılmıştır ve hijyenik bir ortamda hizmet sunarlar (<https://www.ada.org/publications/new-dentist-news/2021/december/ada-data-registry-helps-dentists-answer-questions-about-treatments-outcomes>).

Bu listede sıralanan hizmet dallarına ek olarak, diğer özel hastaneler de vardır. Örneğin, göz hastaneleri, kulak burun boğaz hastaneleri, dermatoloji hastaneleri gibi daha özel konulara odaklanan hastaneler de mevcuttur. Bu liste, hastane türleri için kapsamlı bir liste değildir ve farklı ülkelerdeki sağlık sistemlerine göre değişiklik gösterebilir.

2. TALEP TAHMİNİ VE TAHMİN YÖNTEMLERİ

Tahmin, bir olaya ait geçmişteki verilerinden faydalanılarak ilgili olayın gelecekteki durumu hakkında tahminlerde bulunmaktır. Özetle tahmin, henüz meydana gelmemiş bir oluş hakkında kestirim yapmaktır (Aydın, 2017). Tahmin ne kadar somut delillerle yapılırsa o kadar doğru olacaktır.

Talep tahmini, geçmiş veriler, uzman görüşleri ve ilgili faktörlerin analizi gibi bilimsel yöntemlerden faydalanarak gelecekte oluşacak talep miktarının en az hata payıyla analiz edilmesini ifade eder (Olgun, 2009). Talep ise belirli bir zamanda satın alınması veya verilmesi muhtemel ürün veya hizmet miktarı olarak tanımlanabilir (Şahin, 2019). Bu nedenle, talebin doğru bir şekilde tahmin edilmesi, hizmet sağlayıcının kalitesi ve zamanında hazır bulunması için önemli bir faktördür. Bu tahminler, geçmiş verilere dayanarak yapılan analizler ve uzman görüşleri ile desteklenir ve talebin oluşumunu ve satın alma sürecini etkileyen çeşitli faktörler göz önünde bulundurularak gerçekleştirilir.

Zaman serilerinin analizi, geçmiş verilere dayanarak gelecekteki talepleri ve ihtiyaçları tahmin etmek için kullanılan bir yöntemdir. Sağlık sektöründe, doktor ihtiyacını belirlemek, izinlerin düzenlenmesi ve hastane işleyişinin sürdürülmesi gibi konularda zaman serilerinin analizlerinden yararlanmak mümkündür (Özkan, 2015). Ticari hayattan bağımsız olarak, sağlık sektöründe daha kaliteli hizmet sunabilmek için çeşitli önlemler alınabilir. Bunlar arasında yeterli sayıda doktorun bulundurulması, doktor izinlerinin düzenlenmesi ve hastanenin sürekliliğinin sağlanması yer alır. Bu önlemler, zaman serilerinin analiz edilmesiyle desteklenebilir (Özkan, 2015). Bu analizler, geçmiş verilerin incelenmesi ve gelecekteki talepleri etkileyen faktörlerin göz önünde bulundurulmasıyla gerçekleştirilir. Bu sayede, daha etkili ve verimli bir sağlık hizmeti sunmak için stratejik kararlar alınabilir.

Demirdöğen (1998), tarafından belirtilene göre, bir bölümün ihtiyaçlarının tedarikini sağlamak ve stokta gereken malzemeleri bulundurmak için, hangi aylarda hasta yoğunluğunun olduğunu bilmek önemlidir. Bu nedenle, hedeflenen hasta sayısının en doğru şekilde tahmin edilmesi gerekmektedir. Bu bilgi, bölümün ihtiyaçlarını karşılamak ve sağlık hizmetlerini etkin bir şekilde sunmak için kolaylık sağlayacaktır.

2.1. Talep Tahmini Amacı ve Önemi

İşletmeler, mevcut durumlarını korumak ve iyileştirmek için iyi bir planın parçası olarak gerçekleri doğru anlamalı ve uygun çözümler bulmalıdır. İşletmenin hayatta kalma olasılığı, giderek artan rekabet ortamında gelecek yıllarda ya da daha kısa bir zamanda olabilecek taleplerin tahminlerini doğru bir şekilde yapılmasıyla eş güdümlü olarak artacak ya da azalacaktır. Bu fikre göre, talep tahmini tüm işletmeler için hayati önem taşımaktadır. Tahminin amacı, şirketin gelecekte karşılaşılabileceği durumları farklı veri ve teknikler kullanarak tahmin etmek ve bunlara göre hareket etmektir. Talep tahmini, bir şirketin belirli bir ürün veya ürünlerine belirli bir zaman aralığındaki talep düzeyini tahmin etmek için kullanılan birçok yöntem arasından en doğru olanı seçme sürecidir (Ergün ve Şahin, 2017).

Talep tahmini, tüketicilerin veya talep edenlerin ne zaman, ne kadar ve neyi talep edeceklerini öngörmek amacıyla yapılan bir tahminleme sürecidir. Gelecekte neler olabileceğini tahmin etmek, özellikle rekabet ortamında olan işletmeler için stratejik bir öneme sahiptir ancak belirsiz bir süreçtir. Tüm işletme yönetimi kararları, gelecekteki tahminlere bağlı olduğundan doğru tahminler yapmak, gelecekteki belirsiz durumlar için verilen kararların güvenilirliği için hayati önem taşır (Ergün ve Şahin, 2017).

2.2. Talep Tahmin Yöntemleri

Talep tahmininde bulunulacak sektörler ve talepte bulunacak tüketicilerin farklı olmaları sebebiyle oluşacak talebi tahmin etmek için tek bir yöntemin kullanılması mümkün değildir. Günümüze kadar bir çok tahmin yöntemi geliştirilmiş ve sınıflandırılmışlardır (Nasuhoglu, 2019). Talep tahmin yöntemleri olarak sıklıkla kullanılan kalitatif ve kantitatif yöntemler aşağıda daha detaylı bir şekilde açıklanmaktadır.

2.2.1. Kalitatif Yöntemler

Sosyal bilimler alanında kullanılan araştırma yöntemlerinden biri kalitatif araştırma yöntemidir. Kalitatif araştırma yöntemi, nitel veri toplama ve analizine odaklanan bir araştırma yaklaşımını ifade eder. Bu yöntemde, araştırmacılar bireylerin deneyimlerini, inançlarını, tutumlarını ve davranışlarını anlamak için derinlemesine ve ayrıntılı bir şekilde veri toplarlar. Bu veriler daha sonra analiz edilerek anlamlar ve desenler ortaya çıkarılır.

Kalitatif araştırma yöntemi, sosyal bilimlerde anlayışı derinleştirmek, yeni teorik çerçeveler geliştirmek ve araştırma konularını daha kapsamlı bir şekilde ele almak için yaygın olarak kullanılan bir yaklaşımdır. Kalitatif araştırma yöntemi, olayların gerçekleştiği doğal ortamlarda gerçekçi bir algı oluşturmayı amaçlayan bir yaklaşımdır. Bu durum nitel süreç olarak da bilinir. Kalitatif yöntemlerde amaç, konu veya durumlar hakkında detaylı bilgi elde etmek ve ileride yapılacak çalışmalara katkı sağlamaktır. Nitel yöntemler insanların düşüncelerini içerir (Karaatlı vd., 2012). Kalitatif yöntem hakkında aşağıda daha detaylı bilgi sunulmaktadır.

2.2.1.1. Odak Grup Toplantısı:

Odak grupları, belirli bir konu hakkında müdahale edilmeyen bir ortamda, hedeflenen kitle içinden 6 ila 8 katılımcının bir araya getirilerek gerçekleştirilen bir yöntemdir (Karaatlı vd., 2012). Bu yöntemde, katılımcılar serbest bir şekilde konuşarak deneyimlerini ve düşüncelerini paylaşırlar. Odak grupları, farklı perspektiflerden zengin veriler elde etmeyi ve katılımcıların görüşlerini derinlemesine anlamayı sağlar. Katılımcılar arasındaki etkileşim ve tartışmalar, daha kapsamlı bir anlayış sağlamaya yardımcı olur. Odak grupları, pazar araştırmaları, sosyal bilimlerdeki araştırmalar ve sağlık hizmetlerinin planlanması gibi çeşitli alanlarda kullanılmaktadır. Odak grup toplantısı hakkında farklı kaynaklardan elde edilen tanımlar aşağıda yer almaktadır.

Sarah (2019), odak gruplarını, küçük bir katılımcı grubunun belirli bir konu hakkında yapıcı ve derinlemesine bir tartışma yapmak için bir araya geldiği bir yöntem olarak tanımlanmıştır.

Sharan ve Elizabeth (2015), odak gruplarını, benzer deneyimlere sahip bir grup bireyin bir araya gelerek paylaşımlarda bulunması ve ortak temaları keşfetmesi için kullanılan bir yöntem olarak açıklamıştır.

American Psychological Association (APA) (2020), tarafından yayınlanan "Publication Manual of the American Psychological Association"da, odak grup toplantılarının, araştırmacıların katılımcıların düşüncelerini, deneyimlerini ve tutumlarını anlamak için kullanabilecekleri bir yöntem olduğu belirtilir. Bu toplantıların, yaratıcı bir tartışma ortamı sağlaması ve derinlemesine bilgi elde etmeyi amaçlaması vurgulanmıştır.

Berg (2007), odak gruplarını, bir araştırmacının katılımcılarla etkileşime geçerek derinlemesine bilgi ve anlayış elde ettiği bir yöntem olarak tanımlar. Bu yöntemin, farklı bakış açılarını ve ortak temaları keşfetmek için kullanıldığına dikkat çekilmiştir.

Bu kaynaklar, odak grup toplantılarının bir araştırma yöntemi olarak nasıl kullanıldığı, amaçlarını ve faydalarını açıklamaktadır. Bu toplantılar, katılımcıların deneyimlerini ve görüşlerini paylaşmaları ve araştırmacıların derinlemesine anlayış elde etmeleri için önemli bir araç olarak kabul edilmektedir.

2.2.1.2. Derinlemesine Görüşme:

Araştırma yapılan konu hakkında bilgi sahibi olan teknik uzmanlarla planlanmamış bir şekilde görüşme yapılarak verileri ve bilgilerin toplandığı tekniktir. Özellikle kişisel ve hassas konularda tercih edilen bu yöntem, derinlerde saklı duygu, düşünce ve tutumları görmenizi sağlar. Ayrıca detaylı görüşmeler, odak gruplara katılmak için zamanı olmayan uzmanların görüşlerini ve puanlarını toplamanın nitel bir yoludur (Karaatlı vd., 2012).

Derinlemesine görüşme, genellikle yarı yapılandırılmış veya açık uçlu sorulara dayanır. Araştırmacı, katılımcılara belirli bir konu veya deneyim hakkında derinlemesine düşüncelerini sağlayacak sorular yönelterek onları teşvik eder. Bu sorular, katılımcıların duygusal tepkilerini, motivasyonlarını, değerlerini, inançlarını ve yaşadıkları deneyimleri anlamak için kullanılır (Seidman, 2013)

Görüşme süreci, genellikle bir araştırmacı tarafından kaydedilir ve daha sonra analiz için kullanılmak üzere transkript haline getirilir. Verilerin analizi, katılımcıların ifadelerinin içerik analizi, tema analizi veya diğer nitel veri analizi yöntemleriyle yapılır. Bu analiz süreci, katılımcıların paylaştığı bilgilerin anlamlarını, ortak temaları ve ilişkileri belirlemeyi amaçlar (Kvale,1996).

Derinlemesine görüşme yöntemi, araştırmacılara katılımcıların deneyimlerini daha derinlemesine anlama fırsatı sunar. Katılımcıların iç dünyalarına, motivasyonlarına ve yaşadıkları deneyimlerin anlamına odaklanarak zengin ve ayrıntılı bir perspektif elde edilir. Bu yöntem, sosyal bilimler, psikoloji, sosyoloji, eğitim ve sağlık gibi birçok disiplinde kullanılan etkili bir araştırma yöntemidir (Rubin ve Rubin, 2011).

2.2.1.3. Etnografik Gözlem

Etnografik gözlem, sosyal ve kültürel fenomenleri anlamak ve analiz etmek için antropoloji ve sosyoloji gibi disiplinlerde kullanılan bir araştırma yöntemidir. Bu yöntem, bir araştırmacının doğrudan saha çalışması yaparak belirli bir topluluğun veya kültürün içine girmesini ve olayları, davranışları ve etkileşimleri gözlemlemesini içerir (Hammersley ve Atkinson, 2007).

Etnografik gözlem, katılımcı gözlem veya gözlemci gözlemi olarak gerçekleştirilebilir. Katılımcı gözlemde, araştırmacı, gözlem yaptığı topluluğun bir üyesi gibi davranır, etkileşimlere katılır ve olaylara doğrudan dahil olur. Böylece, topluluğun içindeki deneyimleri, değerleri, inançları ve davranışları daha derinlemesine anlamayı hedefler. Gözlemci gözlemi ise, araştırmacının dışarıdan gözlem yaparak topluluğu analiz etmesini sağlar. Bu durumda, araştırmacı daha objektif bir konumda kalır ve gözlemlerini kaydeder.

Etnografik gözlem genellikle nitel araştırma yöntemlerinin bir parçası olarak kullanılır. Araştırmacı, alan çalışması yaparak topluluğun günlük yaşamını, etkileşimlerini, ritüellerini, dilini, sembollerini ve diğer kültürel özelliklerini gözlemler. Bu süreçte, araştırmacı genellikle notlar alır, ses veya video kayıtları yapar, fotoğraflar çeker ve diğer araştırma tekniklerini kullanır.

Etnografik gözlemde, araştırmacının önyargısız ve tarafsız bir şekilde gözlem yapması ve katılımcıları anlamaya yönelik sorular sorması önemlidir. Ayrıca, araştırmacının etik ilkeleri gözetmesi, gizlilik ve gizlilik bilgilerini koruması ve katılımcıların rızasını alması da gereklidir.

Etnografik gözlem, kültürel farklılıkları ve toplumsal yapıları anlamak, sosyal ilişkileri analiz etmek, insan davranışlarını açıklamak ve sosyal değişimi anlamak için kullanılan etkili bir yöntemdir. Araştırmacılar, etnografik gözlem sonuçlarını raporlarında ve çalışmalarında kaynak göstererek ilgili literatür ve araştırmalarla ilişkilendirirler.

Etnografik gözlem, çeşitli mekanlarda gerçekleştirilen ve antropologlar, psikologlar ve deneyimli araştırmacılar tarafından yapılan bir yöntemdir, bu yöntemde psikolojik, davranışsal ve çevresel faktörler bir arada değerlendirilir (Karaatlı vd., 2012).

2.2.1.4. Çalıştay

Bu yöntem bireylerin ortak konular hakkında çalışmasına, düşünmesine ve öğrenmesine olanak sağlayan uygulamalı akademik öğretim yöntemidir. Bu yöntem, etkin analiz ve sentez yapma olanağı sağlar. Çalıştay, durum tespiti, proje yönetimi, süreç iyileştirme, müşteri odaklılık, stratejik gelişim, hedeflerin belirlenmesi ve kişisel gelişim gibi alanlarda tercih edilmektedir (Karaatlı vd., 2012).

2.2.1.5. İkincil Veri Kaynağı

Akademik çalışmalar, çeşitli kurum ve kuruluşların (TÜİK, KOSGEB, GYODER vb.) yayınları ve piyasa verileri gibi iç ve dış bilgi kaynaklarının araştırılarak yapılan ayrıntılı araştırma türüdür. Deneyimli proje yöneticileri ile ikincil veri kaynağı çalışmaları gerçekleştirilir. Pazar araştırmalarının vazgeçilmez bir parçası olarak proje kapsamının ilk aşamasını oluşturur (Karaatlı vd., 2012).

2.2.1.6. Delphi Tekniği

Bu yöntemin amacı, uzman görüşlerini toplayıp onları yeniden düzenlemek ve öngörüler hakkında bir görüş birliğine varmaktır (Brewer, 2007). Delphi tekniği, bir sorunu çözmek veya bir konuda karar vermek için kullanılan bir yöntemdir. Bu yöntem, bir konuda uzman olan bir grup insanın fikirlerini alarak ve bu fikirleri birbirleriyle tartışarak, bir sonuca ulaşmayı amaçlar.

Delphi tekniği genellikle şu adımları izler (Hsu ve Sandford 2007).

- Sorunun veya konunun belirlenmesi
- Uzmanların belirlenmesi ve onlara sorunun/konunun açıklanması
- Uzmanlardan yazılı olarak görüşlerinin alınması ve bu görüşlerin özetlenmesi

-Özetlenmiş görüşlerin uzmanlara geri bildirimi, tartışılması ve tekrar görüş yazmaları için istenmesi

-Görüşlerin yeniden özetlenmesi ve bir sonuca varılması

Delphi tekniği, uzmanların farklı coğrafi bölgelerde veya farklı sektörlerde olması durumunda da kullanılabilir. Bu yöntem, farklı düşüncelerin birleştirilmesine ve farklı bakış açılarının değerlendirilmesine olanak tanır. Ayrıca, uzmanlar arasında bir hiyerarşi veya baskı olmaması, herkesin görüşünü özgürce ifade edebilmesi, bu yöntemin avantajları arasındadır (Yakar, 2019).

2.2.2. Kantitatif Yöntemler

Kantitatif tahminde ise matematiksel yöntemler kullanılır. Kişiye göre değil, yeterli miktardaki sayısal veriler analiz edilerek tahminde bulunulur (Karaatlı vd., 2012). Sayısal değerleri yorumlayabilen ve genelleseyebilen bir araştırma türüdür. Bu yöntem, evrenin tamamını değil, genellikle örnekleme temsil eden verilerin analizine odaklanır. Kantitatif araştırma yöntemleri, nicel verilerin ölçümlerine dayalı olarak istatistiksel analizler yapmayı ve genellemeler yapmayı amaçlar. Elde edilen sonuçlar üzerinde gerekli istatistiksel ve matematiksel analizleri gerçekleştirilebilir. Kantitatif yöntemin sayısal temsilleri vardır, bu nedenle çalışma popülasyonunu temsil eden örnekleme doğru bir şekilde belirlemek ve uygun soruları sormak önemlidir.

Kantitatif yöntemler kullanılan analizler; gözlemlenen değere ait geçmiş ve şimdiki dönem arasındaki farkların tespit edilerek, veri dizisinin dinamiklerinin belirlenerek ve bunların matematiksel bir dil ile modellenmesi süreçleridir (Christou, 2012). Kantitatif yöntemler üç bölümde incelenmektedir.

- Zaman Serisi Analizi:

- Aralarında Nedensellik İlişkisi Bulunan Yöntemler:

- Yapay Sinir Ağları Yöntemleri

2.2.2.1. Zaman Serisi Analizleri

2.2.2.1.1. Zaman

Zaman, sözlük anlamıyla iki hareket arasındaki süredir (TDK, 2009). Bu kavram göreceli olduğu için zamanı ölçmek için herhangi bir ana ya da aralığa rakamsal bir değer atanır. Bu atamada sürekli değişikliğe uğrayan unsurlar kullanılabilir, örneğin ay veya güneş gibi. İnsanlar tarih boyunca çeşitli yöntemler kullanarak zamanı ölçmeye çalışmıştır (Sarigul, 2016). İlk zamanlarda, sadece hava olaylarının zamanını bilmek yeterliyken zaman ilerledikçe daha küçük zaman birimlerine ihtiyaç duyulmuştur. İnsanlar yılları ve günleri ilk olarak birimlere bölerek kullanmışlardır. Yılları aylara ve haftalara bölen ilk topluluklardan biri Sümerlerdir.

Günümüzde zamanın daha küçük birimleri elde edilmeye çalışılmaktadır. Bu da bazen saniyenin bile önem kazandığı anlamına gelir. İstatistiksel açıdan incelendiğinde, zaman verileri belirli periyot aralıklarına göre değerlendirilerek analiz edilir. Bu periyotlar genellikle yıllık, aylık ya da haftalıktır. Zaman serileri, ekonometri, sinyal işleme, istatistik ve matematiksel finasta veri noktalarının sıklığını ifade eder. Bu veriler genellikle düzenli aralıklarla ölçülen ardışık zaman alanlarını kapsar (Wei, 2006).

2.2.2.1.2. Zaman Serileri

Zaman serileri, zamanla değişen sayısal değerlerin temsil ettiği verilerdir. Bu veriler, belirli zaman aralıklarında elde edilir ve genellikle ticari ve finansal alanlarda kullanılır. Zaman serileri analizi, bu verilere dayanarak trendleri ve mevsimsel değişimleri dikkate alarak gelecekteki talebi tahmin etmek için kullanılan bir modelleme ve analiz yöntemidir. Khandelwal vd., (2015) tarafından yapılan çalışmalarda, zaman serileri analizi konusunda detaylı bilgiler sunulmaktadır. Bu analizler, gelecekteki talebi tahmin etmek için kullanılan modeller ve yöntemler hakkında değerli bir kaynak olabilir. Analiz edilecek veriler haftalık, aylık veya yıllık rakamlardan oluşturularak birçok bilgiye ulaşma imkânını sağlamaktadır. Ticaretle uğraşıyorsa ileride ne kadar stok bulundurmamız gerektiği hatta hangi üründen ne kadar ürün yapmak gerektiği, yoğunluğa göre iş gücünün ne kadar olması gerektiği, depo alanının yetip yetmeyeceği, yatırımların nereye yapılması gerektiği gibi gözlemlenen soruların cevapları; analiz edilen zaman serisinden çıkan sonuçlardan faydalanılarak elde

edilen bilgiler arasında yer almaktadır. Böylelikle gereksiz stok, işgücü ve depolama alanına ihtiyaç kalmayacaktır.

Zaman serileri, Yıldıztan (2010)' a göre bir değişkenin değerlerinin bir periyottan diğerine sürekli olarak gözlemlendiği dizilerdir Bu diziler, rastgele değişkenlerin değerlerinin zamana göre sıralanmasıyla oluşur. Öte yandan, zaman serileri ilgilenilen olayların zamanın ve değerin bir fonksiyonu olarak gözlenmesiyle oluşturulan gruplardır (Horasan, 2011). Yani bir zaman serisi, belirli bir zaman diliminde ilgilenilen bir veya daha fazla değişkenin dağılımını tanımlayan bir dizidir (Bozdağ, 2011).

2.2.2.1.3. Zaman Serilerinin Amacı

Zaman serilerini analiz edilmesindeki amaç ilgilenilen değerler kümesini belli aralıklarla ele alarak zaman içerisinde ortaya çıkan değişimlerini saptayarak gelecekte ortaya çıkacak olan değerin doğru olarak tahmin edilmesidir (Bozdağ, 2011).

Analiz edilen zaman serisinin hangi modellemeye uygun olduğunu tespit etmek ve anlamak, diğeri ise serinin zaman içerisindeki hareketlerinden yola çıkarak gelecekte ortaya çıkacak durumu tahmin etmektir. Yirminci yüzyılın başlarından itibaren elektronik aletlerin keşfi istatistik ve analiz etme ihtiyacının ortaya çıkmasından dolayı özellikle bilgisayarın icadı ve gelişimi ile çok daha ileri safhalara gelmiştir (Bozdağ, 2011). Zaman serilerinin çeşitleri incelendiğinde; uzun dönemli trend şeklinde olan serilerde Trend büyümenin nedenini oluşturmaktadır. Durgunluk dönemlerinde görülen ve canlılık dönemlerinde görülen genişleme hareketlerinin seyrine göre dalgalanmayı temsil etmektedir. Diğer bir unsurda serilerin bir yıl içerisinde gösterdiği mevsimsel dalgalanmalardır. Son olarak artık değişkenlerden oluşan değişimlerdir(Kıran, 2014). Buna örnek vermek gerekirse normal seyrinde giden durumlar karşında aniden ortaya çıkan 19 Aralık 2019 tarihinde Çin'in Wuhan kentinden dünyanın her yerine dağılan Covit-19 virüsünden kaynaklanan izolasyonların ticarete ve ekonomide aşırı dalgalanmalara neden olmasıdır. Zaman serilerinin analizinde kullanılan birçok modelden biri de ARIMA modelidir.

Zaman serilerini analiz edilmesinde ki amaç ilgilenilen değerler kümesinin belli aralıklarla ele alarak zaman içerisinde ortaya çıkan değişimlerin saptanarak gelecekte ortaya çıkacak olan değerin doğru olarak tahmin edilmesidir.

2.2.2.1.4. Zaman Serilerinin Türleri

Zaman serilerinin türleri incelendiğinde yedi farklı türü olduğu gözlemlenmektedir. Ekonomik ve finansal seriler; iktisadi veriler analiz edilmektedir. Fiziksel zaman serileri; fen bilimlerinin konusu içinde yer alan meteoroloji, denizcilik ve coğrafi veriler analiz edilmektedir. İşletme zaman serileri; İşletmenin değişik dönemlerindeki satış verileri analiz edilerek ilerideki satış tahminleri yapılmaktadır. Demografik zaman serileri; nüfus çalışmalarının yapıldığı serilerdir. Süreçle ilgili zaman serileri; belirlenen bir hedefe ne kadar yaklaşıldığı ya da uzaklaşıldığının hesaplanmasıyla alakalıdır. İkili süreç verilerinde; verilerden birine (0) diğerine ise (1) değeri verilerek analiz yapılmaktadır. Nokta süreç verilerde; ise yıl içerisinde belirlenen bir olay ele alınarak analiz yapılmaktadır (Kıran, 2014). Zaman serilerini oluşturan bileşenleri incelendiğinde 4 çeşidi olduğu görülmektedir; bunlar genel eğilim, mevsimsellik, çevrimsel bileşen ve düzensiz bileşenlerdir. Bu bileşenler aşağıda alt başlıklar halinde detaylı açıklanmaktadır (Newbold, 2000).


2.2.2.1.4.1. Genel Eğilim(Trend) Bileşeni;

Genel Eğilim veya Trend bileşeni, bir zaman serisindeki uzun dönemli değişimleri ifade eder. Bu bileşen, zaman serisinin düzenli olarak artma, azalma veya sabit kalma eğilimini temsil eder (Newbold, 2000).

Genel Eğilim bileşeni, zaman serisindeki sistemli ve sürekli değişimleri yansıtır. Bu değişimler genellikle trend çizgisi veya eğri şeklinde görselleştirilir. Trend, genellikle zaman içindeki ortalama bir düzeyin yükselme, azalma veya sabit kalma eğilimini gösterir.


Trend analizi, gelecekteki değerlerin tahmin edilmesi için kullanılır. Trendin yönü ve eğimi, zaman serisindeki değişimin doğasını ve muhtemel gelecek değerlerini anlamamıza yardımcı olur. Trendin yukarı yönlü olması artış eğilimini, aşağı yönlü olması ise azalış eğilimini gösterir. Sabit bir trend ise değerlerin genellikle aynı düzeyde kalacağını işaret eder.

Genel Eğilim bileşeni, zaman serisi analizinde önemli bir bileşendir ve verilerin trendi doğru bir şekilde anlaşıldığında gelecekteki değerlerin tahmin edilmesinde yardımcı olur. Zaman serilerinin uzun dönemli dalgalanmalarının yükselme ve alçalmalarına rağmen artış eğilimi gösteren duruma denir. Bu durum iki şekilde gerçekleşir. Şekil 2.1’de olduğu gibi devamlı artan doğrusal bir trend ya da Şekil 2.2’de olduğu gibi zaman içerisinde azalış ve artışların olmasına rağmen artan bir eğrinin varlığıyla doğrusal olmayan trend şeklinde olmaktadır.



Kaynak: Erdoğan,2006

Şekil 2.1 Doğrusal Trend



Kaynak: Erdoğan,2006

Şekil 2.2 Doğrusal olmayan Trend


2.2.2.1.4.2. Mevsimsellik;

Mevsimsellik bileşeni, bir zaman serisinde düzenli olarak tekrarlanan ve genellikle yıl içindeki belirli dönemsel değişimleri ifade eder. Bu değişimler genellikle mevsim, ay, hafta veya diğer periyodik dönemlerle ilişkilendirilir (<https://support.minitab.com/en-us/minitab/21>).

Mevsimsellik bileşeni genellikle düzenli bir döngüsel örüntüye sahiptir ve genellikle yıl içinde aynı şekilde tekrarlanır. Bu bileşen, özellikle perakende satışlar, turizm, tarım gibi sektörlerde belirli dönemlerdeki değişimleri analiz etmek için önemlidir (<https://support.minitab.com/en-us/minitab/21>).

Mevsimsellik bileşeni, zaman serisi analizinde dikkate alınarak trendin ayrıştırılması ve tahminlerin yapılması sağlanır. Bu sayede, mevsimsel etkilerin ortadan kaldırılmasıyla daha doğru trend tahminleri elde edilebilir ve gelecekteki değerlerin daha doğru şekilde öngörülmesi sağlanır.


Mevsimsellik bileşeni, belirli bir dönemde tekrarlanan örüntüler veya dalgalanmalar şeklinde görülür. Örneğin, hava sıcaklığı verilerinde yaz aylarında artış, kış aylarında ise düşüş eğiliminin yaşanması ya da yaz aylarında dondurma satışlarının çoğalması kış aylarında azalması mevsimsellik bileşenine verilebilecek en iyi örneklerden biridir. Şekil 2.3’de yaz aylarında Mayıs ayının sonlarından başlayarak eylül ayının sonuna kadar devam eden artışla dondurma satış grafiğinin mevsimsellik açısından gösterimi yer almaktadır (<https://support.minitab.com/en-us/minitab/21>).



Şekil 2. 3 Dondurma Satışlarına Dair Mevsimsellik Grafiği

2.2.2.1.4.3. Çevrimsel (Döngüsel) Bileşen;

Dönemsel değişimler, mevsimsel faktörlerle doğrudan ilişkili olmayan, belirli dönemlerde tekrar eden düzenli varyasyonlardır (<https://support.minitab.com/en-us/minitab/21>). Bu değişimler, mevsimsel faktörlerin etkisinden bağımsız olarak ortaya çıkar. Örneğin, haftalık veya aylık bazda belirli periyotlarda tekrarlanan trendler veya etkiler dönemsel değişimlere örnek olarak verilebilir. Bu değişimler, mevsimsel faktörlerden kaynaklanmayan diğer faktörlerin etkisiyle ortaya çıkabilir ve zaman serisi analizinde dikkate alınması gereken önemli bir bileşendir.. Mevsimsel bileşenler yılın aynı döneminde gerçekleşirken çevrimsel bileşenin dönemi belli değildir. Ekonomide yer alan bu bileşen genel eğilimden bağımsız kısa süreli genişleme ya da daralma durumunu yani çevrimsel süreci tarif eder (<https://support.minitab.com/en-us/minitab/21>). Son yıllarda dünya genelinde yayılan pandemi olarak kabul edilen Covid 19 virüsü nedeniyle dünyada yaşanan ekonomik dalgalanmalar Çevrimsel Bileşen için çok iyi bir örnektir.




Kaynak: Erdoğan,2006

Şekil 2.4 Çevrimsel Bileşen

2.2.2.1.4.4. Düzensiz (Rastgele) Bileşen;

Veri analizinde kullanılan unsurlara aykırı olarak belirlenen ve nedeni belirli olmayan, hata terimi ile ifade edilebilecek değişimlerdir. Ortalamanın etrafında gerçekleşen artış ve azalışlar olarak ifade edilebilir (Seker, vd., 2013).



Kaynak: Erdoğan,2006

Şekil 2.5 Düzensiz Bileşen

Zaman serileri kendisini oluşturan bileşenlere ayrıştırıldıktan sonra, elde ettiğimiz sonuçların belli bir zamandaki bileşenlerin

Toplamına; $Serit = Trendt + Mevsimsellik + Çevrimselt + Düzensizt$
ya da

Çarpma yöntemi ile; $Serit = Trendt * Mevsimsellik * Çevrimselt * Düzensizt$

bulunmaktadır. Hesaplamalarda yer alan “t” belli bir dönemi ifade ediyor.

2.2.2.1.5. Zaman Serisi Analizinin Kullanım Amaçları

2.2.2.1.5.1. Aykırı Verilerin Tespiti

Aykırı veri; bir veri setindeki gözlemlenen değerlerin farklı ve uzağında tespit edilen değerlerdir (<https://support.minitab.com/en-us/minitab/21>). Aykırı veriler analizin sonuçlarının yanlış olmasına sebep olmaktadır. Bu değerlerin yakalanabilmesi için s seri üzerinde analizler yapılmalıdır. “*Verilen bir seride aykırı değeri yakalamak, o serinin hareketini yakalamayı gerektirir*” (Barnett VA, 1994). Bu aykırı verileri yakalamak için kullanılan yöntemler histogram, Q-Q grafiği, akış dizisi grafiği ve kutu yöntemidir. Aykırı veriler; yanlış girilmiş veriler, sistemsel hatalardan oluşan veriler veya bir olay sonucunda ortaya çıkan veriler olabilir. Bu sebeple verilerin yakalanarak aykırı veri olmalarına sebep olan olayı bulmak ve bu aykırılığın sebebine müdahalelerde bulunmak gerekmektedir (Seker, vd., 2013).

2.2.2.1.5.2. Tahmin

Zaman serilerinin analiz edilmesinin en önemli nedenlerinden biri tahmin yapmaktır. Zaman serileri, belirli bir zaman diliminde elde edilen verilerin düzenli bir şekilde sıralanmasıyla oluşan veri dizileridir. Bu veriler genellikle zaman içindeki değişimleri yansıtır ve gelecekteki değerlerin tahmin edilmesi için kullanılır (Seker vd., 2015).

Tahmin yapmak, gelecekteki olayları veya değerleri önceden belirlemek veya tahmin etmek anlamına gelir. Zaman serileri analizi, geçmiş verilerin analiz edilmesi ve desenlerin, trendlerin, mevsimsel varyasyonların ve diğer faktörlerin belirlenmesi yoluyla gelecekteki değerlerin tahmin edilmesine yardımcı olur.

Bu tahminler, çeşitli alanlarda kullanılır. Örneğin, finansal piyasalarda gelecekteki fiyat hareketlerini tahmin etmek, ekonomik göstergelerin gelecekteki eğilimlerini belirlemek, hava durumu tahminleri yapmak, pazar taleplerini tahmin etmek gibi birçok uygulama alanı vardır.

Zaman serileri analizi, istatistiksel yöntemler, regresyon analizi, zaman serisi modelleri ve diğer matematiksel teknikler kullanılarak yapılır. Bu analizler, geçmiş verilerin trendleri,

mevsimsel desenleri ve diğer faktörleri temel alarak gelecekteki değerleri tahmin etmeye çalışır.

Örneğin, yaz aylarında havaların ısınmasına bağlı olarak dondurma satışlarının artmasını tahmin etmek için, önceki yıllardaki verilere dayalı olarak mevsimsel desenleri ve trendleri analiz edebiliriz. Bu analizler, dondurma satışlarının gelecekteki performansını tahmin etmek ve üretim ve stok planlamasını buna göre yapmak için kullanılabilir.

Tahminler, iş stratejileri, planlamalar ve kaynak tahsisinde önemli bir rol oynar. Ancak, tahminler her zaman kesin olmayabilir ve belirli bir hata payı içerebilir. Bu nedenle, tahminler yapılırken bu hata payının dikkate alınması ve kabul edilebilir bir aralığın belirlenmesi önemlidir (Seker vd., 2015).

2.2.2.1.5.3. Eksik Verileri Tamamlama

Eksik verilerin yerine kullanılacak değerler zaman serisi analizi uygulanarak bulunabilir (Honaker, 2010). Yani mevcut satış verilerine zaman serisi analizi uygulandığında o verinin zaman içindeki hareketi kayıt altına alınmakta ve eksik verinin değeri hareketten yola çıkılarak tahmin edilebilmektedir.

2.2.2.1.5.4. Hata Düzeltme

“Seride tespit edilen aykırı verilerin serideki diğer değerlere yaklaştırılması işleminde de kullanılır” (Crosswhite, 2003). Hata düzeltme, zaman serilerindeki tahmin hatalarını veya sistemsel hataları tespit etmek ve gidermek anlamına gelir. Zaman serilerindeki hatalar, öngörülen değerler ile gerçek gözlemler arasındaki farklardır. Bu hatalar, birçok farklı nedenden kaynaklanabilir, örneğin ölçüm hataları, veri giriş hataları, modelin yetersizliği veya beklenmeyen olaylar gibi faktörlerden dolayı oluşabilir.

Hata düzeltme yöntemleri, zaman serilerindeki hataları tespit etmek ve düzeltmek için istatistiksel teknikler ve modeller kullanır. Bu teknikler arasında hareketli ortalama, düzeltme faktörleri, regresyon modelleri, ARIMA (Otomatik Regresif Entegre Hareketli Ortalama) modelleri ve daha fazlası yer alabilir (Crosswhite, 2003).

Hata düzeltme yöntemleri, zaman serilerinin doğru tahmin edilmesini ve verilerin daha tutarlı bir şekilde analiz edilmesini sağlar. Bu da iş kararları alırken daha güvenilir sonuçlar elde etmeye yardımcı olur.

2.2.2.1.6. Zaman Serilerinin Sınıflandırılması

Zaman serileri, sürekli ve kesikli serilerde gözlenen değerlerin nasıl elde edildiğine bağlı olarak; gözlenen değerlerin serilerin ortalamasından sapmasına göre durağan ve durağan olmayan seriler, içinde bulundukları döngüsel harekete göre ise mevsimlik ve mevsimlik olmayan seriler olarak sınıflandırılırlar (Duru, 2007).

2.2.2.1.6.1. Sürekli ve Kesikli Zaman Serileri

Zaman serileri, belli bir zaman dilimi içerisinde belirli aralıklarla ölçülen bir veri kümesidir. Bu zaman serileri, sürekli veya kesikli olabilir (Duru, 2007).

Sürekli zaman serileri, belli bir zaman dilimi boyunca sürekli olarak ölçülen bir değişkenin değerlerini içerir. Örneğin, hava sıcaklığı veya hisse senetleri fiyatları gibi sürekli değişkenler sürekli zaman serileri olarak ele alınabilir. Sürekli zaman serileri, genellikle aralıksız bir zaman diliminde ölçülür ve sonsuz sayıda değere sahip olabilir (Duru, 2007).


Kesikli zaman serileri ise belli zaman aralıklarında ölçülen değişkenlerin değerlerini içerir. Örneğin, aylık işsizlik oranları veya günlük hisse senetleri fiyatları gibi değişkenler kesikli zaman serileri olarak ele alınabilir. Kesikli zaman serileri, belirli bir zaman dilimi içinde ölçülür ve sonlu sayıda değere sahip olabilir (Duru, 2007).

Her iki zaman serisi türü de farklı analiz yöntemleri gerektirir. Sürekli zaman serileri için genellikle diferansiyel denklemler kullanılırken, kesikli zaman serileri için regresyon veya varyans analizi gibi yöntemler kullanılabilir. Zaman serilerinin analizi, trendlerin, mevsimselliklerin ve dalgalanmaların belirlenmesine yardımcı olabilir ve gelecekteki trendleri ve değişimleri tahmin etmek için kullanılabilir (Duru, 2007).

2.2.2.1.6.2. Durağan ve Durağan Olmayan Zaman Serileri

Durağanlık, basitçe bir zaman serisi olarak geçmiş, şimdiki zaman ve gelecekte benzer bir zaman serisi olarak tanımlanabilir. Ancak daha teknik bir açıklama yapılacak olursa durağanlık stokastik (rastgele değişkenlere bağlı) bir süreç olarak tanımlanabilir. Bu süreçte, bir değişkenin zaman içindeki varyansı (verilerin aritmetik ortalamadan sapmalarının karelerinin aritmetik ortalaması), ortalaması ve otokovaryansı (iki değişkenin birlikte ne kadar değiştiklerinin ölçüsü) sabit kalır ve serideki değerler belirli bir değere yaklaşır veya beklenen değer etrafında dalgalanır (Kırçıl, 2013).

Zaman serileri genellikle stokastik süreçlerdir ve durağanlık bu süreçlerle ilgili önemli bir kavramdır. Bir zaman serisi, eğer tüm özellikleri (ortalaması, varyansı, kovaryansı vb.) zaman içinde değişmiyorsa veya seri periyodik dalgalanmalardan temizlenmişse durağan zaman serisi olarak adlandırılır. En basit durağan zaman serisi, beyaz gürültü (white noise) sürecidir. Bu konuda yapılmış bazı çalışmalara göre, durağanlık, zaman serilerinin analizi ve tahmini için önemli bir kavramdır (Duru, 2007; Kırçıl, 2013; Erdoğan, 2006; Gözcü, 2009).



Kaynak: (<https://www.sisasoft.com.tr/zaman-serisi-nedir/>)

Şekil 2.6 White Noise (Beyaz Gürültü) Serinin Grafiği

Şekil 2.6’da White Noise (Beyaz Gürültü) sürecine ait bir grafik yer almaktadır. Grafikte değerler “0” sayısının etrafında azalmakta ve artmaktadır. Bir Y_t olarak tanımlanan serisinin durağan olması için aşağıdaki özellikleri sağlaması gerekmektedir (Erdoğan, 2006; Gözcü, 2009).

-Yt serisinin zamana bağı kalmayan sonlu bir varyansı vardır. Bu şart, serinin varyansının zamanla değişmediğini ve sabit kaldığını ifade eder.

-Yt serisi, sabit bir değ er etrafında yer alır. Yani, serinin ortalaması sabittir. Bu koşul, serinin zamanla ortalamasının değişmediğini ifade eder.

-Yt serisinin iki değ eri arasındaki kovaryansı yalnızca bu iki değ erin zamansal uzaklığı na bağı ldır. Bu, serinin zamana bağı lı bir kovaryans yapısına sahip olmadığı anlamına gelir.

Burada t, bir zaman noktasını ifade eder ve Yt, bu zamandaki Y değ erini temsil eder. t'deki bir değ er için ortalama $E(Y_t) = \mu$ ve t'deki bir değ er için varyans $Var(Y_t) = \sigma^2$ olarak ifade edilebilir. Varyans, verilerin aritmetik ortalamadan sapmalarının karelerinin toplamıdır.

Kovaryans, iki değ işken arasındaki doğrusal ilişkinin değ işkenliğini ölçen bir kavramdır. Eđer Yt ve Yt+k iki zaman serisi ise, bu iki serinin kovaryansı $Cov(Y_t, Y_{t+k}) = \gamma_k$ şeklinde gösterilir. Burada γ_k , iki serinin korelasyonunu ve ilişkisini ölçen bir değ erdir (Erdoğan, 2006; Gözcü, 2009).

Kovaryans, iki serinin varyansının da bir ölçüsüdür. İki serinin kovaryansı, her bir serinin varyansı ile ilişkilidir. Örneğin, iki serinin kovaryansının pozitif olması, bir serinin yüksek değ erlerinin diğ er serinin yüksek değ erleriyle ilişkili olduğunu gösterir. Ancak, kovaryansın işaretinin pozitif ya da negatif olması, iki serinin arasındaki ilişkinin şiddeti hakkında bilgi vermez. Bu nedenle, kovaryansın normalizasyonu için korelasyon katsayısı kullanılır (Erdoğan, 2006; Gözcü, 2009).

Durağan olmayan zaman serileri (Erdoğan, 2006; Gözcü, 2009).

Serilerin geçmişteki, şimdiki ve gelecekteki hareketleri birbirine benzemez ve durağan olmayan seriler genellikle artan veya azalan bir trend sergiler. Bu serilerin durağan serilerden farklı özellikleri vardır ve durağan olmayan zaman serileri daha güçlü bir belleğe sahiptir. Durağan serilere gelen şoklar zamanla etkisini kaybederken, durağan olmayan serilere gelen şoklar ise serinin yapısını değiştirebilir.

Durağan olmayan zaman serilerinin özellikleri şöyle sıralanabilir (Erdoğan, 2006; Gözcü, 2009).

-Serinin değerleri belirli bir değer etrafında dağılmaz ve bu nedenle sabit bir ortalamaya sahip değildir.


-Serinin varyansı zamana bağlıdır ve sonsuza gider.

-Serideki gözlemler arasındaki ilişki, gözlemlerin birbirine uzaklığı arttıkça azalmaz. En basit durağan olmayan zaman serisi rastgele yürüyüş sürecidir.

Rastgele yürüyüş süreci şu şekilde gösterilir:

$$Y_t = Y_{t-1} + e_t \quad (2.1)$$

Burada, Y_{t-1} ve Y_t serisinin gecikme değerlerini, e_t ise sıfır ortalamaya sahip bağımsız ve dağılımı tesadüfi olan değişkenleri ifade eder. (Kaynaklar: Elma, 2008; Erdoğan, 2006; Sevüktekin ve Nargeleçkenler, 2007)



Kaynak: <http://mattgrobis.blogspot.com/2016/04/introduction-to-r-3-for-loops->

.....and.html (Erdoğan,2006)

Şekil.2.7. Random Walk (Rastgele Yürüyüş) Grafiği

Şekil 2.7. Değerlerin zamana göre değişimleri göstermekte ve bütün değerler birbirlerinden bağımsız ve farklılık göstermektedir. Değerlerin zamana göre değiştiği ve bu değişimlerin

birbiriyle ilişkisiz olduğu durumlar sıkça karşılaşılan durumlardır. Bu, her zaman serisi gözlem değerinin önceki ve sonraki değerlerinden bağımsız olduğu anlamına gelir. Zaman serilerinin çalışması belirsiz bir gelecek hakkında tahminler yapmayı amaçladığından, stokastik (tesadüfi) süreç durağan değilse, serinin davranışı sadece incelenen tahmin dönemi için geçerli olacak ve ilgili diğer dönemlere genelleme yapılamayacaktır (Kırçıl,2013).

2.2.2.1.7. Mevsimsel ve Mevsimsel Olmayan Zaman Serileri

Zaman serilerinde, benzer hareketlerin aynı aylarda görülmesi durumunda mevsimsel bir seri söz konusu olabilir. Bu tür serilerin analizi yapılırken, mevsimsel etkilerin tüm serinin varyansını etkilediği dikkate alınmalıdır. Mevsimsellik göz ardı edilerek yapılan analizler yanlış sonuçlara ve artan varyansa neden olabilir (Duru,2007).

Mevsimsellik içeren serilerin analiz edilmesi için iki farklı yaklaşım mevcuttur. İlk yaklaşıma göre, seri mevsimsellikten arındırılarak analiz edilmeli ve bu amaçla Üstel Düzleştirme Teknikleri, Hareketli Ortalama Yöntemi, Tramo/Seats Yöntemi ve Ayrıştırma yöntemleri kullanılabilir (Duru,2007).

İkinci yaklaşıma göre ise, mevsimsel değişimler ekonometrik model yardımıyla açıklanmalıdır. Bu yaklaşımda, mevsimselliği düzeltmek yerine ilişkilerin model içerisinde açıklanması gerektiği kabul edilir (Duru, 2007; Kırçıl, 2013). Birinci görüşte ifade edilen mevsimsel düzeltme yöntemleri aşağıda kısaca açıklanmıştır.

2.2.2.1.7.1. Hareketli Ortalama

Hareketli ortalama yöntemi, F.R. Macaulay tarafından 1951 yılında geliştirilmiş bir yöntemdir. Bu yöntem, tüm zaman serilerinin analiz edilebilmesi için dört bileşenden yararlanır ve ad-hoc yöntemleri olarak da bilinir (Macaulay, 1951; Hull, 2015).

Bu yöntemde, hareketli ortalama filtreleri kullanılarak tüm mevsimsel etkiler kabul edilir ve beklenen değer etrafında simetrik bir şekilde dağılır. Bu şekilde, merkezi hareketli ortalama filtreleri kullanılarak mevsimsel etkiler tamamen yok edilir. Ancak, bu yöntemin dezavantajı,

anlaşılamayan mevsimsel etkiler nedeniyle seride gözlem kaybına yol açabilmesidir (Macaulay, 1951; Hull, 2015).

Kaynaklarda bu yöntemin kullanımının dezavantajlarına da değinilmiştir. Örneğin, bazı durumlarda bu yöntem, mevsimsel etkileri tamamen yok etmekte başarısız olabilir ve yanıltıcı sonuçlar verebilir. Bu nedenle, diğer mevsimsel düzeltme yöntemleri ile birlikte kullanılması veya ekonometrik modellerle birlikte kullanılması önerilmektedir (Çiğdem, 2009; Yolsal, 2010).

2.2.2.1.7.2. Üstel Düzleştirme Teknikleri

1950 yılında geliştirilen bu tekniğin anlaşılması kolaydır (Çiğdem, 2009). Üstel yumuşatma yöntemi, verilerdeki en son değişiklikleri ve sıçramaları dikkate alarak tahminlerin veya tahminlerin sürekli olarak güncellendiği bir yöntemdir. Zaman serisi verilerinin üstel düzleştirilmesi, en yeni ve en eski gözlemler için katlanarak azalan ağırlıkların atanmasıdır. Üstel düzleştirme, önceki gözlemlerin etkisini zamanla azaltarak en son gözlemlere daha fazla ağırlık verir. Bu, daha yeni verilerin eski verilere kıyasla daha fazla önem taşıdığı düşüncesine dayanır. Yöntem, ağırlıkların katlanarak azalması sayesinde daha eski verilerin etkisini zamanla azaltır.

Üstel yumuşatma yöntemi, hem deterministik hem de stokastik trendlere sahip tüm serilere uygulanabilir. Bu tekniği kullanan uzun vadeli tahminler çok güvenilir olmayabileceğinden, genellikle kısa vadeli tahminler yapmak için üstel düzeltme kullanılır (Yolsal, 2010).

2.2.2.1.7.2.1. Ayrıştırma (Decomposition) Yöntemi

Ayrıştırma, bir bütünün parçalara ayrılması işlemidir. Bu yöntem genellikle karmaşık sorunların çözümü için kullanılır. Bir sorunu parçalara ayırmak, problemi daha küçük ve daha yönetilebilir parçalara bölmek anlamına gelir. Bu parçalar, sorunu daha iyi anlamasını ve çözmesini sağlayabilir. Her bir parçayı ayrı ayrı ele alarak, daha spesifik ve sınırlı bir kapsamda çalışma imkanı elde edilebilir (Erkaymaz, 2013).

Örneğin, bir programlama problemi çözülmek istenildiğini varsayalım. Bu problem karmaşık olabilir ve doğrudan çözülemez olabilir. Ancak, problemi daha küçük parçalara ayırarak her bir parçayı ayrı ayrı ele alarak çözülebilir. Örneğin, bir programlama probleminin çözümü için, veri girişi, veri işleme ve veri çıktısı olmak üzere üç ayrı parçaya ayrılabilir. Daha sonra, her bir parçayı ayrı ayrı ele alarak, sorunun tamamı çözülebilir.

Ayrıştırma yöntemi, bir problemi daha kolay ve daha yönetilebilir parçalara ayırarak, her bir parçayı ayrı ayrı ele alarak daha hızlı ve daha etkili bir şekilde çözmeyi sağlar. Bu yöntem, karmaşık problemlerin çözümünde büyük ölçüde yardımcı olabilir ve sonuç olarak daha iyi bir çözüm elde edilebilir.

2.2.2.1.7.2.2. Tramo/Seats Yöntemi

Tramo/Seats yöntemi, 1997 yılında İspanya Merkez Bankası çalışanları Gomez ve Maravall tarafından geliştirilmiştir. Bu yöntemde, zaman serisi deterministik etkilerden arındırıldıktan sonra seri üzerine Wiener-Kolmogorow filtresi uygulanarak seri mevsimsel etkilerden arındırılır. Wiener-Kolmogorow filtresinin kullanılmasıyla, çalışılan seride tahmin ve geriye dönük düzeltme yapılabilir (Duru,2007; Kırçıl,2013).

Tramo, aykırı olan değerleri, ticaret günleri(hafta içi günleri olarak kabul edilir) ve tatil etkilerini hesaplar. Bu işlemten sonra, seriler Seats yönteminden geçirilir ve gerçek analiz burada yapılır. Seats yöntemi, gözlenemeyen bileşenlerin spektral yoğunluk fonksiyonu içinde analizini yapar (Çiğdem,2009; Uslu,2011).

2.2.2.2. Aralarında Nedensellik İlişkisi Bulunan Yöntemler

Nedensellik tahmin yöntemleri, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi matematiksel bir fonksiyonla açıklamaya çalışır. Bu yöntemlerde, bağımlı değişkenin tahmini, bağımsız değişkenlerin etkileri ve bu etkilerin belirlenmesi üzerine kuruludur. Örneğin, bir otelin doluluk oranını tahmin etmek istediğimizi düşünelim. Bu durumda bağımlı değişkenimiz doluluk oranı olacaktır. Doluluk oranını etkileyebilecek çeşitli bağımsız değişkenler bulunabilir. Örneğin, oda fiyatları, rekabetçi otellerdeki oda fiyatları, tatil dönemlerinde reklam harcamaları, hava durumu gibi faktörler bağımsız değişkenler

olarak kullanılabilir. Bu faktörlere dayanarak, otelin doluluk oranı tahmin edilmeye çalışılır (Chatterjee and Price, 1975).

İlişkisel tahmin yöntemleri, tahminlerin yanı sıra politika belirleme imkanı da sağlar. Yöneticilere çeşitli faydalar sunar, çünkü parametrelerin değiştirilmesinin nedenleri hakkında bilgi edinilir ve mevcut stratejiler kolayca belirlenip yönlendirilebilir. Bu yöntemlerin uygulanması, birden fazla parametre için bilgi toplanmasını ve uygun bir matematiksel modelin oluşturulmasını gerektirir. Bu nedenle, uygulama aşamaları, analiz aşamasına göre daha karmaşık olabilir (Chatterjee and Price, 1975).

Zaman serisi analizinde ise yalnızca tek bir değişkenin tarihsel dalgalanmaları gözlemlenir, ancak bu dalgalanmaların nedeni belirlenemez. Nedensellik temelli yöntemlerde ise parametrelerin değiştirilmesiyle ilgili bilgi elde edildiği için mevcut stratejiler kolayca belirlenebilir ve yönlendirilebilir. Ancak bu yöntemlerin uygulanması, birden fazla parametre için bilgi toplanmasını ve uygun bir matematiksel modelin oluşturulmasını gerektirir. Bu nedenle, uygulama aşamaları analizden daha zorlu olabilir (Chatterjee and Price, 1975).

2.2.2.2.1. Regresyon Analizi

Regresyon analizi, iki veya daha fazla değişken arasındaki ilişkiyi belirlemek için kullanılan bir istatistiksel yöntemdir. Bu yöntem, bağımlı değişken olarak adlandırılan bir değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi tanımlamak için kullanılır (Yanık, 2019).

Regresyon analizi, bağımlı değişkenin değişkenliğinin bir kısmını açıklayan ve onu tahmin eden bir matematiksel model oluşturur. Bu matematiksel model, bağımsız değişkenlerin değerlerine dayalı olarak bağımlı değişkenin değerini tahmin etmek için kullanılabilir.

Regresyon analizinin, iki temel türü vardır: tek değişkenli regresyon analizi ve çok değişkenli regresyon analizi. Tek değişkenli regresyon analizi, yalnızca bir bağımsız değişken ve bir bağımlı değişken arasındaki ilişkiyi incelerken, çok değişkenli regresyon analizi birden fazla bağımsız değişkenin bir bağımlı değişken üzerindeki etkisini inceler (Yanık, 2019).

Regresyon analizi, birçok farklı alanda kullanılır, örneğin ekonomi, işletme, sosyal bilimler, mühendislik, tıp ve biyoloji gibi alanlarda kullanılır. Regresyon analizi, lineer regresyon, çoklu regresyon, lojistik regresyon, non-lineer regresyon ve doğrusal olmayan regresyon gibi birçok farklı model ve teknik içerir (Yanık, 2019).

Regresyon analizinde, parametrelerin arasındaki doğrusal ya da doğrusal olmayan ilişkileri ifade eden regresyon denklemleri aşağıda verilmiştir.

Basit doğrusal regresyon:

$$Y = a + bX \quad (2,2)$$

Çoklu doğrusal regresyon:

$$Y = a + b_1X_1 + b_2X_2 + b_3X_3 + \dots + b_nX_n \quad (2,3)$$

Üstel regresyon:

$$Y = a + bX + e \quad (2,4)$$

Doğrusal olmayan regresyon:

$$Y = a + b_1X_1 + b_2X_2^2 + b_3X_3^3 + \dots + b_nX_n^n + e \quad (2,5)$$

Basit doğrusal regresyon; bir bağımlı birde bağımsız değişken içeren analiz yöntemidir.

Y= Bağımlı değişken(Tahmini talep değeri)

X= Bağımsız (açıklayıcı) değişken

a=Regresyon denkleminin sabit terimi

b= Regresyon katsayısı

e= Hata terimi(Kalıntı)

Regresyon katsayısı b, bağımsız parametre X'te bir birimlik bir artış veya azalma ile bağımlı Y parametresindeki değişimi temsil eder. Fonksiyonun a ve b parametrelerini hesaplamak için en küçük kareler yöntemi kullanılır. En küçük kareler yöntemi, nokta kümesi için en

uygun eğri belirlenebildiği için kullanılır. Amaç hata değerlerinin karelerini minimumda tutmak ve parametreler için tahmin edilen değerleri hesaplamaktır. Yani en küçük kareler yöntemiyle hesaplanan tahmin değerlerinin fiili talep değerlerinden sapmalarının kareleri toplamının minimum düzeyde tutulması amaçlanmaktadır (Yüzer, 2004).

Hata karelerinin toplamını minimize eden lineer denklem belirlendikten sonra talep tahmini yapılabilir. Tahmin çalışması yapılırken bağımsız parametre X yerine değerine ulaşılacak istenen periyot numarası konur(Adalı, 2020). $Y=a+bx$ denklemindeki parametrelerin değerleri Denklem 12'deki formüller kullanılarak hesaplanır:

$$b = \frac{n \sum xy - (\sum x)(\sum y)}{n \sum x^2 - (\sum x)^2} \quad (2,6)$$
$$a = \frac{\sum Y}{n} - b \frac{\sum X}{n}$$

Burada:

X: Dönem numaraları

y: Geçmiş talep değerleri

n: Geçmiş talep dönemi sayısı

2.2.2.2.2. Korelasyon Analizi

Korelasyon analizi; değişkenler arasındaki ilişkiyi, bu ilişkinin yönünü ve şiddetini bulmayı sağlayan istatistiksel bir yöntemdir. Bağımlı ve bağımsız değişken arasındaki ilişkinin kuvvetine korelasyon katsayısı denilmektedir. Örnek vermek gerekirse öğrencilerin ders çalışmaya ayırdıkları süre ile aldığı notu arasında ilişki olup olmadığını gibi bağımsız değişkenimiz ders notu (X) ile bağımsız değişkenimiz ders çalışmak (Y) arasındaki ilişki korelasyon katsayısı ile incelenir. Korelasyon katsayısı, iki değişken arasındaki doğrusal ilişkinin ölçüsü olup, çalışılan değişkenlerin birimlerinden bağımsızdır ve $-1 \leq r \leq 1$ arasındadır. Korelasyon katsayısının 0'a yaklaşması değişkenler arasında zayıf bir ilişkinin, birlikte artması veya azalması durumunda pozitif, değişkenlerden biri artarken diğ erinin azalması durumunda negatif bir ilişkinin varlığını gösterir (Tanyaş ve Baskak, 2013). İki değişken arasındaki değerler; aşağıdaki gibi değerlendirilmektedir.

$0,9 \leq r < 1$: Çok güçlü bir ilişki

$0,7 \leq r < 0,9$: güçlü bir ilişki

$0,4 \leq r < 0,7$: Orta dereceli bir ilişki

$0,2 \leq r < 0,4$: Zayıf bir ilişki

$0 \leq r < 0,2$: Çok zayıf bir ilişki

2.2.2.2.3. Box Jenkins Yöntemleri (Arıma)

Zaman serisi analizi, geçmiş verileri kullanarak gelecekteki talep tahminlerini yapmak için istatistiksel ve matematiksel teknikler kullanır. Zaman serisi analizinde, zaman içindeki değişimlerin paternleri, trendler, mevsimsellik ve rastgele hata bileşenleri gibi faktörler incelenir. Bu faktörler, geçmiş verilerde bulunabilir ve gelecekteki talep tahminlerinde kullanılabilir. En yaygın zaman serisi modelleri ARIMA (Otomatik Regresyon Entegre Hareketli Ortalama) modelleridir. ARIMA modeli, zaman serisi verilerini regresyon analizi ve hareketli ortalama yöntemiyle modeller (Box Jenkins ve Reinsel, 2008).

ARIMA modeli, zaman serilerinin analizinde kullanılan bir yöntemdir ve ilk olarak Croston ve Box-Jenkins tarafından kullanılmıştır. Bu model, kesikli, doğrusal stokastik süreçlere dayanır (Box Jenkins ve Reinsel, 2008).

ARIMA modeli, Box-Jenkins tahmin modellerinin bir parçasıdır. Bu modeller AR (otoregresif), I (fark), MA (hareketli ortalama) ve S (mevsimsel) bileşenlerinden oluşur. Ayrıca, ARIMA modeli, otoregresif fark D ve hareketli ortalama bileşenlerini de içerebilir (Box Jenkins ve Reinsel, 2008).

AR bileşeni, mevcut gözlemlerin geçmiş gözlemlerine bağımlı olduğu otoregresif bir modeldir. I bileşeni, serinin durağan hale getirilmesi için fark alma işlemidir. MA bileşeni, mevcut gözlemlerin önceki hatalara bağımlı olduğu hareketli ortalama bir modeldir. S bileşeni, mevsimsel etkilerin modellenmesi için kullanılır (Box Jenkins ve Reinsel, 2008).

ARIMA modeli, zaman serilerindeki trendler, durağanlık ve mevsimsel etkiler gibi yapıları yakalamak ve tahmin etmek için kullanılır. Bu model, geçmiş verilere dayalı olarak gelecekteki değerleri tahmin etmek amacıyla kullanılır. ARIMA modelinin parametreleri,

modelin karmaşıklığını ve etkinliğini belirler. Model ifade edilirken ARIMA (pp, dd, qq)*(PP, DD, QQ)ss şekli kullanılmaktadır. Burada küçük harflerle kullanılan p, d ve q mevsimsel olmayan birleşenleri ifade ederken, büyük harflerle ifade edilen P, D ve Q mevsimsel birleşenleri ve s' ise mevsimsellik periyodunu ifade etmektedir. AR(p) ve MA(q); ARMA(p, q) şeklinde kullanılarak mevsimsel olmayan durağan süreçleri ifade eder. ARMA(pp, qq)*(PP, QQ)ss mevsimsel ve durağan süreçleri ifade etmektedir (Box Jenkins ve Reinsel, 2008).

$$\phi(B)(1 - B)^d z_t = \theta_0 + \theta(B)a_t \quad (2.7)$$

Arıma modelinin formülü (2.7) 'de olduğu gibidir. $\phi(B)$ p değeri ve $\theta(B)$ q değerini ifade etmektedir. (B) gecikme operatörü, z_t t zamanındaki geçmiş veridir ve θ_0 sabit bir terimdir. a_t hata teriminin genellikle bağımsız olduğu varsayılır ve ortalaması sıfırdır. Sabit bir zaman serisine dönüştürmek için farklılaştırmanın kullanılması gerekmektedir. Birinci dereceden fark şu şekilde ifade edilebilir (Hanedar, Akkaya, Bizim, 2020):

$$\nabla z_t = z_t - z_{t-1} \quad (2.8)$$

zaman serisinin durağanlığı sağlanıncaya kadar serinin farkı alınarak d'nin değeri artırılır ve ∇z_t 'nin değeri bulur.

ARIMA modellerini tahmin edebilmek için ACF ve PACF grafiklerinden yardım alınır. ACF grafiğinden (q) değerini PACF grafiğinden ise (p) değerinin belirlenmesi sağlanarak ARIMA modeli oluşturulmaya çalışılır.

Model oluşturulmadan önce ACF ve PACF grafiklerinden yararlanılarak ve Box- Pierce tarafından geliştirilen Box –Pierce Q istatistiğinden de faydalanılarak serinin durağan olup olmadığı kontrol edilir.

Q istatistiği, zaman serisi verilerinde otokorelasyonun varlığını test etmek için kullanılan bir istatistiksel testtir. Bu test, m adet otokorelasyon katsayısı üzerinde χ^2 (X-Kare) dağılımına uygunluğunu kontrol eder. Bu test zaman serileri analizinde kullanılan en yaygın testlerdendir. Q istatistiği, analiz edilen verinin parametre tahmini yapılarak hata payları elde edildikten sonra bu hata paylarının yeterli olup olmadığının araştırılmasını sağlayan bir testtir (Hanedar, Akkaya, Bizim, 2020).

$$Q = n \sum_{k=1}^n r_k^2 \quad (2.9)$$

Ljung –Box istatistiği:

$$Q = n(n+2) \sum_{k=1}^m \frac{r_k^2}{n-k} \quad (2.10)$$

Q: Q istatistiği

n: Zaman serisi veri setindeki gözlem sayısı

m: Test edilecek otokorelasyon katsayısı sayısı (lag sayısı)

r_k : Lag k (gözlem aralığı k) için otokorelasyon katsayısı

Σ : Sigma sembolü, toplamı ifade eder

k=1: Toplamı alınacak otokorelasyon katsayılarının başlangıç noktası

m: Toplamı alınacak otokorelasyon katsayısı sayısı

(n+2): (n-k) ifadesinin toplamda n+2 olduğunu ifade eder

Q istatistiği, serinin durağanlığını test etmek için kullanılan bir istatistiksel ölçüdür. Bu istatistik, m serbestlik derecesine sahip χ^2 dağılımını (Ek-1) takip eder.

Durağanlık testinde, önceden belirlenmiş bir anlamlılık düzeyi (genellikle α olarak gösterilir) kullanılır. Eğer Q istatistiği, α düzeyindeki $\chi^2(m)$ tablo değerinden daha büyükse, bu durumda serinin durağan olmadığına ve otokorelasyonun var olduğuna dair kanıtlar olduğu kabul edilir. Bu durumda serinin durağanlığı sağlanamamıştır.

Ancak, eğer Q istatistiği, α düzeyindeki $\chi^2(m)$ tablo değerinden daha küçükse, bu durumda serinin durağan olduğu kabul edilir ve otokorelasyonun istatistiksel olarak anlamlı olmadığı anlaşılır. Bu durumda serinin durağanlığı sağlanmıştır.

Özetle, Q istatistiği serinin durağanlığını test etmek için kullanılır. Eğer Q istatistiği α düzeyindeki $\chi^2(m)$ tablo değerinden büyükse, serinin durağanlığı sağlanamamıştır. Eğer Q istatistiği α düzeyindeki $\chi^2(m)$ tablo değerinden küçükse, serinin durağan olduğu kabul edilir (Hanedar, Akkaya, Bizim, 2020).

2.2.2.2.3.1. Otoregresiv Modeller AR(p) Süreci

Analiz edilen serinin geçmişini yansıtan bilgi yalnızca kendi değerlerine göre modellenirse otoregresif süreç söz konudur.

Örneğin; bir büfede sadece su satılıyor ve her yarım saatte bir 10 adet su satılıyor. Bu 10 adet su her yarım saatte satıldığı için bu su temin edilerek yerine koyuluyor yani her zaman büfede su bulunuyor ve her zaman müşterilerin ihtiyaçlarına cevap verilebiliyor. Büfe sahibine bir şey olmadığı ve büfeyi kapatmadığı sürece bu böyle devam edecektir. Bu sürece otoregresif süreç denir. Ve büfe sahibine veya büfede oluşabilecek bir şok belli bir zamandaki süreci altüst edecektir (Hanedar, Akkaya, Bizim, 2020).

2.2.2.2.3.2. AR(1) Süreci

Birinci dereceden otoregresif süreç demektir. Birinci derece otoregresif süreç formülü (2.11)'de olduğu gibidir.

$$Y_t = \delta + \phi_1 Y_{t-1} + e_t$$
$$-1 < \phi_1 < +1 \quad (2.11)$$

Y_t : Zaman serisindeki mevcut gözlem değeri.

δ : Kesme terimi veya sabit terim. Bu, zaman serisinin(Y_t) ortalama düzeyini temsil eder.

ϕ_1 : Otokorelasyon katsayısı. Bu, bir önceki gözlemin (Y_{t-1}) mevcut gözleme olan etkisini gösterir. Değerleri -1 ile +1 arasında olmalıdır.

Y_{t-1} : Bir önceki gözlem değeri. Bu, otoregresif modeldeki önceki gözleme karşılık gelir.

e_t : Hata terimi veya rassal hata. Bu, modelin açıklamadığı veya tahmin edemediği rastgele bileşendir. Bu terim, modelin gerçekliğiyle uyumsuzlukları temsil eder.

δ : Sabit terim olup stokastik süreç olan Y_t 'nin ortalamasıdır.

σ_e^2 otokorelasyonsuz rassal değişkendir.

Bir değişken tüm dönemlerde aynı olasılık fonksiyonuna sahipse, bu değişkenin geçmiş ve gelecekteki değerlerine bakılmaksızın aynı ortalamaya ve varyansa sahip olduğu tahmin

edilir. Y_t ve Y_{t-s} arasındaki kovaryans zamana değil, bu iki rastgele değişken arasındaki s 'nin önde gelen gecikmesine bağlıdır. Bu, geçmişe dayalı geleceği tahmin etmek için önemli bir varsayımdır. Otokoregressif parametrenin değeri $|\phi_1| < 1$ seri durağandır. $\phi_1 = 1$ ise serinin varyansı sabit olmaz ve zamanla büyür. $\delta = 0$ ise Y_t 'nin ortalaması $\mu = 0$ 'dır. Bu durum seriyi ortalamadan sapmalar cinsinden tanımlamakla özdeştir. Yani $(Y_t - \mu)$ 'a ulaşılır (Hanedar, Akkaya, Bizim, 2020).

$\delta = 0$ olarak varsayarsak AR(1)'in denklemi.

$$\begin{aligned}
 Y_t &= \phi_1 Y_{t-1} + e_t \\
 Var(Y_t) &= \sigma_Y^2 = Var(\phi_1 Y_{t-1} + e_t) \\
 &= \phi_1^2 Var(Y_{t-1}) + Var(e_t) \\
 &= \phi_1^2 Y_0 + \sigma_e^2 = Y_0 \\
 \sigma_Y^2 &= \frac{\sigma_e^2}{1 - \phi_1^2} = Y_0
 \end{aligned} \tag{2.12}$$

Şeklinde olurken.

Covaryansı ise ;

$$\begin{aligned}
 Cov(Y_t, Y_{t-1}) &= E\{[Y_t - E(Y_t)][Y_{t-1} - E(Y_{t-1})]\} \\
 &\downarrow \\
 E(Y_t) &= \mu \rightarrow E(\mu) = 0 \\
 &= E(Y_t Y_{t-1}) \\
 &= E[(\phi Y_{t-1} + e_t) Y_{t-1}] \\
 &= E[\phi Y_{t-1}^2 + e_t Y_{t-1}] \\
 &= \phi E(Y_{t-1}^2) + E[e_t Y_{t-1}] \\
 &= \phi_1 \sigma_Y^2
 \end{aligned} \tag{2.13}$$

Şeklinde olmaktadır. Bu kovaryans bütün rassal değişkenler için aynıdır (Joshua, 2013).

$$\begin{aligned}
 Cov(Y_{t-1}, Y_{t-2}) &= E(Y_{t-1} Y_{t-2}) = \phi_1 \sigma_Y^2 \\
 Cov(Y_{t-2}, Y_{t-3}) &= E(Y_{t-2} Y_{t-3}) = \phi_1 \sigma_Y^2
 \end{aligned} \tag{2.14}$$


Φ_1 sıfıra yakın değerler aldıkça ortalamayı sıkça keser.

Φ_1 bire yakın değerler aldıkça ortalamayı daha az sayıda keser.

$\Phi_1 \geq 1$ olursa patlayan seri ile karşılaşılır.

$\Phi_1 = 1$ olduğunda temiz – dizi söz konusudur.


Şekil 2.8’de Φ otoregresivin -1,1 ve 0 arasında aldığı değerlere göre oluşabilecek AR(1) modelinin ACF ve PACF grafiklerinin olası görünüşleri yer almaktadır. Uygulamalarda, sadece PACF grafiğinin ilk gecikmesindeki korelasyon miktarı istatistiksel olarak anlamlı ise, yani güven sınırını aşıyorsa ve gecikme sayısı arttıkça ACF grafiğindeki korelasyon miktarı giderek azalıyor, en uygun model seri için AR (1) modelidir. Şekil 2.8’ da bulunan iki grafik incelendiğinde ACF grafiği yavaş yavaş azalırken PACF grafiği 1. Gecikmeden sonra aniden sıfırlanıyor.



Şekil 2.8. AR(1) Modeli için ACF ve PACF Grafiği

2.2.2.3.3. AR(2) Süreci

AR(2) modelinin uygulamalarda seriye en uygun model olarak belirlenebilmesi için ACF grafiğinde ilişki miktarı giderek azalırken, PACF grafiğindeki ilk iki gecikmenin ilişkilerinin önemli olması gerekir ve ilişkiler ikinci gecikmeden sonra önemsiz hale gelmeli, yani güven sınırlarını aşmamalıdır (Hanedar, Akkaya, Bizim, 2020).



Şekil 2.9. AR(2) Modeli için ACF ve PACF Grafiği

Şekil 2.9’da yer alan grafikler incelendiğinde AR(2) modelinin ACF yavaş yavaş azalırken PACF grafiğinin 2 gecikmeden sonra aniden “0” değerine ulaştığı gözlemlenmektedir.

AR (1) ve AR (2) modellerinin özellikleri incelenirken ve olası grafikler incelenirken AR (p) modeli için ACF grafiğindeki ilişkiler giderek azalırken, ilk p'nin ilişkilerinin giderek azaldığı söylenebilir. Giderek azalmaktadır. PACF grafiğindeki gecikme önemlidir ve p’inci gecikmesinden sonraki ilişkiler önemli değildir.

2.2.2.2.3.4. Hareketli Ortalama Ma(q) Süreci

Serinin gecikmeli hata terimi mevcut hata terimini etkiliyorsa hareketli ortalama süreci tanımlanır. Hareketli ortalama sürecinde, değişkenin tahmin değeri, hata terimlerinin tahmin değeri ile ilişkilidir (Hanedar, Akkaya, Bizim, 2020).

Örneğin; Elma satan bir pazarcıdan; her gün farklı sayıda müşteri elma almaktadır ve her bir müşterinin alma ihtimali bir bağımsız olaydır. Pazarcının deneyimleri göstermiştir ki, elma satışları hava koşullarına, pazarcının tezgâhının konumuna ve pazarcının elma kalitesine bağlı olarak değişmektedir. Eğer pazarcı yeterli stokta elma bulundurmazsa, müşteriler başka bir yere gidebilirler. Bir gün içinde satılması gereken elma sayısı, pazarcının stok yönetimine göre belirlenir. Öte yandan, ilerideki günler hakkında bugünkü tercihler, gelecekteki elma satışları hakkında bir şey söylemez. Bu süreç, bir hareketli ortalama sürecidir (Hanedar, Akkaya, Bizim, 2020).

Bir hareketli ortalama süreci, MA(q) şeklinde ifade edilir. Hareketli ortalama sürecinde, her bir gecikmeli hata terimi onun şimdiki değerini etkilemektedir. MA(q) değerinin tespit edilmesi içinde ACF ve PACF grafiklerinden yararlanılır.

Genel bir MA(q) süreci için istatistiksel model:

$$Y_t = \mu + e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} \quad (2.15)$$

$$e_t \sim IID(0, \sigma^2)$$

θ_i bilinmeyen parametre

μ sabit parametre

Şeklinde ifade edilmektedir

MA(q) sürecinin ortalaması:

$$E(Y_t) = \mu \quad (2.16)$$

MA(q) sürecinin varyansı:

$$\begin{aligned}
Var(Y_t) &= Y_0 \\
&= E[(Y_t - \mu)^2] \\
&= E[e_t^2 + \theta_1^2 e_{t-1}^2 + \dots + \theta_q^2 e_t^2 - q + 2\theta_1\theta_2 e_{t-1}e_{t-2} + \dots] \\
&= \sigma_e^2 + \theta_1^2 \sigma_e^2 + \dots + \theta_q^2 \sigma_e^2 \\
&= \sigma_e^2 (1 + \theta_1^2 + \dots + \theta_q^2)
\end{aligned} \tag{2.17}$$

2.2.2.2.3.5. MA(1) Süreci

Birinci dereceden hareketli ortalama süreci;

$$Y_t = \mu + e_t + \theta_1 e_{t-1} \tag{2.18}$$

Sürecinin Ortalaması:

$$E(Y_t) = \mu \tag{2.19}$$

Sürecin Varyansı:

$$\begin{aligned}
Var(Y_t) &= E[(Y_t - \mu)^2] \\
Y_0 &= \sigma_e^2 (1 + \theta_1^2)
\end{aligned} \tag{2.20}$$

MA(1) sürecinin Kovaryansı

$$\begin{aligned}
Cov(Y_t, Y_{t-1}) &= E[(Y_t - \mu)(Y_{t-1} - \mu)] \\
&= E[(e_t + \theta_1 e_{t-1})(e_{t-1} + \theta_1 e_{t-2})] \\
Y_1 &= \theta_1 \sigma_e^2 \\
Cov(Y_t, Y_{t-2}) &= E[(Y_t - \mu)(Y_{t-2} - \mu)] \\
&= E[(e_t + \theta_1 e_{t-1})(e_{t-2} + \theta_1 e_{t-3})] \\
Y_2 &= 0 \\
Cov(Y_t, Y_{t-k}) &= E[(Y_t - \mu)(Y_{t-k} - \mu)] \\
&= E[(e_t + \theta_1 e_{t-1})(e_{t-k} + \theta_1 e_{t-k-1})] \\
Y_k &= 0
\end{aligned} \tag{2.21}$$

$K=1$ için kovaryans hesaplanabilmektedir.

$K>1$ için kovaryanslar sıfırdır.

MA(1) süreci bir dönemlik hafızaya sahiptir.


Y_t değeri Y_{t-1} ve Y_{t+1} değerleri ile korelasyonludur.

MA(1) sürecinin otokorelasyon fonksiyonunun formülü;

$$p_k = \frac{Y_k}{Y_0} = \begin{cases} \frac{\theta_1}{1+\theta_1^2} & k=1 \\ 0 & k>1 \end{cases} \quad (2.22)$$

Şeklindedir.

Hareketli ortalama modelinde, gecikme sayısı arttıkça kısmi otokorelasyon değerleri kademeli olarak üssel olarak azalmaktadır. Ancak otokorelasyon değerlerindeki bu düşüş anlıktır. Örneğin MA (1) modelinde otokorelasyon değerleri ilk gecikmeden sonra 0 değerini almaktadır. Şekil 2.10'de bulunan grafikleri incelediğimizde otokorelasyon değerleri aniden azalırken kısmi otokorelasyon değerlerinin üstel olarak azaldığı gözlemlenmektedir.



Şekil 2.10. MA(1) modeli için ACF ve PACF Grafiği

2.2.2.2.3.6. MA(2) Süreci

İkinci dereceden hareketli ortalama süreci;

$$Y_t = \mu + e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} \quad (2.23)$$

Sürecinin Ortalaması:

$$E(Y_t) = \mu \quad (2.24)$$

Sürecin Varyansı:

$$\begin{aligned} Var(Y_t) &= \sigma_e^2(1 + \theta_1^2 + \theta_2^2) \\ &= Y_0 \end{aligned} \quad (2.25)$$

MA(2) sürecinin Covaryansı;


$$\begin{aligned} Cov(Y_t, Y_{t-1}) &= E[(e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2})(e_{t-1} + \theta_1 e_{t-2} + \theta_2 e_{t-3})] \\ &= \theta_1 \sigma_e^2 + \theta_1 \theta_2 \sigma_e^2 \\ Y_1 &= \sigma_e^2(\theta_1 + \theta_1 \theta_2) \\ Cov(Y_t, Y_{t-2}) &= E[(e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2})(e_{t-2} + \theta_1 e_{t-3} + \theta_2 e_{t-4})] \\ Y_2 &= \theta_2 \sigma_e^2 \\ Cov(Y_t, Y_{t-3}) &= E[(e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2})(e_{t-3} + \theta_1 e_{t-4} + \theta_2 e_{t-5})] \\ Y_3 &= 0 \\ Cov(Y_t, Y_{t-k}) &= Y_k = 0 \end{aligned} \quad (2.26)$$

Şeklinde hesaplanır.

k=1 ve k=2 için kovaryans hesaplanabilmektedir. k>2 için kovaryanslar sıfırdır. Bu durumda MA(2) süreci sadece iki döneme sahiptir. MA(2) sürecinin otokorelasyon fonksiyonun formülü (Hanedar, Akkaya, Bizim, 2020); Aşağıdaki şekilde gibidir.

$$\begin{aligned} \rho_1 &= \frac{\theta_1(1 + \theta_2)}{1 + \theta_1^2 + \theta_2^2} & \rho_2 &= \frac{\theta_2}{1 + \theta_1^2 + \theta_2^2} \\ k > 2 & & Y_k &= 0 \\ \theta_1 + \theta_2 &< 1 \\ \theta_2 + \theta_1 &< 1 \\ |\theta_2| &< 1 \end{aligned} \quad (2.27)$$

MA(2) modelinin otokorelasyon fonksiyonlarının grafiği incelendiğinde ilk iki gecikmeye ait ilişki önemli olduğu ve kısmi otokorelasyon fonksiyonunu bakıldığında da gecikme sayısı arttıkça üstel bir şekilde azaldığı gözlemlenmektedir. Şekil 2.11’de bulunan grafiklerde MA(2) modelinin geçerli olduğu ACF ve PACF grafiklerine örnekler yer almaktadır. ACF grafiğinde 2 gecikmeden sonra yer alan ilişkilerin aniden önemsiz olduğu PACF grafiğine bakıldığında da üstel olarak azaldığı gözlemlenmektedir.



Şekil 2.11. MA(2) modeli için ACF ve PACF Grafiği

2.2.2.2.3.7. Durağan Olmayan Modeller (ARIMA)

Zaman serilerinin çoğu durağan değildir. Bunun nedenleri trend ve mevsimsellik gibi etmenlerin varlığıdır. Bunlar serinin durağanlığını bozan sebeplerdir. Durağanlığı olmayan zaman serilerinin modellenmesi yapılmadan önce serinin durağan hale getirilmesi gerekmektedir (Çevik, 1999).

Durağanlık testi, bir zaman serisinin durağan olup olmadığını belirlemek için yapılır. Durağanlık, bir zaman serisinin istatistiksel özelliklerinin zaman içinde sabit kaldığı anlamına gelir. Eğer bir zaman serisi durağan değilse, istatistiksel analizler ve tahminler yaparken yanıltıcı sonuçlara yol açabilir.

Durağanlık testi yapmanın temel nedenleri şunlar olabilir (Çevik, 1999):

Model Seçimi: Zaman serisi analizlerinde, durağanlık durumu, hangi istatistiksel modellerin kullanılacağını ve hangi tahmin yöntemlerinin geçerli olacağını etkiler. Eğer bir zaman serisi

durağan değilse, uygun olmayan modeller veya tahmin yöntemleri kullanıldığında sonuçlar yanıltıcı olabilir.

Hipotez Testleri: İstatistiksel hipotez testleri, zaman serisindeki ilişkileri değerlendirmede kullanılır. Bu testlerin güvenilir sonuçlar üretebilmesi için zaman serisinin durağanlık koşulunu sağlaması gerekebilir.

Tahmin ve Analiz: Zaman serisi analizleri ve tahminler, serinin geçmiş verilerine dayanarak geleceği tahmin etmek amacıyla yapılır. Eğer zaman serisi durağan değilse, geçmiş veriler geleceği tahmin etmek için kullanıldığında yanıltıcı sonuçlar elde edilebilir.

İlişkilerin Değerlendirilmesi: Birçok ekonomik ve finansal analizde, farklı değişkenler arasındaki ilişkileri anlamak önemlidir. Bu ilişkilerin doğru bir şekilde değerlendirilmesi için zaman serilerinin durağanlık durumu dikkate alınmalıdır.

Durağanlık testleri, zaman serilerinin analiz ve tahminlerde güvenilir sonuçlar üretebilmesi için önemli bir adımdır. Bu testler, durağanlık koşulunun sağlanıp sağlanmadığını belirlemek ve uygun analiz yöntemlerini seçmek için kullanılır.

ARIMA modeli kullanılarak analizi yapılan zaman serisinde gözlem değerleri eğer serinin ortalaması etrafında toplanmıyorsa seri fark alma işlemiyle durağan hale getirilmektedir. Fark alma işlemi ‘d’ ile sembolize edilmektedir.

Fark alma işlemiyle durağan hale getirilen seriye uygulanan modellere, durağan olmayan ARIMA modelleri denilmektedir. Bu modellerin, otoregresyon parametresi p, hareketli ortalama parametresi q, fark alma katsayısı ise d ile ifade edilerek model, ARIMA (p, d, q) şeklinde yazılmaktadır (Çevik, 1999).

$$W_t = \phi_1 w_{t-1} + \phi_2 w_{t-2} + \dots + \phi_p w_{t-p} \quad (2.28)$$

w_t : Farkı alınmış seri

Eğer seriyi, (d=1) yani birinci dereceden fark durağan hale getiriyorsa:

$$\nabla x_t = w_t = x_t - x_{t-1} \quad (2.29)$$

∇ = Fark operatörüdür.

Analiz edilen seri eğer durağan bir seri ise o zaman fark derecesi ($d=0$)' dır. Bu durumda ARIMA modeli daha önce incelendiği üzere $AR(p)$, $MA(q)$ ya da $ARMA(p, q)$ modellerinden birine dönüşebilmektedir. Bu nedenle ARIMA değişken bir modeldir (Çevik, 1999).

2.2.2.2.3.8. Mevsimsel Modeller

Analiz edilen yılların belli dönemlerinde düzenli olarak tekrar eden dalgalanmalara sahip zaman serilerine 'mevsimsel seriler' denir. Mevsimsel dalgalanmalar 's' ile ifade edilir. Bu dalgalanmalar aylık değerler üzerinde gerçekleşiyorsa $s = 12$ veya 4 (dört) aylık dönemde bir tekrarlanıyorsa $s = 3$ olarak alınır. Mevsimsellik, zaman serilerinde durağanlığı bozan faktörlerden biridir. Serinin durağanlığını sağlamak için mevsimsel etkiden arındırılması gerekir. Mevsimselliğin giderilmesi için veri setinin s'inci dereceden farkı alınması gerekmektedir. Mevsimselliğin kaldırılabilmesi için s değerinin bilinmesi önemlidir (Duru, 2007; Kendall, 1973). Zaman serilerinin mevsimselliğinin kaldırılmasında kullanılan modellerden biride ARIMA yöntemidir.

Mevsimsel fark almada kullanılan ARIMA modelinin formülü aşağıda ki gibidir.

$$\phi_p(B) \phi_p(B^s) \nabla^d \nabla_s^D x_t = \Theta_q(B) \Theta(B^s) e_t \quad (2.30)$$

ϕ : Mevsimsel otoregresyon parametresi

Θ : Mevsimsel hareketli ortalama parametresi

S : Mevsimsel dalgalanmaların uzunluğu

D : Mevsimsel fark alma derecesi

p : Mevsimsel hareketli ortalama model derecesi

$\phi_p(B^s)$ ve $\Theta(B^s)$ e_t : sırasıyla p ve q dereceden B' nin polinomları


∇_s^D : Mevsimsel fark alma operatörü

∇^d : d ' inci dereceden fark alma operatörü

Mevsimsel olmayan modelin dereceleri, (p, d, q), mevsimsel modelin dereceleri ise (P, D, Q) şeklinde formül edilmektedir.

2.2.2.2.3.9. Model Belirleme Aşamaları

Box-Jenkins modelleri, zaman serilerinin analizi, geliştirilmesi ve tahmini için kullanılan bir yöntemdir. Bu modellerin belirlenmesi için ilk olarak, zaman serisi incelenerek farklı model grupları arasından en uygun olanı seçilir. Ardından, seçilen modelin parametreleri tahmin edilir. Sonrasında, seçilen ve parametreleri tahmin edilen modelin yeterli olup olmadığı test edilir. Eğer model yeterli ise tahmin yapmak için kullanılır, aksi takdirde ilk adıma geri dönülerek daha uygun bir model seçilmeye çalışılır. Bu adımlar, uygun bir Box-Jenkins modeli bulunana kadar tekrarlanır (Çevik, 1999).



Şekil 2.12. Box- Jenkins Yönteminde Model Belirleme Çalışmaları (Çevik, 1999)

Bir serinin trendi (aritmetik ortalama) ve varyansı zaman içinde düzenli olarak değişmiyorsa bu serilere durağan seriler denir. Uygun bir Box-Jenkins modeli oluşturmanın ilk adımı, zaman serisinin durağan olup olmadığını incelemektir. Serinin durağan olmadığı belirlendiğinde farkı alınarak seriler durağan hale getirilmeye çalışılır. Zaman serisinin durağan olup olmadığını anlamak için uygulanabilecek en basit yöntem serinin grafiğini oluşturmaktır. Grafik trend ve mevsimsellik gibi unsurların olduğunu gösteriyorsa serinin durağan olmadığına karar verilir. Ancak, bu yöntemle durağanlığı tespit etmek çoğu zaman kolay değildir. Seri durağan gibi görünse de aslında zamanla değişebilir. Bu nedenle,

durağanlığı belirlemek için serilerin otokorelasyon fonksiyonlarının korelasyonlarının incelenmesi güvenilirdir. Serilerin durağanlığı araştırılırken grafikler kullanılsa da nihai bir karara varmak için bazı testlere ihtiyaç duyulmaktadır. Bu nedenle parametrik ve parametrik olmayan (parametrik olmayan) testler uygulanmaktadır (Çevik, 1999).

2.2.2.2.3.9.1. Box –Pierce istatistiği;

Box-Pierce tarafından geliştirilen Q istatistiği, zaman serisi analizinde kullanılan önemli bir testtir. Daha sonra Ljung-Box tarafından düzeltilmiştir. Test edilecek m otokorelasyon katsayısı için Q istatistiği, χ^2 (Ki-Kare) dağılımına uyar. Bu test, deneysel modelin parametre tahmini yapıldıktan ve hata payları elde edildikten sonra bu hata paylarının yeterli olup olmadığını araştırmak için kullanılır (Box Jenkins ve Reinsel, 2008).

Q istatistiği aşağıdaki formülle hesaplanır:

$$Q = n \sum_{k=1}^n (r_k)^2 \quad (2.31)$$

Ljung-Box istatistiği ise şu şekilde hesaplanır:

$$Q^* = n(n + 2) \sum_{k=1}^m \frac{r_k^2}{n-k} \quad (2.32)$$

Burada n, gözlem sayısını; m, test edilecek otokorelasyon katsayısını ifade eder. Q istatistiği, m serbestlik dereceli χ^2 dağılımını izler. Eğer Q istatistiği, $\chi^2_{0.052(m)}$ tablo değerinden daha büyük ise durağanlığın sağlanmadığı, eğer küçük ise serinin durağan olduğu kabul edilir.

2.2.2.2.3.10. Modelin Uygunluğunun Testi

Eldeki durgun bir seri verisinde, uygun bir model tahmin etmek için ACF ve PACF grafikleri kullanılır ve seçilen modelin uygunluğu Box-Jenkins tarafından geliştirilen Q istatistiği kullanılarak test edilir. Model uygunluğu için ARIMA modelindeki parametreler, Şekil

4.8'de olduđu gibi programda sekmeler takip edilerek Q istatistiđi hesaplanır. Q istatistiđi, yaklaşık olarak ki-kare deđeriyle aynıdır. Bu test, hata otokorelasyon katsayılarının sıfırdan farklı anlamlı olup olmadığını ve hata serilerinin rastgele olup olmadığını belirlemek için kullanılan yöntemlerden biridir. Bu yöntemle model uygunluđu araştırılır ve Q deđerleri, ki-kare tablosu deđerleriyle karşılaştırılır. Eđer hesaplanan Q deđeri, ki-kare (95%) tablo deđerinden büyükse, seri rastgele deđildir, uygun limitler arasında deđildir ve model uygun deđildir. Uygun model, tahmin için kullanılır (Kaya, 2019).

Box-Pierce istatistiđi (veya Q istatistiđi), zaman serisi verilerinin otokorelasyonunu (kendine bađlılık) test etmek için kullanılan bir istatistiksel testtir. Bu testin hipotezleri aşıđıdaki gibidir:

Hipotezi (H0): Zaman serisi verilerindeki otokorelasyonlar istatistiksel olarak anlamlı deđildir ve rastgeledir.

Hipotez (H1): Zaman serisi verilerinde en az bir otokorelasyon istatistiksel olarak anlamlıdır ve rastgelelik dışında bir desen gösterir.

Box-Pierce istatistiđi, otokorelasyon fonksiyonunun (ACF) karelerinin belirli bir dönem boyunca toplamını temsil eder. Bu istatistik, örneklem büyüklüğüne ve belirli bir gecikme (lag) deđerine dayalı olarak hesaplanır. Hipotez testi, bu istatistiđin örneklem dađılımını kullanarak, otokorelasyonların rastgelelikle uyumlu olup olmadığını deđerlendirir.

Eđer Box-Pierce istatistiđi altında, önceden belirlenmiş bir anlamlılık seviyesi (örneğin, %5) altında bir p deđeri elde edilirse, bu durumda null hipotezi reddedilir. Bu da, zaman serisi verilerinde en az bir otokorelasyonun istatistiksel olarak anlamlı olduđunu ve rastgelelik dışında bir yapı gösterdiđini gösterir. Alternatif olarak, p deđeri anlamlılık seviyesinden büyükse, null hipotezi reddedilmez ve verilerde anlamlı bir otokorelasyon olduđuna dair yeterli kanıt bulunmaz.

2.2.2.3. Yapay Sinir Ağları Yöntemi

Yapay sinir ağları, beynin işleme yöntemini taklit ederek bilgiyi saklama, genelleme ve tahmin etme yeteneği olan paralel dağılmış bir sistemdir. Talep tahmini gibi bir problemde, yapay sinir ağları diğer matematiksel modellerle benzer şekilde geçmiş verileri kullanır ve hata minimizasyonu prensibiyle parametre değerlerini belirler. Yapay sinir ağları, girdi katmanı, gizli katman(lar) ve çıktı katmanını olmak üzere katmanlardan oluşur. Girdi katmanı bağımsız değişkenleri temsil eder, çıktı katmanını ise bağımlı değişkenleri. Gizli katman ise farklı sayıda hücre içerebilir, ancak genellikle girdi sayısının iki katını geçmez (Ataseven, 2013).

Talep tahmini için, yapay sinir ağları ve regresyon temelli istatistiksel yöntemler arasında önemli farklar yoktur. Ancak, yapay sinir ağlarının avantajları ideal koşulların olmadığı durumlarda daha belirgindir. Yapay sinir ağları, değişkenler arasındaki ilişkileri öğrenebilme yeteneğine sahiptir ve model için varsayımlara ihtiyaç duymaz. Ayrıca, yapay sinir ağları önyargılı veya yanıltıcı varsayımlara dayalı modellerde daha etkilidir ve daha kesin tahminler yapabilir (Adıyaman, 2007).

Yapay sinir ağlarının uygulama süreci genellikle yedi adımdan oluşur: problemin tanımlanması, ilişkili özelliklerin belirlenmesi, veri toplama, veri düzenleme, yapay sinir ağı yapısının kurulması, yapay sinir ağının eğitilmesi ve son olarak ağı test edilip doğrulanması (Serttaş, 2011).

2.3. Talep Tahmini Aşamaları

Tahmin sürecinin aşamalarına bakıldığında; aşamaların hepsine, her tahmin probleminde ihtiyaç duyulmayabilir (Armstrong, 2001). Yargısal metotların kullanılacağı bir tahmin problemi için kantitatif yöntemlerin ve kantitatif nedensel yöntemlerin uygulanması aşamalarının kullanılmayacağını ifade eder. Yani, tahmin probleminde niceliksel (kantitatif) yöntemler ve nedensel yöntemlerin uygulanması aşamaları yerine yargısal metotlar kullanılacaktır. Talep tahmin sürecinin aşamaları aşağıda özetlenmiştir (Nasuhoğlu, 2019).

2.3.1. Talebi Etkileyen Faktörleri Belirleyin

Talebi tahmin yapmadan önce şirket özellikleri, ürün özellikleri, şirket konumu, şirket geleceği, plan şeması, benzer ürünlerle rekabet eden şirketlerin pazardaki konumu gibi faktörlerdir (Yılmaz, 2010).

Bu faktörler, talebin tahmin edilmesi için değerlendirilmesi gereken unsurlardır. Şirket özellikleri, şirketin genel performansı, gücü, itibarı, iş süreçleri vb. hakkında bilgi sağlar. Ürün özellikleri, ürünün kalitesi, benzersiz özellikleri, tüketici taleplerine uygunluğu vb. hakkında bilgi verir. Şirket konumu, coğrafi konum, pazar payı, hedeflenen müşteri segmenti vb. gibi faktörleri içerir.

Şirket geleceği ve plan şeması, şirketin stratejik hedeflerini, büyüme planlarını, yeni ürün veya pazar geliştirme stratejilerini ifade eder. Benzer ürünlerle rekabet eden şirketlerin pazardaki konumu ise, rekabet ortamını, pazardaki rakiplerin gücünü, rekabet avantajlarını ve pazar payını gösterir.

Bu faktörler, talep tahmini için önemlidir çünkü şirketin ve ürünün piyasada nasıl konumlandığı, rekabet ortamı, tüketici talepleri ve şirket stratejileri, talep düzeyini etkileyen faktörlerdir. Bu bilgiler, doğru talep tahmini yapabilmek ve iş stratejilerini geliştirmek için analiz edilmelidir.

2.3.2. Veri Düzenleme Ve Birleştirme

Tahmin için kullanılan bilgileri oluşturulması, şirket kayıt bilgilerinin uygun şekilde saklanması ile ilgilidir. Şirket geçmişi, son birkaç yıldaki işlemler, teslimatlar ve maliyetler hakkında bilgi sahibi olmadan gelecek için bir tahminde bulunmak mümkün değildir. Planlamacıların ayrıca iş hedeflerini de göz önünde bulundurmaları gerekmektedir. Veri içeriğini buna göre seçilmesi gerekmektedir (Yılmaz, 2010).

2.3.3. Tahmin Döneminin Belirlenmesi

Doğru tahminler yapabilmek için tahminin yapıldığı bağlama ve veriye bağlıdır. Tahmin yapmak, belirli bir durum veya olayın gelecekteki olası sonuçlarını tahmin etmek anlamına

gelir. Ancak, tahminlerin doğruluğu, tahmin edilen olayın özelliklerine, kullanılan verilere, tahmin yöntemlerine ve diğer faktörlere bağlı olarak değişebilir (Yılmaz, 2010).

Örneğin, günlük rutin aktivitelerin tahmini gibi kısa vadeli tahminler yaparken, genellikle mevcut duruma dayalı geçmiş verilere ve güncel bilgilere dayanırız. Ancak bu tahminler, beklenmedik olaylar veya değişen koşullar nedeniyle doğru olmayabilir. Örneğin, bir trafik tahmini yaparken, trafik koşullarının anlık olarak değişebileceği göz önünde bulundurulmalıdır.

Öte yandan, daha uzun vadeli tahminler yaparken, genellikle istatistiksel modeller veya makine öğrenme teknikleri kullanılır. Bu tür tahminlerde, geçmiş veriler ve trendler üzerinden gelecekteki sonuçlar tahmin edilmeye çalışılır. Ancak bu tahminler, gelecekteki bilinmeyen değişkenlerin etkisiyle yanıltıcı olabilir. Örneğin, ekonomik bir tahmin yaparken, politik veya küresel faktörler gibi dış etkenlerin de tahmini etkileyebileceği göz önünde bulundurulmalıdır.

Sonuç olarak, tahminlerin doğruluğu, kullanılan verilere, yöntemlere ve belirli durumun karmaşıklığına bağlıdır. Tahmin yaparken, olası belirsizlikleri ve değişkenleri dikkate almak önemlidir. Ayrıca, doğru tahminler elde etmek için güncel verilerin izlenmesi ve tahmin yöntemlerinin sürekli olarak gözden geçirilmesi gerekmektedir.

2.3.4. Talep Tahmin Yönteminin Seçimi

Bir tahmin yöntemi seçerken göz önünde bulundurulması gereken birçok şey vardır. İlk olarak, tahmini mevcut kaynaklar ve kısıtlamalar tanımlanmalıdır. Bunlar geçmişte elde edilen veriler, finansal fırsatlar, danışılması gereken uzman görüşleridir. İnsanlar ve kaynaklar, zaman vb. gibi kısıtlamalar, durumu tahminden elde etmeyi umarlar. Bir tahmin yöntemi seçerken, iyi bir tahmin yöntem seçilmelidir. Bu işlevler şu şekilde sıralanabilir (Chatfield, 2000):

- Tahmin dönemi doğru olmalıdır. İyi bir tahmin yönteminin tahmini dönemi doğru bir şekilde ele alınmalıdır.

- Tahminler doğru olmalıdır. Bu nedenle tahmin hatası iyi belirlenmeli ve Tüm yöntemler göz önünde bulundurularak en küçük hataya sahip yöntem tercih edilmelidir.
- Kullanılması beklenen tahmin yöntemi güvenilir bir yöntem olmalıdır. Her zaman iyi sonuç veren bir yöntem güvenilir bir yöntemdir. belirli zamanlarda iyi Belirli dönemlerde kötü sonuç veren yöntemler güvenilir kabul edilemez.
- Kullanılması beklenen tahmin yöntemi doğru birimleri içermelidir. Örneğin, Mali yönde tahminin yapıldığı para birimi gibi, tahminler birim bazlı olmalıdır.
- Tahmin metodolojisinin anlaşılması, uygulanması ve raporlanması kolay olmalıdır (Tokat, 1994).

2.3.5. Talep Tahmin Hatasının Belirlenmesi

Talep tahmin hatalarının belirlenmesi, gerçek talep değerleriyle tahmin edilen değerler arasındaki farkın ölçülmesi ve analiz edilmesi sürecidir. Talep tahmini yapılırken, tahmin edilen değerlerin gerçek talep değerlerine ne kadar yakın olduğunu değerlendirmek önemlidir. Talep tahmin hataları, tahminin ne kadar doğru veya yanlış olduğunu gösterir ve tahmin yönteminin performansını değerlendirmek için kullanılır (Gilliland, Tashman ve Sglavo, 2015).

Talep tahmin hatalarını belirlemek için kullanılan bazı yaygın metrikler şunlardır:

Ortalama Hata (Mean Error): Gerçek talep değeri ile tahmin edilen değer arasındaki farkın ortalamasıdır. Pozitif ve negatif hataların birbirini dengeleyebileceği için bu metrik tek başına yeterli olmayabilir.

Ortalama Mutlak Hata (Mean Absolute Error): Gerçek talep değeri ile tahmin edilen değer arasındaki mutlak farkların ortalamasıdır. Bu metrik, hataların mutlak değerlerini kullanarak tahminin ortalama doğruluğunu gösterir.

Ortalama Kare Hatası (Mean Squared Error): Gerçek talep değeri ile tahmin edilen değer arasındaki farkların karelerinin ortalamasıdır. Kareler kullanılarak hatalar arasındaki büyük farklar vurgulanır ve büyük hataların daha fazla etkisi olur.

Kök Ortalama Kare Hatası (Root Mean Squared Error): Ortalama kare hatasının kareköküdür. Bu metrik, hataların orijinal ölçek biriminde ifade edilmesini sağlar ve tahminin genel doğruluğunu gösterir.

Katsayı(Coef)= Bir terimin katsayısı, diğer terimler sabit tutulurken, o terimde kodlanmış bir birimin artmasıyla bağlantılı ortalama yanıtta ki değışikliğı temsil eder. Katsayının işareti, terim ile yanıt arasındaki ilişkinin yönünü gösterir (<https://support.minitab.com/en-us/minitab/21>).

Katsayının Standart Hatası(SE Coef): Katsayı tahmininin kesinliğini ölçmek için katsayının standart hatasını kullanılır. Standart hata ne kadar küçük olursa, tahmin o kadar kesin olur. Katsayının standart hatasına bölünmesi bir t-değeri hesaplar. Bu t istatistiğıyle ilişkili p değeri anlamlılık seviyenden küçükse, katsayının istatistiksel olarak anlamlı olduğı sonucuna varılır (<https://support.minitab.com/en-us/minitab/21>).

T değeri (t-Value), katsayı ile standart hatası arasındaki oranı ölçer. Seriyi analiz etmek için kullanılan Minitab 21 programı, katsayının 0'dan önemli ölçüde farklı olup olmadığını test etmek için kullanılan p değerini hesaplamak için t değerini kullanır (<https://support.minitab.com/en-us/minitab/21>).

P değeri (p-Value) bir katsayının istatistiksel olarak sıfırdan farklı olup olmadığını belirlemek için kullanılan bir istatistiksel ölçüttür. Bu ölçüt, p değerinin belirli bir önem düzeyi ile karşılaştırılması yoluyla yorumlanır. Genellikle, 0.05'lik bir önem düzeyi (α veya alfa olarak gösterilir) iyi bir sonuç verir. 0.05 anlamlılık düzeyi, katsayının sıfır olduğı durumda, sıfır olmadığı sonucuna varma riskinin %5 olduğunu gösterir (<https://support.minitab.com/en-us/minitab/21>).

Eğer p değeri α 'dan küçük veya buna eşitse ($p \text{ değeri} \leq \alpha$), yanıt değışkeni ile terim arasında istatistiksel olarak anlamlı bir ilişki olduğı sonucuna varılır. Bunun anlamı, bu ilişkinin tesadüfi olmadığı, gerçek bir ilişki olduğudur.

Ancak eğer p değeri α 'dan büyükse (p değeri $> \alpha$), yanıt değişkeni ile terim arasında istatistiksel olarak anlamlı bir ilişki olduğu sonucuna varılamaz. Bu durumda, bu ilişkinin tesadüfi olduğu, gerçek bir ilişki olmadığı anlamına gelir.

Toplam serbestlik derecesi (DF), verilerinizdeki bilgi miktarını temsil eder. Analiz, bilinmeyen popülasyon parametrelerinin değerlerini tahmin etmek için bu bilgiyi kullanır. Toplam DF, numunenizdeki gözlem sayısına bağlı olarak belirlenir. Bir terimin DF'si, o terimin ne kadar bilgi kullandığını gösterir. Örnek boyutunuz arttıkça, popülasyon hakkında daha fazla bilgi elde edersiniz ve bu da toplam DF'yi artırır. Ancak, modelinizdeki terim sayısını artırdıkça, parametre tahminlerinin değişkenliğini tahmin etmek için kullanılan mevcut DF'yi azaltırsınız (<https://support.minitab.com/en-us/minitab/21>).

Düzeltilmiş kareler toplamı (SS), modelin farklı bileşenleri için varyasyon ölçüleridir. Modeldeki tahmin edicilerin sırası, düzeltilmiş kareler toplamının hesaplanmasını etkilemez. Minitab 21, varyans Analizi tablosunda, karelerin toplamını, farklı kaynaklardan kaynaklanan değişimi tanımlayan farklı bileşenlere ayırır (<https://support.minitab.com/en-us/minitab/21>).

Düzeltilmiş ortalama kareler (MS), girdikleri sıraya bakılmaksızın, diğer tüm terimlerin modelde olduğu varsayılarak, bir terimin veya modelin ne kadar varyasyonunun açıkladığını ölçer. Ayarlanmış kareler toplamından farklı olarak, ayarlanmış ortalama kareler, serbestlik derecelerini dikkate alır. Hatanın düzeltilmiş ortalama karesi (MSE veya s^2 olarak adlandırılır), takılan değerler etrafındaki varyanstır. Minitab 21, bir terimin p-değerini hesaplamak için ayarlanmış ortalama kareleri kullanır. Minitab 21, ayarlanmış R^2 İstatistiğini hesaplamak için ayarlanmış ortalama kareleri kullanır. Genellikle, ayarlanmış ortalama kareleri yerine p-değerlerini ve düzeltilmiş R^2 istatistiği yorumlanır (<https://support.minitab.com/en-us/minitab/21>).

Bu hata metriklerinin yanı sıra, tahmin edilen ve gerçek talep değerleri arasındaki farkın dağılımını gösteren grafikler ve istatistiksel testler kullanılabilir. Talep tahmin hatalarının analizi, tahmin modelinin performansını değerlendirmek, iyileştirmeler yapmak ve gelecekteki tahminlerin doğruluğunu artırmak için önemlidir.

2.3.6. Tahmin Yoluyla Elde Edilen Sonuların İncelenmesi:

eřitli verilerin sonuları Tahmine dayalı bilgi ile kabul edilen doėru bilgi arasındaki fark için bařka yolların belirlenmesi lazım. Keskin (2016), gre bir řirket, bir mřterinin gemiř davranıřlarını biliyorsa, gelecekteki eylemleri hakkında nemli bilgiler aldıėı anlamına geldiėini ifade etmektedir. Talep etmek yoktan var olmaz. Mřteri gereksinimleri, zaman içinde eřitli faktrler tarafından oluřturulur. En azından belirli bir olasılıkla tahmin edilebilirler. İřte bu faktrler arasındaki iliřki belirlenebilirse, gelecekteki talep seviyeleri belirlenebilir.



3. LİTERATÜR TARAMASI

Bu çalışmada da kullanılan ARIMA yöntemi ile farklı sektörlerde talep tahmini gerçekleştiren literatürdeki çalışmaların bazıları aşağıda paylaşılmıştır

Alon ve Diğ., (2001), yaptıkları çalışmalarında perakende sektöründeki satış tahmini için YSA ve ARIMA analizlerini karşılaştırmış ve YSA analizinin doğrusal olmayan ve mevsimsellik ilişkilerini tahmin etmede başarılı olduğunu gözlemlemiştir.

Ceydeli (2006), çalışmasında, bir üniversite hastanesindeki bilgisayarlı tomografi cihazının yenilenme yatırımlarının değerlendirilmesi amaçlanmıştır. Çalışmada, Haziran 2004-Mayıs 2005 dönemine ait veriler kullanılarak, mevcut bilgisayarlı tomografi cihazının kapasite kullanım oranı %75 olarak hesaplanmıştır. Ayrıca, Haziran 2005-Mayıs 2006 gelecek dönemi için en küçük kareler yöntemi kullanılarak (doğrusal, parabolik ve yarı logaritmik (üssel) yaklaşımlar), tetkik talep tahmini gerçekleştirilmiştir. Çalışmada, ilgili cihazın yıllık teorik kapasitesi 13.949 hasta olarak belirlenmiş ve edilen %75 kapasite kullanım oranının arttırılması için, personel sayısının artırılması, iş süreçlerinde revizyonlar yapılması, hizmet içi eğitimlerin verilmesi gibi düzenlemelerin yapılması önerilmiştir. Bu önerilerin uygulanmasıyla, cihazın kapasite kullanım oranının arttırılabileceği ve hastaların hizmet alım süreçlerinin daha etkin hale getirilebileceği vurgulanmıştır

Lim vd. (2009), tarafından yapılan çalışmada, konaklama sektöründe yer alan işletmelerin bu modelleri kullanmasıyla yönetim ve planlamada maliyet avantajı kazanabilecekleri ve Winter yönteminin kendisinden daha karmaşık yöntemler olarak gösterilen ARMA ve Box Jenkins yöntemleri kadar iyi performans gösterdiği vurgulanmıştır.

Yaşar (2009), kent içi otobüs taşımacılığı talep tahmini konulu çalışmasında, Kraft Talep Modeli kullanılarak sabit mobilite faktörü kullanılarak tahmin edilmiştir. Yapılan tahminler kullanılarak değişik senaryolar altında arz-talep analizi yapılmıştır. Taşınabilecek yolcu sayısı üzerinde yolcu başına getirilerin doğrudan etkisi olduğu tespit edilmiştir.

Kam, Sung ve Park (2010), araştırmasında, Kore'deki bir hastanenin acil tıp merkezi için günlük hasta sayısını tahmin etmek amacıyla zaman serisi analizi kullanılmıştır. Araştırmada, Ocak 2007 - Aralık 2008 dönemine ait veriler hastane veri tabanlarından toplanmıştır. Hareketli ortalama MA(2), tek değişkenli otoregresif hareketli ortalama SARIMA(1,0,1)(0,1,1)₇ ve çok değişkenli SARIMA(1,0,2)(0,1,1)₇ modelleri kullanılarak ayrı ayrı tahminler yapılmıştır. Yapılan tahminlerin karşılaştırılmasında, çok değişkenli SARIMA modelinin tahminlerinin MAPE değeri %7,4 olarak hesaplanmış ve en küçük çıkan bu değer nedeniyle en uygun tahmin modeli olarak seçilmiştir. Bu sonuçlar, araştırmada elde edilen verilerin güvenilirliği ve analizin etkinliği açısından önemli bir bulgu olarak değerlendirilmiştir.

Soysal ve Ömürgönülşen (2010), turizm sektöründe, 2000-2007 yılları arasında Turizm Bakanlığı tarafından verilen turizm işletme belgesine sahip tesislerde konaklayan yerli ve yabancı turist sayısı verileri kullanılarak, 2008 yılı için gelebilecek turist sayılarının tahmini yapılmıştır. Winter yöntemi, mevsimselliği ve trend içermesi sebebiyle sahip olunan veri setiyle tahmin yapılması için daha uygun olduğu sonucuna varılmıştır.

Köksal, Irmak ve Asilkan (2012), araştırmasında, özel bir hastanenin hasta yoğunluğunu tahmin etmek amacıyla üstel düzgünleştirme (Winters Additive), yapay sinir ağları ve ARIMA modellerini kullanmışlardır. Araştırmada, her bir yöntemin farklı kombinasyonları ile tahminler gerçekleştirilmiş; üstel düzgünleştirme yöntemleri içerisinde Winters Additive modeli, yapay sinir ağları yöntemleri arasında Prune yöntemi ve ARIMA yöntemleri içerisinde ARIMA(3,1,0)(1,0,0)₁₂ modeli en iyi sonuçları elde etmiştir. Ancak bu üç yöntem içerisinde, hasta yoğunluğunu tahmin etmede en başarılı ve gerçek değerlere en yakın tahminleri sağlayan modelin, Winters Additive üstel düzgünleştirme modeli olduğu tespit edilmiştir. Bu çalışma kapsamında, hastane veri tabanından sağlanan veriler kullanılmıştır.

Akar (2014), çalışmada, Türkiye'deki her bir reçeteye düşen maliyet ortalamasını ARIMA (Oto-regresif Bütünleşik Hareketli Ortalama) modeli kullanarak tahmin etmiştir. Çalışmada, 2009 Ocak- 2013 Haziran dönemini içeren verilerle yapılmış olan tahminlerle, ileriki dönemlerin tahmininde en iyi sonuçları veren modelin ARIMA modeli olduğu belirtilmiştir.

Özüdoğru ve Görener (2015), tarafından yapılan bir çalışmada, İstanbul'daki bir hastaneden elde edilen veriler üzerinde farklı tahmin yöntemleri kullanılarak talep tahmini yapılması ve en az hata veren yöntemlerin belirlenmesi amaçlanmıştır. Minitab17 istatistik programı kullanılarak yapılan analizler sonucunda en doğru tahminlerin hangi yöntemlerle elde edildiği belirlenmiştir.

Ahn ve Yoo'nun (2015), makalesi, moda endüstrisinde renk trendlerinin tahmininde ARIMA modelinin kullanımını ele almaktadır. Bu çalışmada, Google Trend verileri kullanılarak ARIMA modeli oluşturulmuştur. Sonuçlar, ARIMA modelinin renk trendlerinin tahmininde etkili olduğunu ve sektördeki karar vericiler için yararlı bir araç olabileceğini göstermiştir. Almakrami ve Basir'in (2016), makalesi, elektrik talebi tahmininde ARIMA modelinin kullanımını araştırmaktadır. Çalışma, önceki talep verilerini kullanarak bir ARIMA modeli oluşturmuş ve gelecekteki talebi tahmin etmek için kullanmıştır. Sonuçlar, ARIMA modelinin elektrik talebi tahmininde etkili olduğunu ve elektrik sektöründe talep yönetimi için kullanılabileceğini göstermiştir.

Hazır ve arkadaşları (2016), ise Türkiye'deki mobilya satış değerlerinin tahmin edilmesi için yapay zeka yöntemi ve regresyon analizi tekniği kullanmışlardır. Yapılan analizler sonucunda yapay sinir ağlarının regresyon analizine göre daha doğru sonuçlar verdiği tespit edilmiştir.

Yiğit (2016), makalesi, Süleyman Demirel Üniversitesi Hastanesi'nin serum seti tüketiminin kantitatif tahmin yöntemleri ile analiz edilmesini ve en uygun tahmin modelinin belirlenerek gelecek dönemlere ait serum seti tüketiminin tahmin edilmesini amaçlamıştır. Çalışmada, talep tahmini yöntemlerinden hareketli ortalama, üstel düzeltme, Holt-Winters ve doğrusal regresyon tahmin yöntemleri kullanılarak serum seti tüketimi tahmin edilmiştir. Tahmin sonuçlarının doğruluğu değerlendirilirken ortalama mutlak hata yüzdesi (Mean Absolute Percent Error - MAPE) ve ortalama mutlak hata (Mean Absolute Deviation - MAD) metrikleri kullanılmıştır. Ayrıca çalışmada, serum seti tüketiminde en iyi tahmini sağlayan yöntemin belirlenmesi amacıyla yöntemler arası karşılaştırmalar yapılmıştır. Araştırma sonuçlarına göre, en düşük MAPE değeri 5 ve en düşük MAD değeri 971 ile Holt-Winters'ın toplamsal tahmin yönteminde elde edilmiştir.

Ali ve Abbas'ın (2017), makalesi, turizm endüstrisinde turist varışlarının tahmininde ARIMA modelinin kullanımını ele almaktadır. Bu çalışmada, ARIMA modeli ile yapay sinir ağı (ANN) modellerinin turist varışlarının tahmininde karşılaştırılması yapılmıştır. Sonuçlar, ARIMA modelinin ANN modellerine göre daha iyi sonuçlar verdiğini ve turizm endüstrisinde talep tahmini için etkili bir araç olduğunu göstermiştir.

Yücesan (2018), tarafından gerçekleştirilen bir çalışmada ise beyaz eşya sektöründe talep tahmini yapmak için Yapay Sinir Ağları (YSA), ARIMA ve ARIMAX yöntemleri kullanılmıştır. Yapılan karşılaştırmalar sonucunda en doğru sonuçların YSA yöntemi ile elde edildiği belirlenmiştir.

Nasuhoglu (2019), ise ilaç endüstrisinde yapay sinir ağları ve zaman serisi analizleri kullanarak talep tahmini yapmıştır. Yapılan analizler sonucunda çoğu üründe yapay sinir ağlarının daha doğru sonuçlar verdiği tespit edilmiştir. Ayrıca, tahmin sonuçları ile gerçek değerler arasındaki hata değerleri MSE yöntemi kullanılarak hesaplanmıştır.

Park ve Yeo'nun (2019), makalesi, talep tahmininde ARIMA modeli ile makine öğrenimi tekniklerinin birleştirilerek nasıl daha iyi sonuçlar verebileceğini ele almaktadır. Çalışma, ARIMA modeli ile yapay sinir ağı (ANN) ve destek vektör makineleri (SVM) gibi diğer makine öğrenimi tekniklerinin birleştirilerek bir hibrit model oluşturulmuştur. Sonuçlar, ARIMA modelinin bu tekniklerle birleştirildiğinde daha iyi sonuçlar verdiğini ve talep tahmininde etkili bir araç olduğunu göstermiştir.

Wang, Zhang ve Luo'nun (2020), makalesi, metro istasyonlarında kısa vadeli yolcu akışının tahmininde ARIMA modelinin kullanımını araştırmaktadır. Bu çalışmada, ARIMA modeli ile birlikte hibrit modelleme teknikleri de kullanılmıştır. Sonuçlar, ARIMA modelinin yolcu akışının tahmininde etkili olduğunu ve metro istasyonlarında talep yönetimi için kullanılabileceğini göstermiştir.

Dedeoğlu ve Çetin (2021), çalışmada, talep tahmini amacıyla hareketli ortalama, üstel düzgünleştirme, Holt yöntemi, trend analizi ve regresyon analizi yöntemleri kullanılmıştır. Beş farklı cerrahi bölümde ayaktan hasta sayısı, ameliyat sayısı ve yatılan gün sayısı tahminleri yapılmıştır. Ayaktan hasta tahmini için beş farklı yöntem ve üç hata parametresi

ile yapılan tahminler, MAPE, MAD ve MSE kriterleri ile değerlendirilmiştir. Regresyon analizi sonucunda ise iki departman için ayaktan hasta sayısının ameliyat sayısını etkilediği tespit edilmiştir.

Özkaya (2022), Porsuk Barajı'ndaki aylık akım verilerinin ARIMA modelleri kullanılarak tahmin edilebilirliğini araştırmaktadır. Barajın akım verilerinin doğru bir şekilde analiz edilmesi ve tahmin edilmesi, su kaynaklarının etkin yönetimi ve baraj operasyonlarının optimize edilmesi açısından büyük önem taşımaktadır. Tez, Porsuk Barajı'ndaki aylık akım verileri üzerinde ARIMA modeli uygulanarak doğruluk ve performans değerlendirmesi gerçekleştirmekte ve elde edilen sonuçlar ARIMA modelinin başarılı bir şekilde kullanılabileceğini göstermektedir. Bu çalışma, su kaynakları yönetimi ve benzer hidrolojik uygulamalar için pratik bir yaklaşım sunarak, su kaynaklarının daha iyi yönetilmesine ve baraj operasyonlarının verimliliğinin artırılmasına katkı sağlamayı amaçlamaktadır

Farklı sektörlerde gerçekleştirilen çeşitli araştırmalar, talep tahmininin karmaşıklığını ele almak ve etkili sonuçlar elde etmek amacıyla çeşitli analitik yöntemleri inceleme ve karşılaştırmayı hedeflendiğini; örneğin, perakende sektöründe yapılan bir çalışma, satış tahmini için Yapay Sinir Ağları (YSA) ve ARIMA modellerinin başarısını karşılaştırmış, YSA'nın doğrusal olmayan ilişkileri ve mevsimsel faktörleri tahmin etmedeki etkinliği vurgulanmıştır. Tıp alanında gerçekleştirilen bir diğer araştırma, hastane acil servislerinde günlük hasta sayısını tahmin etmek için zaman serisi analizi kullanmış ve en iyi tahmin modeli olarak çok değişkenli SARIMA modelini belirlemiştir. Turizm, enerji ve diğer sektörlerdeki çalışmalar da, ARIMA, YSA, Winter yöntemi gibi farklı analitik araçların talep tahmini konusunda ne kadar etkili olabileceğine dair farklı perspektifler sunmuştur. Bu çalışmalar, her sektörün özgünlüğüne bağlı olarak en iyi tahmin modelinin seçilmesinde rehberlik ederken, analitik yöntemlerin talep tahminindeki genel rolünü de vurgulamaktadır.

Yerli ve yabancı literatürün ayrıntılı bir analizi sonucunda, ilaç, turizm, sağlık gibi farklı sektörlerde talep tahmini yöntemleri ve bu yöntemlerin kullanım alanlarına dair çeşitli araştırmaların bulunduğu görülmüştür. Özellikle sağlık sektöründe, maliyet öngörüsünden hasta sayısı tahminine, vaka sayısı tahmininden cihaz sayısı tahminine kadar farklı alanlarda gelecek dönem tahminlerinde talep tahmini yöntemlerinin kullanıldığı belirlenmiştir. Bu çalışma ise Ağız ve Diş Sağlığı alanında hasta sayısı talep tahminlerini ARIMA modeliyle

gerçekleştirerek, doğru bir şekilde talebi belirlemeyi ve hastane yöneticilerine gerekli iyileştirmeleri yapabilme amacıyla kapasite planlaması yapmayı hedeflemektedir. Kapasite planlaması, idari sorunları çözmeye yardımcı olan bir alan olup, literatürde dış hastanelerinin hasta sayısı tahminlerini kantitatif ve analitik yöntemlerle planladığına dair bir çalışma bulunmamaktadır. Bu çalışma, dış sağlığı alanındaki hasta talebinin tahminini ele alarak literatüre değerli bir katkı sunmayı amaçlamaktadır.

4. MATERİYAL VE YÖNTEM

4.1. Materyal

Bu çalışmada, Bingöl ilindeki Bingöl Ağız ve Diş Sağlığı Merkezine gelen hasta sayılarının zaman serisi analizi yapıp, gelecekteki hasta sayılarının tahmin edilmesi amaçlanmaktadır. Analiz için Minitab programı kullanılmakta ve ikincil verilerden yararlanılmaktadır.

Bu çalışma, Ocak 2016 - Aralık 2021 tarihleri arasında toplanan hasta sayısı verilerini kullanarak, Ocak-Aralık 2022 ve önceki yıllar için hasta sayısı tahminlerini yapmayı amaçlamaktadır. Bu veriler zaman serisi analizi için kullanılmakta olup, analizin temel adımları veri toplama, zaman serisi modeli seçimi, veri ayrıştırma, model parametrelerinin ayarlanması, tahminlerin gerçek verilerle karşılaştırılması ve sonuçların sunulması şeklinde sıralanmaktadır. Bu çalışmanın sonuçları, sağlık hizmetlerinin planlanması ve kaynak tahsisinin daha etkili bir şekilde yapılması için önemli bir bilgi kaynağı olmaktadır.

Zaman serisi analizi, geçmiş verilere dayalı olarak gelecekteki eğilimleri ve desenleri tahmin etmek için kullanılan bir yöntemdir. Bu analizde, hastane ziyaretlerindeki mevsimsel veya trendsel değişiklikler, özel günlerin etkisi gibi faktörler göz önünde bulundurulmaktadır.

Minitab programı, istatistiksel analizlerin gerçekleştirildiği bir yazılımdır. Bu programın zaman serisi analizi araçları, verileri grafiklerle görselleştirebilme, trendleri ve desenleri belirleyebilme, tahmin modelleri oluşturma gibi işlemleri kolaylaştırmaktadır.

4.2. Yöntem

Çalışmada Bingöl ilinde yer alan Bingöl Ağız ve Diş Sağlığı Hastanesinin Ocak 2016 - Aralık 2021 yılları arasındaki verileri kurumdan alınmıştır. Kurumdan alınan geçmiş yılların verilerine dayanılarak gelecek 1 yıl (Ocak- Aralık 2022) tahmin edilmiştir. Model Minitab 21 paket programı kullanılarak analiz edilmiştir. Minitab 21 programı istatistiksel anlamda güçlü analiz yapan programlardan biri olarak değerlendirilmektedir. İstatistiksel analiz ve işlemlerin ileriye dönük karar süreçlerini etkileyecek tahminlerde bulunmak amacı ile

geliştirilmiş olduğundan dolayı çalışmamızda Minitab 21 programı kullanılarak analizler yapılmaktadır.

ARIMA modellerinin doğruluğunu değerlendirmek için genellikle bazı istatistiksel ölçütlere bakılır. İşte ARIMA modellerinin doğruluğunu değerlendirmek için kullanılan bazı ölçütler (Çuhadar vd., 2009).

-Akaike Bilgi Kriteri (AIC): Bu kriter, bir modelin uygunluğunu ölçmek için kullanılan bir istatistiksel ölçüttür. AIC değeri, modelin karmaşıklığına ve veriye ne kadar iyi uyduğuna bağlıdır. Daha düşük AIC değeri, daha iyi bir model uyumu gösterir.

-Bayes Bilgi Kriteri (BIC): Bu kriter, AIC'ye benzer bir şekilde çalışır, ancak daha az karmaşık modelleri ödüllendirir. BIC değeri de AIC gibi daha düşük olmalıdır.

-Kök Ortalama Kare Hata (RMSE): Bu ölçüt, modelin tahminlerinin gerçek değerlerden ne kadar uzak olduğunu ölçer. Daha düşük RMSE değeri, daha iyi bir model performansı gösterir.

-R-kare (R^2): Bu ölçüt, modelin ne kadar varyansı açıkladığını ölçer. R^2 değeri, 0 ile 1 arasında değişir ve daha yüksek bir değer daha iyi bir model performansı gösterir.

-Ortalama Mutlak Hata (MAE): Bu ölçüt, MAE, bir tahmin modelinin gerçek değerlerle ne kadar uyumlu olduğunu ölçmek için kullanılır. Tahmin edilen değerler ile gerçek değerler arasındaki farkın mutlak değerlerinin ortalaması olarak hesaplanır. Bu, modelin tahminlerinin gerçek değerlere ne kadar yakın olduğunu değerlendirmek için kullanışlı bir ölçüttür.

- χ^2 (Ki-Kare) Ölçütü: χ^2 ölçütü, genellikle kategorik verilerin uyumunu test etmek veya gözlenen frekanslar ile beklenen frekanslar arasındaki farklılığı incelemek için kullanılır. Bir tahmin modelinin gerçek verilere ne kadar iyi uyduğunu değerlendirmek için χ^2 ölçütü kullanılabilir.

Bu çalışmada, seçilen modelin performansını değerlendirmek için χ^2 (Ki-Kare) ölçütü kullanılarak modelin gözlenen verilere ne kadar iyi uyduğu test edilecektir. Aynı zamanda, modelin tahmin ettiği değerlerin doğruluğunu ölçmek için Ortalama Mutlak Hata (MAE) ölçütü kullanılacaktır. Bu yaklaşım, hem modelin uyum yeteneğini hem de tahmin doğruluğunu aynı anda değerlendirerek, analizin kapsamlı bir sonuca ulaşmasını sağlayacaktır.

4. 3. Talep Tahmini Uygulaması

4.3.1. Problemin Tanımı

Temel bir insan hakkı olan sağlık hizmetinden her bireyin adil ve etkili bir şekilde yararlanabilmesi, belirsizlik ve değişen koşullar altında bile, karar vericilerin objektif ve güvenilir kararlar alabilmesini gerektirir. Aynı zamanda, sağlık kaynaklarının etkin ve verimli bir şekilde kullanılması, gereksiz israfın önlenmesi amacıyla sezgisel yaklaşımlar yerine bilimsel tekniklerin tercih edilmesi, daha güvenilir verilere ulaşma açısından büyük bir başarı olarak değerlendirilmektedir. Ağız ve Diş Sağlığı Merkeziyle alakalı bir araştırma da muhtemel sorunlardan bir kaçış aşağıda yer almaktadır.

Sağlık personeli sayısı: Bir hastanede uygun hizmetin sağlanabilmesi için doğru sayıda personele ihtiyaç vardır. Hastane, mevcut hasta yoğunluğu, poliklinik sayısı, yatan hasta sayısı ve uzmanlık alanları gibi faktörleri göz önünde bulundurarak sağlık personeli sayısını belirlemelidir. İdeal olarak, hastaların uygun zaman aralıklarında muayene olabilmesi ve tedavi alabilmesi için yeterli sayıda sağlık personelinin bulunması gerekmektedir.

Malzeme İhtiyaçları: Hastanelerde, tıbbi malzemelerin yeterli ve doğru miktarda temin edilmesi önemlidir. Bu malzemeler, cerrahi aletler, ilaçlar, laboratuvar malzemeleri gibi çeşitli ürünleri kapsar. Hastanenin hasta yoğunluğuna, uzmanlık alanlarına ve hizmet verdiği branşlara bağlı olarak malzeme ihtiyaçları belirlenmelidir. Malzeme envanterinin doğru şekilde yönetilmesi ve talep tahminlerinin yapılması, hastane operasyonlarının verimli ve kesintisiz şekilde devam etmesini sağlar.

İzinleri: Sağlık personelinin izinlerinin düzenlenmesi, hastane yönetimi açısından önemli bir konudur. Personelin dinlenmeye ve tatil yapmaya ihtiyacı vardır, ancak izinlerin düzenlenmesi hastanenin hizmet kalitesi ve sürekliliği için dikkate alınmalıdır. Hasta yoğunluğu, poliklinik programları, ameliyat takvimi ve uzmanlık alanları gibi faktörler göz önünde bulundurularak izinlerin planlanması gerekmektedir. Böylece, hastane hizmetlerinin aksamadan sürdürülmesi ve hastaların tedavi süreçlerinin aksatılmaması sağlanır.

Bu konular hastanelerdeki etkin bir işleyişin sağlanması ve hizmet kalitesinin yükseltilmesi açısından önemlidir. Doğru sağlık personeli sayısı, uygun malzeme ihtiyaçları ve personelin izinlerinin düzenlenmesi, hastane yönetimi tarafından planlanmalı ve sürekli olarak gözden geçirilmelidir. Bu şekilde hastaneler, sağlık hizmetlerini etkili bir şekilde sunabilir ve hastaların ihtiyaçlarını karşılayabilir. Ortaya konulan problemin çözüme ulaşabilmesi için de hastaneye gelmesi muhtemel hasta sayılarının doğru bir şekilde talep tahmini yapılması gerekmektedir.

4.3.2. Çalışmanın Amacı

Bingöl ilinde yer alan Bingöl Ağız ve Diş Sağlığı Merkezinin hasta gereksinimlerini karşılayacak şekilde planlanması, kaynakların etkin yönetimi, kaliteli sağlık hizmeti sunumu ve hasta memnuniyeti üzerinde doğrudan etkisi olan kritik bir konudur. Bu çalışma, tüm bu unsurların başarısını şekillendirebilecek etkili bir yaklaşımı temsil ederken, kaynakların verimli ve etkili bir şekilde kullanılmasını sağlayacaktır. Bu bağlamda, Bingöl ilinde yer alan Bingöl Ağız ve Diş Sağlığı Merkezine Ocak 2016 - Aralık 2021 yılları arasında 72 aylık zaman diliminde hasta başvurularının kantitatif tahmin yöntemleriyle analiz edilmesi ve en uygun tahmin modelinin belirlenmesi, gelecek dönemler için hasta sayısı tahminlerinin yapılması amaçlanmaktadır.

4.3.3. Çalışmanın Önemi

Bingöl Ağız ve Diş Sağlığı Merkezinin, yaptığımız tahminlerin temel amacı, ağız ve diş sağlığının yaşam kalitesi üzerindeki büyük etkisini vurgulamaktır. Diş sağlığı problemleri, sadece ağız sağlığını değil, aynı zamanda genel sağlığı da olumsuz yönde etkileyebilir. Sağlıklı bir ağız ve diş yapısı; beslenme, konuşma ve sosyal etkileşim gibi hayati

fonksiyonların düzgün şekilde yerine getirilmesine katkı sağlar. Bu nedenle, ağız ve diş sağlığının genel yaşam kalitesi üzerindeki önemini göz önünde bulundurarak, etkili bir kapasite planlaması stratejisinin yapılabilmesi için, hastalara her zaman en iyi sağlık hizmetini sunabilmek ve ağız sağlığının genel sağlıkla olan ayrılmaz ilişkisine dikkat çekmektir.

Bu analizler sayesinde, geçmiş verilere dayanarak hasta yoğunluğunun mevsimsel veya dönemsel olarak nasıl değiştiği belirlenebilir. Örneğin, bazı bölümlerde yaz aylarında yoğunluk artarken, kış aylarında azalabilir. Bu bilgiler, o bölümdeki doktor sayısının ve malzeme tedarikinin bu değişkenlere göre planlanmasını sağlar.

Zaman serileri analizleri aynı zamanda gelecekteki taleplerin tahmin edilmesinde de yardımcı olur. Geçmiş verilere dayanarak yapılan tahminler, bölümün veya hastanenin gelecekteki hasta yoğunluğunu öngörmesine ve buna göre kaynakları planlamasına yardımcı olur. Bu sayede, talebi karşılamak için gereksiz stok maliyetlerinden kaçınılır ve kaynakların etkin kullanımı sağlanır.

Bu nedenle, sağlık sektöründe malzeme ve ekipman yönetimi stratejik bir öneme sahiptir. Doğru stok seviyesini belirlemek, talep tahminlerine dayanarak malzemeleri zamanında temin etmek ve gereksiz stok maliyetlerini en aza indirmek önemlidir. Bunun için sağlık kuruluşları, talep analizleri ve zaman serileri analizlerinden yararlanarak malzeme ihtiyaçlarını doğru bir şekilde planlamalı ve tedarik süreçlerini etkin bir şekilde yönetmelidir. Ayrıca, malzeme ve ekipman yönetimi yanında, bakım ve onarım süreçleri de önemlidir. Ekipmanların düzenli bakımının yapılması, arızaların önlenmesi ve süreçlerin kesintisiz devam etmesi için kritiktir.


Sonuç olarak, zaman serileri analizleri ticari ve sağlık sektöründe daha kaliteli hizmet sunmak için önemli bir araçtır. Bu analizler, bölümlerin ve hastanelerin taleplere uygun şekilde sağlık personeli sayısını belirlemesine, malzeme teminini planlamasına ve kaynakları verimli bir şekilde kullanmasına yardımcı olur. Böylece, hem hasta memnuniyeti artar hem de hastane süreçleri optimize edilir. Ayrıca, sağlık sektöründe malzeme ve ekipman yönetimi, etkili bir sağlık hizmeti sunabilmek için büyük bir öneme sahiptir. Doğru stok

seviyeleri, zamanında tedarik ve düzenli bakım süreçleri, hastanelerin verimliliğini artırır, maliyetleri kontrol altında tutar ve kaliteli sağlık hizmeti sunumuna katkı sağlar.

Bu çalışma ise Ağız ve Diş Sağlığı alanında hasta sayısı talep tahminlerini ARIMA modeliyle gerçekleştirerek, doğru bir şekilde talebi belirlemeyi ve hastane yöneticilerine gerekli iyileştirmeleri yapabilme amacıyla kapasite planlaması yapmayı hedeflemektedir. Kapasite planlaması, idari sorunları çözmeye yardımcı olan bir alan olup, literatürde diş hastanelerinin hasta sayısı tahminlerini kantitatif ve analitik yöntemlerle planladığına dair bir çalışma bulunmaktadır. Bu çalışma, diş sağlığı alanındaki hasta talebinin tahminini ele alarak literatüre değerli bir katkı sunmayı amaçlamaktadır.

5. BULGULAR


Verilerin analizi için Minitab 21 programından faydalanılmıştır. Programa veri dosyasının aktarımı iki şekilde gerçekleşmektedir. İlk yöntemde hasta sayıları veri dosyasından kopyalanarak yapıştırılmakta iken ikinci yöntemde File>Open>Dosya seçenekleri takip edilerek kargo sayılarının ve tarihlerinin bulunduğu sütunlar seçilerek veri seti programa eklenmektedir. Veriler programa eklendikten sonra ilk olarak verilerin grafiğini oluşturarak verinin nasıl bir veri olduğu analiz edilmesi gerekmektedir. Grafiği ekrana çizdirmek için Şekil 4.1’de görüldüğü gibi Graph > Times Series Plot >Simple ve Time/Scale seçeneklerini tıklayarak, Şekil 4.1’ de görünen ayarları yaparak Şekil 4.2’ de yer alan grafik çizdirilmektedir.



Şekil 4.1. Grafik Çizdirme Ekranı


Şekil 4.2'yi incelediğinde, herhangi bir trend veya mevsimsellik belirtisi gözlemlenmemektedir. Yani, verilerin genel eğilimi açısından bir artış veya azalış gözlenmemekte ve yılın belirli dönemlerinde belirgin bir artış veya azalış paterni tespit edilmemektedir.

Bu durumda, verilerin zaman içinde sabit veya neredeyse sabit bir düzende olduğu söylenebilir. Hasta sayılarında belirli bir artış veya azalış trendi olmaması, hasta yoğunluğunun yıl boyunca nispeten sabit olduğunu göstermektedir. Örneğin, belirli bir mevsime veya döneme bağlı olarak yoğunlukta artış veya azalış olmaması, Bingöl Ağız ve Diş Sağlığı Merkezi'nde hastaların yıl boyunca hemen hemen aynı düzeyde olduğu söylenebilir. Artan bir eğri veya yılın belli dönemlerinde yer alan artış ya da azalışlar saptanmamıştır.




Şekil 4.2. Hasta Sayılarının Aylara Göre Dağılımı

Model oluşturulmadan önce ACF grafiğinden ve Box- Pierce tarafından geliştirilen Box – Pierce Q istatistiğinden de faydalanılarak serinin durağan olup olmadığı kontrol edilir. Grafiği çizdirdikten sonra durağanlığını test etmek için ACF(Autocorrelation Function) ve PACF(Partial Autocorrelation Function) grafiklerinin çizdirilmesi gerekmektedir. Stad > Time Series > Autocorrelation sekmelerini seçerek Hasta sayısının bulunduğu sekmeyi seçerek Şekil 4.3'te yer alan ayarlamalar yapılarak ACF grafiği için süreç tamamlanmaktadır.



: ACF grafiğinin ve LBQ istatistiği sonuçlarının yazdırılması

Şekil 4.3. ACF Grafiği Ekran Ayarı



Şekil 4.4. Hasta Sayısı İçin ACF Grafiği

Şekil 4.3 ile yapılan ayarlardan sonra ekrana Şekil 4.4 yazdırılan oto korelasyon grafiğinde 1 tane gecikmenin anlamlı olduğu görülmektedir. Q istatistiği, zaman serisi verilerinde otokorelasyonun varlığını test etmek için kullanılan bir istatistiksel testtir. Bu test, m adet otokorelasyon katsayısı üzerinde χ^2 (Ki-Kare) dağılımına uygunluğunu kontrol eder. Bu test zaman serileri analizinde kullanılan en yaygın testlerdendir. Q istatistiği, analiz edilen verinin parametre tahmini yapılarak hata payları elde edildikten sonra bu hata paylarının yeterli olup olmadığının araştırılmasını sağlayan bir testtir (Hanedar, Akkaya, Bizim, 2020). Oto korelasyon fonksiyonunun t-istatistiği ve Ljung-Box Q istatistiği incelemek için Tablo 4.1 değerler yer almaktadır.

Tablo 4.1. LBQ (Ljung-Box Q) Değerleri


Gecikme	ACF	T-İstatistiği	LBQ
1	0,586333	4,98	25,80
2	0,321691	2,10	33,68
3	0,201902	1,24	36,82
4	0,130905	0,79	38,17
5	0,036253	0,22	38,27
6	-0,011409	-0,07	38,28
7	-0,068571	-0,41	38,67
8	0,019966	0,12	38,70
9	-0,013008	-0,08	38,71
10	-0,034387	-0,21	38,82
11	0,027457	0,16	38,88
12	0,091819	0,55	39,63
13	-0,105220	-0,62	40,63
14	-0,132916	-0,78	42,25
15	-0,143747	-0,84	44,18
16	-0,165756	-0,96	46,80
17	-0,238783	-1,37	52,32
18	-0,293557	-1,64	60,82

Hipotezi (H0): Zaman serisi verilerindeki Q (LBQ) > χ^2 (%95) Tablo değeri ise otokorelasyonlar istatistiksel olarak anlamlı değildir ve rastgeledir.

Alternatif Hipotez (H1): Zaman serisi verilerinde en az biri Q (LBQ) < χ^2 (%95) ise otokorelasyon istatistiksel olarak anlamlıdır.


Tablo 4.1’de hesaplanan Q değerleri, χ^2 tablosu değerleriyle kıyaslanarak tablodaki değerlerden büyük olup olmadığına bakıldığında 18 serbestlik derecesinde Q değerleri= 60,82 , χ^2 (% 95) tablo değerinde $\chi^2= 28,869$ ’dan büyük olduğu için Hipotez (H0) kabul edildiği için serinin rassal olmadığı ve uygun limitler arasında yer almayan serinin durağan olmadığı anlaşılmaktadır.

ACF grafiği ve Q istatistiği incelediğinde serinin durağan olmadığı gözlemlendikten sonra serinin durağanlığını sağlamak için ARIMA modeli kullanılarak analizi yapılan zaman serisinde fark alma işlemiyle durağan hale getirilmektedir. Fark alma işlemi ‘d ‘ ile sembolize edilmektedir. Serinin 1. farkını alıp ACF grafiği ve Q istatistiğini kontrol etmek için Stad > Time Series > Diffirences seçeneklerini seçerek fark alma işlemi gerçekleştirilir.



Şekil 4.5. Hasta Sayısı İçin Fark aldırma

Fark aldırma işleminde 2. Değerden 1. Değer çıkartılarak Fark sütunda 2. Değer olarak yazdırılarak yeni veri setini oluşturulmaktadır. Şekil 4.5 İle fark sütunu üzerinden ACF grafiği çizdirilerek Şekil 4.6 'nın Ljung-Box Q ve T- istatistiği değerleri Tablo 4.2'de yazdırılmıştır.



Şekil 4.6. 1.Fark alma işleminden sonra ACF Grafiği

Şekil 4.6 incelendiğinde serinin 1. Farkının oto korelasyonunun 1 adet gecikmesinin anlamlı olduğu gözlemleniyor. Tablo 4.2'de hesaplanan Q değerleri, χ^2 tablosu değerleriyle kıyaslanarak tablodaki değerlerden büyük olup olmadığına bakıldığında 18 serbestlik derecesinde Q değerleri= 22,75 , χ^2 (% 95) tablo değerinde $\chi^2= 28,869$ 'dan küçük olduğu için Hipotez (H0) red edilip Hipotez (H1) kabul edilir. Otokorelasyon istatistiksel olarak



anlamlıdır. Serinin rassal olduğu ve uygun limitler arasında değer aldığından serinin durağan olduğu anlaşılmaktadır.

Tablo 4.2. 1. Fark Alma İşleminden Sonra LBQ (Ljung-Box Q) Değerleri

Gecikme	ACF	T-İstatistiği	LBQ
1	-0,176785	-1,49	2,31
2	-0,164149	-1,34	4,34
3	-0,066420	-0,53	4,67
4	0,044765	0,36	4,83
5	-0,069981	-0,55	5,21
6	0,003191	0,03	5,21
7	-0,141015	-1,11	6,83
8	0,118756	0,92	7,99
9	-0,024994	-0,19	8,04
10	-0,088719	-0,68	8,71
11	0,025580	0,19	8,76
12	0,326034	2,48	18,10
13	-0,212664	-1,49	22,14
14	-0,006127	-0,04	22,15
15	0,016165	0,11	22,17
16	0,047953	0,33	22,39
17	-0,054638	-0,37	22,67
18	-0,027150	-0,18	22,75



Verinin durağanlığını sağladıktan sonra hangi modelinin kullanılacağına karar verilmesi gerekmektedir. Bunun için PACF grafiğini 1. Fark alma işleminden sonra Şekil 4.7’de görüldüğü gibi çizdiriliyor. Modelde ARIMA(p,d,q) yani (p) AR modellerinin belirlenebilmesi için kısmi otokorelasyon grafikleri değerlendirilir. Serinin PACF grafiğine Şekil 4.7’ye bakıldığında; kısmi otokorelasyon grafiğinin anlamlılık sınırını aşan gecikme değerleri dikkate alınabilir. (q) MA modellerinin belirlenmesinde, Şekil 4.6’ da bulunan otokorelasyon grafikleri değerlendirilerek % 5 anlamlılık sınırını aşan gecikmeler dikkate alınarak model parametreleri tahmin edilebilir. Şekil 4.6’da bulunan ACF grafiği ve Şekil 4.7’de bulunan PACF grafikleri incelediğinde iki grafikte de 1 gecikmenin anlamlı olduğu gözlemlenmektedir. Model olarak ARIMA(1,1,1), şeklinde olduğuna karar veriliyor. Ancak seçilen modelin karşılaştırmasını yapabilmek için ACF ve PACF grafiklerinde anlamlı olan gecikme değerlerine dayanarak modeli genişletip diğer olasılıkları da değerlendirilmesi

gerektiğinden ARIMA(0,1,0), ARIMA(1,1,0) ve ARIMA(0,1,1) modellerinin de değerlerini bakılarak sonucun doğruluğunu kontrol edilir.



Şekil 4.7.1.Fark alma işleminden sonra PACF grafiği ve ekrana yazdırılması

ARIMA(1,1,1) modelinin değerini ekrana getirebilmek için Şekil 4.8’de gösterilen adımlar çalışma kapsamında takip edilmiştir.



Şekil 4.8 ARIMA(1,1,1) Modelinin Çizdirilmesi

Tablo 4.3. ARIMA(1,1,1) modelinin geçerlilik değerleri

Model Tipi	Katsayı	Katsayının Standart hatası	T-Değeri	P-Değeri
AR 1	0,624	0,108	5,78	0,000
MA 1	0,9899	0,0363	27,30	0,000
Normallik	1,73	7,14	0,24	0,809

Toplam Serbestlik Derecesi	Düzeltilmiş Kareler Toplamı	Düzeltilmiş Ortalama Kareler
68	184324684	2710657

Tablo 4.3. ARIMA(1,1,1) modelinin performansını değerlendirmek ve modelin güvenilirliği hakkında bilgi sağlamak için kullanılan değerler yer almaktadır. Modelde kullanılan otoregresif (AR) ve hareketli ortalama (MA) katsayıları, geçmiş değerler ve hata terimlerinin gelecekteki değerleri tahmin etmek için nasıl kullanıldığını gösterir. Bu bağlamda, AR(1) katsayısı 0.624 olarak tahmin edilmiş ve standart hatası 0.108'dir. MA(1) katsayısı ise 0.9899 olarak tahmin edilmiş ve standart hatası 0.0363'tür. Bu katsayılar, modelin hangi önceki değerleri veya hataları temel alarak tahminlerde bulunduğunu belirtir.

T-değerleri, katsayıların sıfır olma hipotezine karşı ne kadar güçlü bir şekilde test edildiğini ifade eder. Hem AR(1) hem de MA(1) katsayılarının T-değerleri oldukça yüksektir (5.78 ve 27.30), bu da bu katsayıların istatistiksel olarak anlamlı olduğunu gösterir. P-değerleri ise T-testinin istatistiksel anlamlılığını belirler. Her iki katsayı için de P-değerleri oldukça düşüktür (0.000), bu da katsayı tahminlerinin istatistiksel olarak anlamlı olduğunu gösterir.

Normallik testi, modelin hata terimlerinin normal dağılıma uygun olup olmadığını kontrol eder. Buradaki normallik testi sonuçlarına göre hata terimlerinin normal dağılıma uygun olduğu görülmektedir (normallik testi için P-değeri 0.809).

Toplam serbestlik derecesi, veri noktalarının toplam sayısını ifade ederken, düzeltilmiş kareler toplamı modelin ne kadar iyi veriyi açıkladığını yansıtır. Bu değer, veri noktalarının özetlenmiş bir değeridir ve modelin ne kadar iyi uyarlandığını gösterir. Düzeltilmiş ortalama kareler ise modelin tahminlerinin gerçek değerlere ne kadar yakın olduğunu ölçer. Bu bağlamda, veri setinin düzeltilmiş kareler toplamı 184324684, toplam serbestlik derecesi 68 ve dolayısıyla düzeltilmiş ortalama kareler 2710657 olarak hesaplanmıştır. Bu değerler, modelin veriyi ne kadar iyi açıkladığını ve tahminlerin gerçek değerlere ne kadar yakın olduğunu yansıtmaktadır.

Tablo 4.4 ARIMA(1,1,0) modelinin geçerlilik değerleri


Model Tipi	Katsayı	Katsayının Standart hatası	T-Değeri	P-Değeri	Toplam Serbestlik Derecesi	Düzeltilmiş Kareler Toplamı	Düzeltilmiş Ortalama Kareler
AR 1	-0,178	0,119	-1,50	0,139	69	219339613	3178835
Normallik	48	212	0,23	0,822			

Tablo 4.4'te verilen istatistiksel sonuçlara göre, AR(1) modelindeki otoregresif (AR) katsayısı -0.178 olarak tahmin edilmiştir. Ancak, bu katsayının T-değeri -1.50 ve P-değeri 0.139 olduğundan, istatistiksel olarak anlamlı olmadığı söylenebilir. Normallik testi sonucunda, hata terimlerinin normal dağılıma uygun olduğu kabul edilebilir, çünkü normallik testinin P-değeri 0.822 olarak hesaplanmıştır. Toplam serbestlik derecesi 69 ve düzeltilmiş kareler toplamı 219339613 olarak bulunmuştur, bu da modelin genel uyarlamasını yansıtmaktadır. Ayrıca, düzeltilmiş ortalama kareler değeri 3178835, yani modelin tahminlerinin gerçek değerlere yakınlığını göstermektedir. Bu sonuçlara dayanarak, AR(1) modelinin belirli bir zaman serisi veri setini doğru bir şekilde açıklamada sınırlı başarı gösterdiği ve katsayıların istatistiksel olarak anlamlı olmadığı sonucuna varılmaktadır.

Tablo 4.5 ARIMA(0,1,1) modelinin geçerlilik değerleri

Model Tipi	Katsayı	Katsayının Standart hatası	T-Değeri	P-Değeri	Toplam Serbestlik Derecesi	Düzeltilmiş Kareler Toplamı	Düzeltilmiş Ortalama Kareler
MA 1	0,323	0,114	2,82	0,006	69	213961660	3100894
Normallik	35	142	0,25	0,806			

Tablo 4.5'te istatistiksel sonuçlara göre, MA(1) modelindeki hareketli ortalama (MA) katsayısı 0.323 olarak tahmin edilmiştir. Bu katsayının T-değeri 2.82 ve P-değeri 0.006 olduğundan, istatistiksel olarak anlamlı olduğu söylenebilir ve modeldeki hareketli ortalamanın bir etkisi olduğu düşünülebilir. Normallik testi sonucuna göre, modelin hata terimlerinin normal dağılıma uygun olduğu kabul edilebilir, çünkü normallik testinin P-değeri 0.806 olarak hesaplanmıştır. Toplam serbestlik derecesi 69 ve düzeltilmiş kareler toplamı 213961660 olarak bulunmuştur, bu da modelin genel uyarlamasını yansıtmaktadır. Ayrıca, düzeltilmiş ortalama kareler değeri 3100894, yani modelin tahminlerinin gerçek değerlere yakınlığını göstermektedir. Bu sonuçlara dayanarak, MA(1) modelinin zaman serisi veri setini daha iyi açıklamada ve tahmin etmede bir etkisi olduğu sonucuna varılabilir.



Şekil 4.9 ARIMA(0,1,0) Modelinin Çizdirilmesi

Şekil 4.9’da yer alan modelde ARIMA(0,1,0)’in değeri ekrana yazdırmak istenildiğinde Ekranda * ERROR * Model contains no autoregressive or moving average term(* HATA * Model, otoregresif veya hareketli ortalama terimi içermiyor) mesajı yazdırıldı.


Bunun için ARIMA(0,1,0) modelini değerlendirmeye alınmıyor. Seçilen modellerin geçerli olabilmesi için “p” değerinin 0,05’ten küçük olması ve MS(Düzeltilmiş Ortalama Kareler) değerinin “p” değeri 0,05’ten küçük olan değerlerde en küçük MS değerine sahip olması gerekmektedir. Yukarıda yer alan Tablo 4.3, Tablo 4.4 ve Tablo 4.5’te ki tüm ARIMA modellerinin anlamlılıklarını inceledikten sonra ARIMA(1,1,1) modelinin en iyi model olduğuna karar verilmektedir. Ayrıca model uygunluğunun genel kontrolü için Ljung-Box istatistiği dikkate alınarak Ki-Kare testi ile kontrol edilmiştir. Testin istatistik sonuçları aşağıda Tablo 4.6’da verilmiştir.

Tablo 4.6 ARIMA(1,1,1) modelinin istatistik test sonucu

Gecikme	12	24	36	48
Ki-Kare	9,60	30,92	45,14	52,00
Toplam Serbestlik Derecesi	9	21	33	45

Seçilen modelin, yukarıda verilen istatistik sonuçları χ^2 tablosuna uygunluğu incelendiğinde kabul edilebilir nitelikte olduğu ve modelin zaman seri analizi için uygun olduğu anlaşılmaktadır.

ARIMA (1,1,1) tahmin ve kalıntı grafiklerine ve gelecek tahmin grafikleri, Şekil 4.10’a bakıldığında serimizin gelecek 12 ay için de izleyeceği muhtemel değerlerin grafiği gösterilmektedir. Şekil 4.10’da bulunan ACF (Otomatik Korelasyon Fonksiyonu) ve PACF (Kısmi Otomatik Korelasyon Fonksiyonu) grafikleri incelendiğinde, herhangi bir kalıntının varlığı gözlemlenmemiştir. Bu durum, seçilen modelin uygunluk açısından doğru olduğunu göstermektedir (Box Jenkins ve Reinsel, 2015).




Şekil 4.10. ARIMA(1,1,1) Modeli için Gelecek Tahmin grafiği


ACF grafiği, bir zaman serisinin otomatik korelasyonunu gösterir. Yani, bir gözlem değerinin geçmişteki gözlem değerleriyle ne kadar ilişkili olduğunu gösterir. Eğer ACF grafiğinde herhangi bir otokorelasyon paterni belirgin değilse, yani çizgiler istatistiksel olarak anlamlı bir şekilde ötesine geçmiyorsa, bu durumda zaman serisindeki gözlemler arasında belirgin bir kalıntı veya otokorelasyon olmadığı anlaşılır.

PACF grafiği ise, bir zaman serisinin kısmi otomatik korelasyonunu gösterir. Kısmi otomatik korelasyon, bir gözlem değerinin geçmişteki gözlem değerleriyle ilişkisini kontrol ederken aradaki diğer gözlem değerlerinin etkisini kontrol etmeyi sağlar. Eğer PACF grafiğinde belirgin bir düşüş ve sifıra yakınsayan değerler gözleniyorsa, bu da zaman serisindeki kalıntının düzgün bir şekilde kontrol edildiğini ve seçilen modelin uygun olduğunu gösterir.

Dolayısıyla, Şekil 4.11'de ACF ve PACF grafiklerinde herhangi bir belirgin otokorelasyon veya kısmi otokorelasyon olmadığı gözlemlenmiştir. Bu durumda, seçilen modelin zaman serisi verilerine uygun olduğu ve kalıntıların düzgün bir şekilde kontrol edildiği gözlemlenmektedir(Box Jenkins ve Reinsel, 2015).



Şekil 4.11. ARIMA(1,1,1) Modeli için ACF ve PACF kalıntı grafiği



Şekil 4.12. ARIMA(1,1,1) Modeli için kalıntı grafiği

Artıkların normal dağıldığı varsayımını doğrulamak için artıkların normal olasılık grafiğini kullanılmalıdır. Artıkların normal olasılık grafiği, yaklaşık olarak düz bir çizgi izlemelidir. Bu uygulamada çizilen grafikte başta ve sonda birer kopma oluşmuş fakat diğer noktada düz çizgi çizmiştir (Şekil 4.12). “versus fits(Karşıt Uyum)” grafiği, artıkların rastgele dağıtıldığı ve sabit bir varyansa sahip olup olmadığı varsayımını doğrulamak için kullanılır. “versus order (Düzene Karşıtlık)” grafiği artıkların birbirinden bağımsız olduklarını kanıtlamak için

kullanılır. İdeal olarak, grafik üzerindeki artık değerler merkez çizginin etrafına rasgele dağılmalıdır (Sezer, vd., 2019). Bu açıklamalar gösteriyor ki seçilmiş model hem değerleriyle hem de artık grafikleriyle uygun bir modeldir.

Tablo 4.7. ARIMA(1,1,1) Modeline Göre Gelecek Dönemlerin Tahmin Tablosu

Tarih	Tahmin	95% Limit	
		En Düşük	En yüksek
2022-01	9386,42	6158,81	12614,0
2022-02	8926,50	5104,25	12748,7
2022-03	8641,15	4600,38	12681,9
2022-04	8464,76	4335,36	12594,2
2022-05	8356,39	4188,66	12524,1
2022-06	8290,48	4105,03	12475,9
2022-07	8251,07	4056,73	12445,4
2022-08	8228,20	4028,95	12427,5
2022-09	8215,67	4013,39	12417,9
2022-10	8209,57	4005,21	12413,9
2022-11	8207,50	4001,56	12413,4
2022-12	8207,95	4000,70	12415,2

ARIMA(1,1,1) modelini kullanarak tahminler gerçekleştirilmiş ve Tablo 4.7 de serinin gelecek 12 aya ait tahminler sunulmuştur. Tablo 4.7 ve Ek-2’de yer alan veriler karşılaştırıldığında 2021 yılında gelen hasta sayısına göre 2022 yılında %15’lik bir artış olacağını ortaya koymuştur.

Tablo 4.8. ARIMA(1,1,1) Modeline Göre Eldeki Verileri Kullanarak 6. Yıl Tahmin Tablosu

Tarih	Gerçek Değer	Tahmin	En Düşük	En yüksek
2021-01	4873	5977,68	2697,48	9257,9
2021-02	7871	6518,73	2596,76	10440,7
2021-03	9047	6860,03	2683,13	11036,9
2021-04	7351	7075,33	2783,38	11367,3
2021-05	5155	7211,14	2861,94	11560,3
2021-06	8721	7296,82	2916,11	11677,5
2021-07	7555	7350,86	2950,88	11750,8
2021-08	7127	7384,95	2971,83	11798,1
2021-09	8665	7406,46	2983,47	11829,5
2021-10	8345	7420,03	2988,98	11851,1
2021-11	9593	7428,59	2990,54	11866,6
2021-12	10126	7433,98	2989,57	11878,4

Tablo 4.8’de yer alan verilerin doğruluk derecesini ve Ocak 2016- Aralık 2020 yılları arasında bulunun 12 aylık dönemlerin her birinin Ortalama Mutlak Hata (MAE) ölçütü kullanarak tespit edilmeye çalışılmaktadır. Bulunan sonuçlar değerlendirilerek seçilen ARIMA(1,1,1) modelinin doğruluk ve güvenilirlik derecesi ortaya konulmaya çalışılmaktadır.

Tablo 4.9. ARIMA(1,1,1) Modeline Göre Eldeki Verileri Kullanarak 2021 Yılından 2017 Yılına Kadar Geçmiş Değer Tahmin Tablosu

Dönem	Kullanılan Veriler	MAE	Gerçek Değerler Top.	% MAE
Ocak 2021-Aralık 2021	Ocak 2016- Aralık 2020	1658,82	19905,84	8,33
Ocak 2020-Aralık 2020	Ocak 2016- Aralık 2019	3617,67	72653	4,98
Ocak 2019-Aralık 2019	Ocak 2016- Aralık 2018	1439,76	110559	1,30
Ocak 2018-Aralık 2018	Ocak 2016- Aralık 2017	1472,96	103650	1,42
Ocak 2017-Aralık 2017	Ocak 2016- Aralık 2016	926,22	93498	0,99

Ortalama Mutlak Hata (MAE), tahminlerin gerçek değerlerden ortalama olarak ne kadar sapma gösterdiğini ölçen bir metriktir.

Tablo 4.9’da yer alan sonuçlar, tahminlerin gerçek değerlere ortalama olarak %MAE kadar bir hata yaptığını göstermektedir. Pandemi dönemi, özellikle 2020 yılında yaşanan sokağa çıkma yasakları ve kısıtlamaları nedeniyle, ARIMA(1,1,1) modelinin doğruluk oranını değerlendirmek için hesaplanan %MAE değerlerini etkilemiştir. Bu hesaplamalara göre, 2017’den 2020’ye kadar olan dönem için %1’lik bir hata sapması hesaplanmıştır. Ancak, 2020 yılında pandemi dönemi ve sokağa çıkma kısıtlamaları gibi faktörlerin etkisiyle tahminlerin %4,98 ve %8,33’lük hata oranlarıyla oldukça iyi bir doğruluk düzeyine sahip olduğu gözlemlenmektedir. Bu durum, modelin bu olağanüstü koşullara uyum sağlayarak daha geniş hata paylarına rağmen tatmin edici tahminler ürettiğini göstermektedir.

6. SONUÇ

Bu çalışma, Bingöl Ağız ve Diş Sağlığı Merkezi'ne gelen hasta sayılarını analiz etmeyi ve gelecekteki talebi tahmin etmeyi amaçlayan bir araştırmayı temsil etmektedir. Ocak 2016 ile Aralık 2021 arasındaki altı yıllık bir döneme ait hasta verileri kullanılarak bir model oluşturulmuştur. Bu model, bir yıl içinde hastaneye başvuracak hasta sayısını tahmin etmeyi hedeflemektedir. Elde edilen sonuçlar, hastanenin kaynaklarını daha etkili bir şekilde yönlendirmesine, malzeme temini ve doktor izinlerini düzenlemesine yardımcı olacak ve hastaların daha iyi sağlık hizmeti almasını sağlayacaktır. Bu tez çalışması, sağlık sektöründe daha verimli ve etkili hizmet sunmak için önemli bir adım olarak değerlendirilebilir.

Çalışma sürecinde Box-Jenkins yöntemi kullanılmıştır. Bu yöntem, bir zaman serisinin yapısını belirleme, gözlem değerleri arasındaki bağıntıları etkili bir şekilde yansıtma ve model belirleme aşamasında istatistiksel testler kullanma yeteneği sunar. Ancak bu yöntemin uygulanabilirliği, kullanılan zaman serisinin durağan olmasına bağlıdır. Bu nedenle, bazı serilerde bu yöntemin uygulanması zorluğu ortaya çıkabilir.

Çalışmada, Box-Jenkins yönteminin genel yapısı ve durağan ve durağan olmayan modeller için kullanılan ARIMA modelleri ile ilişkilendirilmesi teorik olarak açıklanmıştır. Deneysel olarak, Bingöl Ağız ve Diş Sağlığı Hastanesi'nden alınan Ocak 2016 ile Aralık 2021 veri seti kullanılmıştır. ARIMA modellerini uygulayabilmek için zaman serisinin durağan olması gerektiği göz önüne alınmıştır. Durağanlığın sağlanması için trend etkisi ve mevsimsellik gibi faktörler fark alma işlemi ile giderilmeye çalışılmıştır. Fark alma işlemi sonrasında yapılan analizler, zaman serisinin durağan hale getirildiğini göstermektedir.

Serinin durağanlığı sağlandıktan sonra, en uygun ARIMA modeli belirlenmiştir. Yapılan deneyler sonucunda ARIMA(1,1,1) modeli en uygun model olarak seçilmiştir. Bu model kullanılarak gelecekteki 12 aylık hasta talepleri tahmin edilmiştir. Yapılan zaman serisi analizi, Bingöl ilindeki ağız ve diş sağlığı hizmetlerine olan talebin arttığını ve gelecek yıl beklenen talep artışının yaklaşık %15 olacağını göstermektedir.

2020 yılında yaşanan COVID-19 pandemisi, ARIMA(1,1,1) modelinin doğruluk oranını etkilemiştir. Pandeminin neden olduğu belirsizlikler ve olağandışı durumlar, tahminlerde zorluklar yaratmıştır. Ancak model, bu olağanüstü koşullara rağmen tatmin edici tahminler üretebilmiş ve 2017 ile 2020 arasındaki dönem için %1'lik bir hata sapması hesaplamıştır. Bu, seçilen modelin yüksek doğruluk seviyeleri sağladığını göstermektedir.

Sonuç olarak, bu çalışma, ağız ve diş sağlığı alanındaki hasta taleplerini ARIMA modeli kullanarak tahmin ederek, doğru bir şekilde talebi belirlemenin ve hastane yöneticilerine gerekli iyileştirmeleri yapabilme amacını taşımaktadır. Bu çalışma, kapasite planlaması ve yönetim sorunlarını çözmeye yardımcı olan önemli bir katkı sağlamış ve diş hastanelerinin hasta sayısı tahminlerini ele alarak literatüre değerli bir katkı sunmuştur.

KAYNAKÇA

Adalı, E.(2020). Makina İmalat Sanayiinde Talep Tahmini: Elektromekanik Sanayiinde Bir Uygulama, Balıkesir Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Yüksek Lisans Tezi.

Adıyaman, F.(2007). Talep Tahmininde Yapay Sinir Ağlarının Kullanılması. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 109 s.

Ahn, H., ve Yoo, S. H. (2015). "Forecasting fashion color trend using ARIMA model with Google trend data." Journal of the Korean Data Analysis Society, 17(4), 1825-1836.

Akar, S. (2014). Türkiye’de Sağlık Harcamaları, Sağlık Harcamalarının Nisbi Fiyatı ve Ekonomik Büyüme Arasındaki İlişkinin İncelenmesi, Celal Bayar Üniversitesi İ.İ.B.F, Manisa, 21(1).

Ali, M., ve Abbas, S. (2017). "An empirical evaluation of ARIMA and ANN models for forecasting tourist arrivals." Journal of Travel Research, 56(2), 171-184.

Alon, Diğ.(2001). Forecasting aggregate retail sales: A comparison of artificial neural networks and traditional methods. Journal of retailing and consumer services, 8(3), 147-156.

Almakrami, A., ve Basir, N. (2016). "Forecasting long-term electricity demand using a modified ARIMA model." Journal of Energy and Power Engineering, 10(9), 637-646.

American Psychological Association (APA). (2020). Publication Manual of the American Psychological Association (7th ed.). American Psychological Association.

Armstrong, J. Scott. (2001).Selecting Forecasting Methods, Principles of Forecasting: A Handbook for Researchers and Practitioners içinde (der. J. S. Armstrong), Norwell, MA: Kluwer Academic. s. 363-386.

Arslan, A.(2020). Atatürk Üniversitesi, Sağlık Hizmetleri MYO. Sağlık Yönetim Ders Notları.

Ataseven, B.(2013) .Yapay Sinir Ağları ile Öngörü Modellemesi, Öneri Dergisi, vol.10, no.39, s.101-115.

Ataman, G., Kurşunluoğlu Yarımoğlu,E.(2018). Hastane Türlerine Göre Hasta Memnuniyetini ve Hastane Seçimini Etkileyen Unsurlar. Hacettepe Sağlık İdaresi Dergisi, 21(2), 273-288.

Berg, B. L. (2007). Qualitative Research Methods for the Social Sciences. Allyn & Bacon.

Box, GEP, Jenkins, G.M. and Reinsel, G.C.(2008). Time Series Analysis: Forecasting and Control. 4th Edition, Wiley, Oxford. <https://doi.org/10.1002/9781118619193>

Box, GEP, Jenkins, G.M., Reinsel, G.C., Ljung, G.M. (2015). Time series analysis: forecasting and control. John Wiley & Sons.

Bozdağ, H. (2011). Box-Jenkins Ve Yapay Sinir Ağı Yöntemleri İle Havalimanı Yolcu Talebi Öngürülenmesi. Antalya Havalimanı Örneği. Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Ekonometri Anabilim Dalı Yüksek Lisans Tezi.

Ceydeli, N. (2006). Hastane İşletmelerinde Yenileme Yatırım Kararları ve Bir Üniversite Hastanesi Radyoloji Bölümünde Uygulama. Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü. Yayınlanmamış Yüksek Lisans Tezi

Chatfield, C. (2000). Time Series Forecasting, Washington D.C: Chapman & Hall.

Christou, I.T. (2012). Quantitative Methods in Supply Chain Management. London: Springer-Verlag London Limited.

Crosswhite, C.E. (2003). Method for determining optimal time series forecasting parameters.

Çakır, B. (2017). Sağlıklı Yaşam: Gündelik Hayatta Karşılaştığımız Sağlık Risklerini Azaltabilir miyiz? Ankara Med J, 2017;(3):179-88.

Çevik, O.(1999). Zaman Serilerin Analizinde Box- Jenkins Yöntemi ve Turizm Verileri Üzerine Bir Uygulama, Doktora Tezi, Kırıkkale Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı.

Çıkmak, S. (2012). İşletmelerde Stratejik Yönetim Sürecinin İncelenmesi ve Yeniden Yapılandırılması. Yüksek Lisans Tezi, Sakarya Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı

Çiğdem, Ş.(2009). Zaman Serileri Analizinde Mevsimsel Düzeltme Yöntemleri ve Aylık Sanayi Üretim İndeksine Uygulanması. Gazi Üniversitesi Fen Bilimleri Enstitüsü İstatistik Anabilim Dalı Yüksek Lisans Tezi.

Çuhadar, M., Güngör, İ., Göksu, A. (2009). Turizm Talebinin Yapay Sinir Ağları İle Tahmini Ve Zaman Serisi Yöntemleri İle Karşılaştırmalı Analizi: Antalya İline Yönelik Bir Uygulama. Süleyman Demirel Üniversitesi, The Journal of Faculty of Economics and Administrative Sciences,1, 99-114.

Dedeoğlu, T., Çetin, O. (2021).Sağlık Sektöründe Hasta Talebinin Tahmini.Trakya Üniversitesi İktisadi ve İdari Bilimler Fakültesi E-Dergi.Haziran 10(1),25-38.

Demirdöğen, O. (1998). Talep Tahmininde Monte-Carlo Simülasyon Tekniğinin Kullanılması. Turizm Araştırma Dergisi, 15(1), 25-30.

Duru, Ö. (2007). Zaman Serileri Analizinde ARIMA Modelleri Ve Bir Uygulama. İstanbul Üniversitesi Sosyal Bilimler Enstitüsü Ekonometri Anabilim Dalı Yüksek Lisans Tezi.

Elma, Ç.A. (2008). Yapısal Kırılmalar Altında Birim Kök Testleri Ve Eşbütünleşme Analizi : para Talebi İstikrarı. Gazi Üniversitesi Sosyal Bilimler Enstitüsü Ekonometri Anabilim Dalı Yüksek Lisans Tezi.

Erdoğan, E. (2006). Zaman Serilerinde ARIMA Modelleri. Muğla Üniversitesi Fen Bilimleri Enstitüsü İstatistik Ve Bilgisayar Bilimleri Anabilim Dalı Yüksek Lisans Tezi.

Ergün, S., Şahin, S.(2017).İşletme Talep Tahmini Üzerine Literatür Araştırması. ulakbilge 5. 10 (2017), 469-487.

Erkaymaz, A.(2013). Decomposition Method for Solving Nonlinear Equations: A Review, Applied Mathematics and Computation, Vol. 219, No. 15, pp. 7624-7636, 2013.

Fişek, N. (1983). Halk Sağlığına Giriş. Hacettepe Üniversitesi Dünya Sağlık Örgütü Hizmet Araştırma ve Araştırmacı Yetiştirme Merkezi, Yayın No: 2, Ankara.

Gözcü, O. (2009). Türkiye’de Hava Ulaşım Talebinin ARIMA Modelleri İle Tahminlenmesi. Atatürk Üniversitesi Fen Bilimleri Enstitüsü İnşaat Mühendisliği Anabilim Dalı Yüksek Lisans Tezi.

Hammersley, M., & Atkinson, P. (2007). Ethnography: Principles in Practice. Routledge.

Hanedar, A. Ö., Akkaya, O., Bizim, Ç. “Durağanlık Analizi, Birim Kök Testleri Ve Trend “ İnternet Erişim Tarihi: 10.12.2020.

Hazır, E., Koç, K.H., Esnaf ,Ş. (2016). Türkiye Mobilya Satış Değerlerinin Örnek Bir Yapay Zekâ Uygulaması İle Tahmini. Selçuk-Teknik Dergisi ISSN:1302-6178. Konya.

Hull, J. C. (2015). Options, Futures, and Other Derivatives. Pearson Education.

Honaker, J.A.(2010). What to do about missing values in time-series cross-section data. American Journal of Political Science, 561-581.

Horasan, E.B.(2011). Box-Jenkins Modelleri İle Bağımsız Denetim Uygulaması. Marmara Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı Muhasebe Denetimi Bilim Dalı Yüksek Lisans

s Tezi.

Hsu, C. C., & Sandford, B. A. (2007). The Delphi technique: making sense of consensus. Practical Assessment, Research & Evaluation, 12(10), 1-8.

Joshua, M.(2013). Stat 520 Forecasting And Time Serier. Departman Of Statistics University Of South Carolina.

Kam, H.J., Sung, J.O. ve Park, R.W. (2010). Prediction of Daily Patient Numbers for a Regional Emergency Medical Center using Time Series Analysis. Healthc Inform Research. 16(3): 158-165.

Karaatlı, M., Helvacıoğlu, Ö.C., Ömürbek, N., Tokgöz, G. (2012). Yapay Sinir Ağları Yöntemi İle Otomobil Satış Tahmini. Uluslararası Yönetim İktisat ve İşletme Dergisi.

Kaya, E. (2019). Zaman Serileri Analizinde Box-Jenkins Yöntemi ile Savunma Sanayileri Verileri Üzerine Bir Uygulama, Yüksek Lisans Tezi, Karaman Üniversitesi, İşletme Anabilim Dalı.

Kavuncubaşı, Ş., Kısa, A. (2002). Sağlık Kurumları Yönetimi, Anadolu Üniversitesi Yayın No: 1429, Eskişehir, s. 68.

- Kavuncubaşı, Ş., Kısa, S. (2002). Ekip çalışması ve liderlik. Sağlıkta Kalite Dergisi, 3(3), 30-33.
- Khandelwal, I., Adhikari, R., Verma, G. (2015). Time Series Forecasting using Hybrid ARIMA and ANN Models based on DWT Decomposition. Procedia Computer Science(48), 173-179.
- Kendall, M.G.(1973). The advanced Theory of Statics, Charles Griffin, London, sf: 506-507.
- Kıran, B. (2014).İstanbul Üniversitesi, Uzaktan Eğitim Uygulama Ve Araştırma Merkezi İSUZEM.Ekonomimetre, Zaman serileri analizi dersnotları.
- Kırçıl, M.(2013). Box-Jenkins Yöntemi İle Konut Doğalgaz Talebinin Tahminlenmesi : İzmir İli Örneği. Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Ekonometri Anabilim Dalı Yüksek Lisans Tezi.
- Kırılmaz, H., Bağış, M., Salim, B. ve Şimşir, İ. (2015). Sağlık Yöneticilerinin Değişim Sürecine Bakış Açılarını Belirlemeye Yönelik Bir Araştırma. Uluslararası Yönetim İktisat ve İşletme Dergisi, 11(25), 91-113.
- Köksal, C.D. Irmak, S. Asilkan, Ö. (2012). Hastanelerin Gelecekteki Hasta Yoğunluklarının Veri Madenciliği Yöntemleri İle Tahmin Edilmesi. Uluslararası Alanya İşletme Fakültesi Dergisi. 4(1): 101-114.
- Kvale, S. (1996). InterViews: An introduction to qualitative research interviewing.
- Lim, C., Chang, C., M, McAleer. (2009). Forecasting H(m)otel Guest Nights in New Zealand, International Journal of Hospitality Management, 28 (2), 228-235.
- Macaulay, F. R. (1951). The Movement of Interest Rates, Bond Yields and Stock Prices in the United States since 1856. New York: National Bureau of Economic Research.
- Merriam, S. B., & Tisdell, E. J. (2015). Qualitative Research: A Guide to Design and Implementation. John Wiley & Sons.
- Minitab 21 destek. <https://support.minitab.com/en-us/minitab/21/help-and-how-to/statistical-modeling/regression/how-to/fit-regression-model/interpret-the-results/all-statistics-and-graphs/analysis-of-variance-table/>.ErişimTarihi.11.06.2022.
- Gilliland, M., Tashman, L., Sglavo, U.(2015). Business Forecasting: Practical Problems and Solutions.Viley.
- Nasuhoğlu, H. (2019). Eczacılık sektöründe yapay sinir ağları ve zaman serileri analizi ile talep tahmini. Maltepe Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı Yüksek Lisans Tezi.
- Newbold, P. (2000).İşletme ve İktisat için İstatistik, çev. Ümit Şenesen, Literatür Y., İstanbul, .ss.777-785.
- Olgun, S. (2009). Tedarik zinciri yönetiminde talep tahmini yöntemleri ve yapay zeka tabanlı bir talep tahmini modelinin uygulanması. Yayımlanmamış Yüksek Lisans Tezi. İstanbul: İstanbul Üniversitesi, Fen Bilimleri Enstitüsü.

Önder, Ö. R. (2017). Ankara Üniversitesi, Sağlık Bilimleri Fakültesi Ders Notları.

Önder, M. E. (2017). Sağlık Hizmetlerinin Tanımı, Türleri, Sağlık Ekonomisi ve Finansmanı. Yeni Tıp Dergisi, 34(1), 36-43.

Özkaya, M.(2022). Arıma Modellerinin Porsuk Baraj Haznesi Aylık Akım Verilerine Uygulanabilirliğinin Araştırılması. Eskişehir Teknik Üniversitesi, İnşaat Mühendisliği Anabilim Dalı Yüksek Lisans Tezi.

Özüdoğru, A.G., Görener, A. (2015). Hizmet Sektöründe Talep Tahmini: Sağlık İşletmelerinde Bir Uygulama, T.C. İstanbul Ticaret Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı İşletme Yüksek Lisans Programı, İstanbul.

Park, C., ve Yeo, I. (2019). "A hybrid model for demand forecasting: combining ARIMA and machine learning techniques." Journal of Industrial Engineering and Management Science, 3(1), 39-52.

Ransom, E.R., Joshi, M.S., Nash, D.(2022).The Healthcare Quality Book: Vision, Strategy, and Tools. AUPHA/HAP Book.s.450.

Rubin, H. J., & Rubin, I. S. (2011). Qualitative interviewing: The art of hearing data

Rubin, T.(2016). <https://bilimgenc.tubitak.gov.tr/makale/gecmiste-insanlar-zamani-nasil-olcuyordu>. Erişim Tarihi:04.05.2021.

Seçim, H.(1991). Hastane Yönetimi ve Organizasyonu-Türkiye’de Hastanelerin Organizasyonu İçin Bir Model Önerisi, İşletme Fakültesi Yayın No:252, İstanbul, s. 5.

Seidman, I. (2013). Interviewing as qualitative research: A guide for researchers in education and the social sciences

Seker, S.E., Mert, C., Al-Naami, K., Ozalp, N., Ayan, U.(2013). Correlation between the Economy News and Stock Market in Turkey. International Journal of Business Intelligence and Review (IJBIR) , 4 (4), 1-21.

Seker, S., İşçen, H. İ., Özcan, Y. (2015). Zaman Serileri Analizi ve Prognoz. Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi, 16(2), 27-45.

Seker, S.E. (2015). Zaman Serileri Analizi (Time Series Analysis), YBS Ansiklopedi, v.2, is.4, Aralık,(31), 69-91.

Serttaş, Z., (2011). Türkiye’de Perakende Sektöründe Talebi Etkileyen Etmenler ve Yapay Sinir Ağlarıyla Talep Tahmini Uygulaması, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, İstanbul.

Sevüktekin, M., Nargeleçekenler, M.(2007). Ekonometrik Zaman Serileri Analizi Eviews Uygulamalı. Nobel Yayın Dağıtım.

- Sezer, B., Taşdelen Teker, D., Sezer, T.A., Elçin, M. (2019). DundeeMevcut EğitimOrtamı Değerlendirme Ölçeği (DEODÖ): Türkçe Uyarlama Çalışması , Ulusal Tıp Eğitimi Sempozyumu, Türkiye,10 -12 Nisan.
- Soysal, M., Ömürgönülşen, M.(2010). Türk Turizm Sektöründe Talep Tahmini Üzerine Bir Uygulama. Turizm Araştırmaları Dergisi, Cilt 21, Sayı 1, Bahar: 128-136.
- Stadler, H., Kilger, C.(2000). Supply Chain Management and Advanced Planning, Springer, s.8.
- Şahin, B. (2019). Vasıflı ve parlak çelik sektöründe çoklu regresyon analizi ile talep tahmini uygulaması. Yayınlanmamış Yüksek Lisans Tezi. Karabük: Karabük Üniversitesi, Fen Bilimleri Enstitüsü.
- Tanyaş, M. ve Baskak, M. (2013). Üretim Plânlama ve Kontrol. İstanbul: İrfan Yayıncılık.
- Taşlıyan, M., Gök, S.(2012). Kamu ve Özel Hastanelerde Hasta Memnuniyeti: Kahramanmaraş'ta Bir Alan Çalışması, Kahramanmaraş Sütçü İmam Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 2(1), 69-94.
- T.C.S.B. (2020). T.C. Sağlık Bakanlığı COVID- 19 Dış Hekimliği Uygulamalarındaki Acil ve Zorunlu Hizmetler. 2020, April 21. Available from: [https:// covid19bilgi.saglik.gov.tr/depo/enfeksiyonkontorl-onlemleri/COVID19-DisHekimligiUygulamalarindakiAcilVeZorunluHizmetler.pdf](https://covid19bilgi.saglik.gov.tr/depo/enfeksiyonkontorl-onlemleri/COVID19-DisHekimligiUygulamalarindakiAcilVeZorunluHizmetler.pdf)
- TDK. Türk Dil Kurumu. (2009).
- Uslu, E.E. (2011). Mevsimsel Düzeltme Yöntemlerinin Hane halkı İşgücü İstatistiklerine Uygulanması. Dicle Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi,1,2, 40-56.
- Yakar, H. (2019). Ortaokul düzeyinde iklim okuryazarlığı yeterliliklerinin Delphi tekniğiyle belirlenmesi. Yayınlanmamış Doktora Tezi. Ankara: Gazi Üniversitesi, Eğitim Bilimleri Enstitüsü.
- Yaşar, A.B.(2009). Kentiçi Otobüs Taşımacılığında Talep Tahmini”, Yüksek Lisans Tezi, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü, Denizli, s.70.
- Yıldırtan, D.Ç.(2010). Eviews Uygulamalı Temel Ekonometri Makro Ekonomik Verilerle. Türkmen Kitabevi.
- Yılmaz, V. (2010). Enerji Talebi ve Tokat'ta Elektrik Enerjisi Talebi Üzerine Bir Uygulama (YL Tezi). Gaziosmanpaşa Üniversitesi, Tokat.
- Yiğit, V. (2016). Hastanelerde Tıbbi Malzeme Talep Tahmini:Serum Seti Tüketimi Üzerinde Örnek Bir Uygulama. Manas Sosyal Araştırmalar Dergisi.
- Yücesan, Ö. (2018). YSA, ARIMA ve ARIMAX Yöntemleriyle Satış Tahmini: Beyaz Eşya Sektöründe bir Uygulama. Journal Of Business Research Turk dergisi, 10(1),689-706.
- Yüzer, Ali F. (2004), İstatistik, Anadolu Üniversitesi Yayını, Yayın No:1448, Eskişehir.
- Yolsal, H.(2010). Mevsimsel Düzeltmede Kullanılan İstatistiki Yöntemler Üzerine Bir İnceleme. İstanbul Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi,9,33, 245-257.

Wang, Z., Zhang, Y., ve Luo, Y. (2020). "ARIMA-based short-term passenger flow forecasting at subway stations." Journal of Advanced Transportation, 2020.

Wei, W. (2006) Zaman Serileri Analizi; Pearson Education yayınevi

WHO (1948). Constitution of the World Health Organization. Geneva, World Health Organization

WHO (1986). Ottawa charter of health promotion. Geneva, World Health Organization.

Walshe, K., Smith, J. (2006). Healthcare Management. Open University Press, s. 552.

URWorld Health Organization. (2021). Hospitals. https://www.who.int/health-topics/hospitals#tab=tab_1(Erişim Tarihi 04.03.2023).

<https://support.minitab.com/en-us/minitab/21>(Erişim Tarihi 04.03.2021).

<https://www.sisasoft.com.tr/zaman-serisi-nedir/>(Erişim Tarihi: 19.01.2022).

EKLER

Ek-1. χ^2 (X- Kare) Olasılık Tablosu

S.D.	Olasılık (α)									
	0,995	0,990	0,975	0,950	0,900	0,100	0,050	0,025	0,010	0,005
1	-	-	-	-	0,016	2,706	3,841	5,024	6,635	7,879
2	0,010	0,020	0,051	0,103	0,211	4,605	5,991	7,378	9,210	10,597
3	0,072	0,115	0,216	0,352	0,584	6,251	7,815	9,348	11,345	12,838
4	0,207	0,297	0,484	0,711	1,064	7,779	9,488	11,143	13,277	14,860
5	0,412	0,554	0,831	1,145	1,610	9,236	11,070	12,833	15,086	16,750
6	0,676	0,872	1,237	1,635	2,204	10,645	12,592	14,449	16,812	18,548
7	0,989	1,239	1,690	2,167	2,833	12,017	14,067	16,013	18,475	20,278
8	1,344	1,646	2,180	2,733	3,490	13,362	15,507	17,535	20,090	21,955
9	1,735	2,088	2,700	3,325	4,168	14,684	16,919	19,023	21,666	23,589
10	2,156	2,558	3,247	3,940	4,865	15,987	18,307	20,483	23,209	25,188
11	2,603	3,053	3,816	4,575	5,578	17,275	19,675	21,920	24,725	26,757
12	3,074	3,571	4,404	5,226	6,304	18,549	21,026	23,337	26,217	28,300
13	3,565	4,107	5,009	5,892	7,042	19,812	22,362	24,736	27,688	29,819
14	4,075	4,660	5,629	6,571	7,790	21,064	23,685	26,119	29,141	31,319
15	4,601	5,229	6,262	7,261	8,547	22,307	24,996	27,488	30,578	32,801
16	5,142	5,812	6,908	7,962	9,312	23,542	26,296	28,845	32,000	34,267
17	5,697	6,408	7,564	8,672	10,085	24,769	27,587	30,191	33,409	35,718
18	6,265	7,015	8,231	9,390	10,865	25,989	28,869	31,526	34,805	37,156
19	6,844	7,633	8,907	10,117	11,651	27,204	30,144	32,852	36,191	38,582
20	7,434	8,260	9,591	10,851	12,443	28,412	31,410	34,170	37,566	39,997
21	8,034	8,897	10,283	11,591	13,240	29,615	32,671	35,479	38,932	41,401
22	8,643	9,542	10,982	12,338	14,041	30,813	33,924	36,781	40,289	42,796
23	9,260	10,196	11,689	13,091	14,848	32,007	35,172	38,076	41,638	44,181
24	9,886	10,856	12,401	13,848	15,659	33,196	36,415	39,364	42,980	45,559
25	10,520	11,524	13,120	14,611	16,473	34,382	37,652	40,646	44,314	46,928
26	11,160	12,198	13,844	15,379	17,292	35,563	38,885	41,923	45,642	48,290
27	11,808	12,879	14,573	16,151	18,114	36,741	40,113	43,195	46,963	49,645
28	12,461	13,565	15,308	16,928	18,939	37,916	41,337	44,461	48,278	50,993
29	13,121	14,256	16,047	17,708	19,768	39,087	42,557	45,722	49,588	52,336
30	13,787	14,953	16,791	18,493	20,599	40,256	43,773	46,979	50,892	53,672
40	20,707	22,164	24,433	26,509	29,051	51,805	55,758	59,342	63,691	66,766
50	27,991	29,707	32,357	34,764	37,689	63,167	67,505	71,420	76,154	79,490
60	35,534	37,485	40,482	43,188	46,459	74,397	79,082	83,298	88,379	91,952
70	43,275	45,442	48,758	51,739	55,329	85,527	90,531	95,023	100,425	104,215
80	51,172	53,540	57,153	60,391	64,278	96,578	101,879	106,629	112,329	116,321
90	59,196	61,754	65,647	69,126	73,291	107,565	113,145	118,136	124,116	128,299
100	67,328	70,065	74,222	77,929	82,358	118,498	124,342	129,561	135,807	140,169

Ek-2. Ağız ve Diş Sağlığı Merkezine 2016-2021 Yılları Arasında Gelen Hasta Sayısı
Tablosu

Tarih	Hasta Sayısı Gerçek Değer
2016-01	7037
2016-02	7924
2016-03	8750
2016-04	8038
2016-05	7930
2016-06	5920
2016-07	6978
2016-08	7857
2016-09	5194
2016-10	7244
2016-11	8010
2016-12	7371
2017-01	8412
2017-02	7812
2017-03	9028
2017-04	7724
2017-05	7668
2017-06	5147
2017-07	7246
2017-08	6611
2017-09	7482
2017-10	8559
2017-11	8819
2017-12	8990
2018-01	10982
2018-02	9374
2018-03	9516
2018-04	8589
2018-05	6894
2018-06	5433
2018-07	8687
2018-08	7295
2018-09	9080
2018-10	9387
2018-11	9210
2018-12	9203
2019-01	9112
2019-02	9445
2019-03	11311
2019-04	10966
2019-05	6635
2019-06	5738
2019-07	9898
2019-08	6738
2019-09	9879

2019-10	9736
2019-11	10581
2019-12	10520
2020-01	11344
2020-02	11172
2020-03	8613
2020-04	2556
2020-05	2980
2020-06	5248
2020-07	7388
2020-08	5159
2020-09	3635
2020-10	4238
2020-11	5200
2020-12	5120
2021-01	4873
2021-02	7871
2021-03	9047
2021-04	7351
2021-05	5155
2021-06	8721
2021-07	7555
2021-08	7127
2021-09	8665
2021-10	8345
2021-11	9593
2021-12	10126