



T.C.

BİNGÖL ÜNİVERSİTESİ

SOSYAL BİLİMLER ENSTİTÜSÜ

İŞLETME ANABİLİM DALI

**YAPAY ZEKA İLE ACİL HASTA SAYILARININ
TAHMİNİ EDİLMESİ: BİNGÖL DEVLET HASTANESİ
ÖRNEĞİ**

Muhammet Naif BARUT

DOKTORA TEZİ

Danışman

Prof.Dr. Sait PATIR

Bingöl-2024

T.C.
BİNGÖL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI

YAPAY ZEKA İLE ACİL HASTA SAYILARININ TAHMİNİ
EDİLMESİ: BİNGÖL DEVLET HASTANESİ ÖRNEĞİ

Muhammet Naif BARUT

DOKTORA TEZİ

Danışman

Prof.Dr. Sait PATİR

Bingöl-2024

İÇİNDEKİLER

BİLİMSEL ETİK BİLDİRİMİ	iv
TEZ KABUL VE ONAY	v
ÖNSÖZ	vi
ÖZET	vii
ABSTRACT	viii
KISALTMALAR	ix
TABLO LİSTESİ	xi
ŞEKİL LİSTESİ	xii
GİRİŞ	1

BİRİNCİ BÖLÜM: SAĞLIK SİSTEMİ

1.1. Sağlık ve Sağlık Sistemi.....	4
1.1.1. Sağlık Hizmeti	5
1.1.2. Sağlık Sisteminin Önemi	6
1.1.3. Sağlık Sistemi Özellikleri	6
1.1.4. Sağlık Hizmetlerinin Etkili Kullanımı	8
1.1.5. Sağlık Hizmetine Erişim Sorunları	9
1.1.6. Sağlık Hizmetlerinin Sınıflandırılması	9
1.1.6.1. Koruyucu Sağlık Hizmetleri	10
1.1.6.2. Tedavi Edici Sağlık Hizmetleri	11
1.1.6.3. Rehabilitasyon Hizmetleri.....	12
1.2. Sağlık Sistemleri Modelleri.....	13
1.2.1. Beveridge Modeli (Ulusal Sağlık Hizmeti)	14
1.2.2. Bismarck Modeli.....	15
1.2.3. Karma Model	16
1.2.4. Ulusal Sağlık Sigortası Modeli	16
1.2.5. Cepten Ödeme Modeli	17
1.2.6. ABD Modeli	17
1.2.7. Türkiye Modeli (Genel Sağlık Sigortası).....	18
1.2.8. Ülkelerin Sağlık Sistemlerinin İşgücü Açısından Karşılaştırılması	18
1.3. Türkiyede Sağlık Sisteminin Tarihçesi	21
1.3.1. Anadolu Selçukluları ve 19. Yüzyıla Kadar Osmanlı Dönemi.....	22
1.3.2. 19. Yüzyıldaki Osmanlı'dan Cumhuriyet Dönemine	22
1.3.3. Cumhuriyet Dönemi	24

1.3.4. Atatürk Sonrası Dönemden 2000’li Yıllara Gelişim	25
1.3.5. 2000’li Yıllarda Sağlık	26
1.3.5.1. Sağlık Hizmetlerinde Gelişim	27
1.3.5.2. Sağlık Hizmetlerinde Dijitalleşme	28
1.3.5.3. Pandemi ile Birlikte Meydana Gelen Değişim ve Gelişmeler	30
1.3.5.3.1. Pandemi Sonrası Ekonomik ve Sosyal Değişimler	30
1.3.5.3.2. Pandemi’nin Sağlık Sistemlerine Etkisi	31
1.3.5.3.3. Pandemiyle Birlikte İş ve İstihdam Alanındaki Değişimler	32
1.3.5.3.4. Pandeminin Eğitim ve Öğretim Alanına Etkisi	33
1.3.5.3.5. Pandemi ile Birlikte Toplumsal Davranışlarda Değişim	34
1.3.6. Acil Servislerin Sağlık Sisteminde Yeri ve Önemi	35
1.3.6.1. Acil Servis Hizmetlerinin Özellikleri	36
1.3.6.2. Acil Servis Hizmetlerinin Amacı	37
1.3.6.3. Dünyada ve Türkiyede Acil Servisler	39
1.3.6.4. Çalışmanın Acil Serviste Yapılmasının Nedenleri	40

İKİNCİ BÖLÜM:YAPAY ZEKA İLE TAHMİN

2.1.Yapay Zeka Ve Talep Tahmini	45
2.1.1.Yapay Zeka	45
2.1.1.1. Yapay Zekanın Tarihi	47
2.1.1.2. Yapay Zekanın Temel Unsurları	49
2.1.1.3. Yapay Zekanın Kullanım Alanları	51
2.1.2. Yapay Zeka Çeşitleri	52
2.1.2.1. Uzman Sistemler	52
2.1.2.2. Bulanık Mantık	54
2.1.2.3. Genetik Algoritmalar	56
2.1.2.4. Yapay Sinir Ağları	57
2.1.2.5. Bilgisayarlı Görme (Vision)	59
2.1.2.6. Makine Öğrenmesi	60
2.1.2.7. Doğal Dili İşleme ve Anlama	60
2.1.2.8. Robotik	61
2.1.3. Tahmin Yöntemleri	61
2.1.3.1. Kalitatif Yöntemler (Nitel Yöntemler)	61
2.1.3.2. Kantitatif Yöntemler(Nicel Yöntemler)	64
2.1.3.2.1. İlişkisel Yöntemler-Regresyon Analizi	65

2.1.3.2.2. Zaman Serisi Yöntemleri.....	65
2.1.3.3. Yapay Zeka ile Tahminin Avantajları ve Dezavantajları	69
ÜÇÜNCÜ BÖLÜM:ACİL SERVİS HASTA SAYILARININ TAHMİNİ	
3.1. Yöntem ve Amacı.....	71
3.1.1. Araştırmanın Amacı.....	72
3.1.2. Araştırmanın Önemi	73
3.1.3. Araştırmanın Yöntemi	73
3.1.4. Araştırmanın Evren ve Örneklemi	73
3.1.5. Literatür Taraması.....	75
3.2. Devlet Hastanesi Acil Hasta Sayılarının Tahmini.....	88
3.2.1. Aylık Hasta Sayılarının Otokorelasyon Ve Kısmi Otokorelasyonu	96
3.2.2. Zaman Serisi Tahmin Modelleri	99
3.2.2.1.AR Model.....	102
3.2.2.1.1.AR(1) Modeli	102
3.2.2.1.2.AR(2) Modeli	104
3.2.2.1.3.AR(3) Modeli	105
3.2.2.2.MA Model	107
3.2.2.2.1.MA(1) Modeli	107
3.2.2.2.2.MA(2) Modeli	109
3.2.2.2.3.MA(3) Modeli	110
3.2.2.3.ARMA Model	111
3.2.2.3.1.ARMA(1.1) Modeli.....	111
3.2.2.3.2.ARMA(2.2)Modeli.....	113
3.2.2.4. ARIMA MODEL.....	114
3.2.2.4.1 ARIMA(1.1.1) MODELİ.....	115
3.2.2.4.2 ARIMA(2.2.2) MODELİ.....	116
3.2.2.5.SARIMA MODELİ.....	118
3.2.2.5.1.SARIMA (1.1.1) Modeli	118
3.2.2.5.2.SARIMA (2.2.2) Modeli	120
3.2.2.6. Zaman Serisi Modellerinin Değerlendirmesi Ve Karşılaştırılması ..	122
3.2.3. Doğrusal Regresyon ile Hasta Sayısı Tahmini	123
3.2.3.1.Regresyon Modelinin Uygulanması Ve Analizi	124
3.2.3.2.Doğrusal Regresyon Modelinin Kurulması Ve En Uygun Modelin Seçilmesi	127
3.2.3.3. Tahmin Ölçeği Oranlarının Analizi	134

3.2.4.Yapay Sinir Ağlarıyla Tahmin.....	137
3.2.4.1. Yapay Sinir Ağları Tahmini: Eğitim, Doğrulama ve Test Oranlarının Analizi.....	137
3.2.4.2. Yapay Sinir Ağı Yapısı: Girdi, Gizli Katman ve Çıkış Katmanı Şeması	138
3.2.4.3. Yapay Sinir Ağı Eğitimi ve Değerlendirmesi.....	139
3.2.4.4. Yapay Sinir Ağı Eğitimi: Nntool Sonuçları ve Analizi	141
3.2.4.5. Yapay Sinir Ağı Eğitim Performansı Grafiği: En İyi Doğrulama Sonucu.....	142
3.2.4.6. Yapay Sinir Ağı Eğitiminde Eğim, Momentum ve Doğrulama Analizi	143
3.2.4.7. Yapay Sinir Ağı Hata Dağılımı Analizi	145
3.2.4.8. Doğrusal Regresyon Modelinin Performans Analizi	145
3.2.4.9. Yapay Sinir Ağı Test Sonuçlarının Değerlendirilmesi	147
SONUÇ VE ÖNERİLER.....	152
KAYNAKÇA	164
EKLER.....	177
EK-1. Acil Servis Hasta Sayısını Tahminlemede Kullanılan Giriş Verileri	177
EK-2. Hasta Sayılarının Tahmininde Kullanılan Verilerin Normalizasyonu.....	181
EK-3. Doğrusal Regresyon Oranları	185
EK-4. Doğrusal Regresyon Yönteminde Kullanılan Kodlar	188
EK-5. YSA Tahmin Yönteminde Kullanılan Kodlar	191
ÖZGEÇMİŞ.....	196

BİLİMSEL ETİK BİLDİRİMİ

Doktora tezi olarak hazırladığım, Yapay Zeka İle Acil Hasta Sayılarının Tahmin Edilmesi: Bingöl Devlet Hastanesi 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.

... / ... / 2024

İmza

Muhammet Naif BARUT

TEZ KABUL VE ONAY
BİNGÖL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ MÜDÜRLÜĞÜNE

Muhammet Naif BARUT tarafından hazırlanan Yapay Zeka İle Acil Hasta Sayılarının Tahmin Edilmesi: Bingöl Devlet Hastanesi Örneği, başlıklı bu çalışma, [*Savunma Sınavı Tarihi*] tarihinde yapılan tez savunma sınavı sonucunda [*oybirliği/oy çokluğuyla*] başarılı bulunarak jürimiz tarafından *İşletme* Anabilim Dalı'nda Doktora tezi olarak kabul edilmiştir.

TEZ JÜRİSİ ÜYELERİ (Unvanı, Adı ve Soyadı)

Başkan	:	İmza:
Danışman	:	İmza:
Üye	:	İmza:

TEZ KABUL VE ONAY

Bu Tez, Bingöl Üniversitesi Sosyal Bilimler Enstitüsü Yönetim Kurulunun/....../201.. tarih ve sayılı oturumunda belirlenen jüri tarafından kabul edilmiştir.

Unvanı Adı Soyadı

ÖNSÖZ

Sağlık sektörü, artan hasta yükü, kaynak kısıtlamaları ve yükselen acil durum talepleri gibi zorluklarla karşı karşıya kalmaktadır. Zorlukların üstesinden gelmek için, sağlık hizmetlerinin daha etkin ve verimli bir şekilde planlanması gerekmektedir. Planlamanın yapılması amacıyla birçok tahmin yöntemi kullanılmıştır. Yapay zeka, büyük veri analitiği ve öğrenme algoritmaları aracılığıyla sağlık sektörü için önemli bir çözüm sunmaktadır. Teknolojiler, geçmiş veri setlerini inceleyerek gelecekteki talepleri tahmin etmekte ve hastane kaynaklarını optimize etmekte kullanılmaktadır. Bingöl Devlet Hastanesi'nin acil servis hasta sayıları üzerinde yapılacak olan analiz, yapay zeka tabanlı talep tahmini modelinin uygulanabilirliği hakkında önemli bilgiler sağlayacaktır.

Çalışma, acil servis hasta sayılarının talep tahminini yapay zeka ile analiz etmeyi amaçlayarak, Bingöl Devlet Hastanesi özelinde bir uygulama sunmaktadır. Bingöl Devlet Hastanesi'nin acil servisindeki hasta sayıları üzerinden yola çıkarak, yapay zeka destekli talep tahmininin mümkün olan etkinliğini ve uygulanabilirliğini değerlendirmeyi amaçlamaktadır. Elde edilecek sonuçlar, sağlık yöneticilerine, doktorlara ve diğer ilgili paydaşlara, hastane kaynaklarını daha iyi yönetme ve gelecekteki acil durum taleplerine daha etkili bir şekilde hazırlıklı olma konusunda rehberlik edebilecek bilgiler sunabilecektir. Bingöl Devlet Hastanesi örneği, sağlık sektöründe yapay zeka tabanlı modellerin uygulanabilirliğini ve etkinliğini anlamamıza katkıda bulunacaktır. Elde edilecek sonuçlar, sağlık hizmetlerinin gelecekteki taleplerine daha iyi bir şekilde yanıt verme kapasitesini artırmak adına yönetim ve politika oluşturma süreçlerine ışık tutacaktır.

Bu çalışmanın hazırlanmasında yardımlarını esirgemeyen danışman hocam *Prof. Dr. Sait PATİR* başta olmak üzere yol gösteren tüm hocalarıma teşekkürlerimi sunmayı bir borç bilirim. Çalışmamı tamamlamam konusunda moral ve motivasyonumu üst düzeyde tutmama yardımcı olan değerli aileme şükranlarımı sunarım.

....../....../2024

Muhammet Naif BARUT

ÖZET

Tezin Başlığı : Yapay Zeka İle Acil Hasta Sayılarının Tahmin Edilmesi: Bingöl Devlet Hastanesi Örneği
Tezin Yazarı : Muhammet Naif BARUT
Danışman : Prof. Dr. Sait PATİR
Anabilim Dalı: İşletme
Bilim Dalı : Genel İşletme
Kabul Tarihi : 30.07.2024
Sayfa Sayısı : xiii +195
Çalışma, sağlık sektöründe acil servis hizmetlerinde ortaya çıkabilecek hasta sayılarının daha etkili bir şekilde tahmin edilmesi amacıyla yapay zeka tabanlı talep tahmini modellerini değerlendirmeyi hedeflemektedir. Bingöl Devlet Hastanesi'nde gerçekleştirilecek örnek uygulama ile bu teknolojinin uygulanabilirliği ve etkinliği üzerine odaklanılarak, sağlık sektöründe daha akılcı ve hızlı bir planlama ve kaynak yönetimi sağlama potansiyeli incelenmiştir. Çalışmada, on üç bağımsız değişken seçilmiş ve acil servise başvuran toplam hasta sayıları bağımlı değişken olarak belirlenmiştir. Bingöl Devlet Hastanesi'ne 2013-2023 yılları arasında yapılan acil servis başvurularını tahmin etmek amacıyla çeşitli tahmin modelleri kullanılmıştır. Zaman serisi modelleri arasında SARIMA(1,1,1) modeli en yüksek performansı göstermiştir. Doğrusal regresyon ile tahmin sonuçlarına göre düşük MSE (0.017211) ve düşük RMSE (0.13119) değerleri elde edilmiştir. YSA modeli ise en düşük MSE (0.012172) ve RMSE (0.11040) değerleri ile en doğru tahminleri yapmıştır. Bağımsız değişkenler arasında toplam nüfus, erkek nüfusu, kadın nüfusu ve okuma yazma bilen oranı gibi faktörlerin acil servis başvuruları üzerinde belirgin etkileri olduğunu ortaya koymuştur. Yerel demografik ve sosyoekonomik faktörlerin dikkate alınarak yapıldığı tahminlerle, sağlık hizmetlerinin kalitesinin artırılması amaçlanmıştır. YSA ve diğer makine öğrenimi algoritmalarının kullanımıyla elde edilen sonuçlar, sağlık yöneticilerine gelecekteki hasta akışını tahmin etme ve kaynak yönetimini daha etkin bir şekilde planlama konusunda önemli rehberlik sağlayabilecektir. 2024-2025 yılı için yapılan hasta sayısı tahminleri YSA modeli kullanılarak hesaplanmış ve acil sağlık hizmetleri planlaması, kaynak tahsisi gibi stratejik kararların alınmasında önemli bir rol oynayabilecektir. Tahmin edilen hasta sayıları, hastane kapasitesinin planlanması ve yönetilmesi için kritik bir bilgi kaynağı oluşturmaktadır. Sonuçlar, sağlık sektöründe yapay zeka ve veri analitiği tekniklerinin kullanımının önemini vurgulamakta ve acil sağlık hizmetlerini daha etkili ve verimli hale getirme potansiyeline sahip olduğunu göstermektedir.
Anahtar kelime: Talep Tahmini , Yapay Zeka, Acil Servis.

ABSTRACT

Title of the Thesis: Estimating the Number of Emergency Patients with Artificial Intelligence: Bingöl State Hospital Example	
Author	: Muhammet Naif BARUT
Supervisor	: Professor Sait PATIR
Department	: Business
Sub-field	: General Business
Date	: 30.07.2024
Number of pages : xiii +195	
The study aims to evaluate artificial intelligence-based demand forecasting models in order to more effectively predict the number of patients that may arise in emergency services in the healthcare sector. Focusing on the applicability and effectiveness of this technology, the potential of providing more rational and faster planning and resource management in the healthcare sector was examined with the sample application to be carried out at Bingöl State Hospital. In the study, thirteen independent variables were selected and the total number of patients applying to the emergency department was determined as the dependent variable. Various prediction models were used to predict emergency department admissions to Bingöl State Hospital between 2013 and 2023. Among the time series models, the SARIMA(1,1,1) model showed the highest performance. According to the prediction results with linear regression, low MSE (0.017211) and low RMSE (0.13119) values were obtained. The ANN model made the most accurate predictions with the lowest MSE (0.012172) and RMSE (0.11040) values. It has been shown that among the independent variables, factors such as total population, male population, female population and literacy rate have significant effects on emergency department admissions. It is aimed to increase the quality of health services with the predictions made by taking local demographic and socioeconomic factors into account. Results obtained through the use of ANN and other machine learning algorithms can provide important guidance to healthcare managers in predicting future patient flow and planning resource management more effectively. Predictions of the number of patients for 2024-2025 were calculated using the ANN model and can play an important role in making strategic decisions such as emergency health services planning and resource allocation. Estimated patient numbers constitute a critical source of information for planning and managing hospital capacity. The results highlight the importance of the use of artificial intelligence and data analytics techniques in the healthcare sector and show that they have the potential to make emergency healthcare more effective and efficient.	
Keywords: Demand Forecasting, Artificial Intelligence, Emergency Service.	

KISALTMALAR

ACF	(AutoCorrelation Function)
AR	Otogresif
ARIMA	Otoregresif Entegre Hareketli Ortalama
bkz.	Bakınız
dğr.	Diğer
DSÖ	Dünya Sağlık Örgütü
GSMH	Gayrisafi Milli Hasıla
HBYS	Hastane Bilgi Yönetim Sistemi
IBM	Uluslararası İş Makineleri (İnternational Business Machines)
İLO	Uluslar Arası Çalışma Örgütü (International Labour Organization)
İTS	İlaç Takip Sistemi
MA	Hareketli Ortalama
MR	Manyetik Rezonans Görüntüleme
MHRS	Merkezi Hekim Randevu Sistemi
MLP	Çok Katmanlı Algılayıcılar (Multi-Layer Perceptron)
OECD	Ekonomik İşbirliği ve Kalkınma Örgütü
PACF	Kısmi Otomatik Korelasyon İşlevi (Partial AutoCorrelation Function)
TÜİK	Türkiye İstatistik Kurumu
TSH	Temel Sağlık Hizmeti
TSK	Türk Silahlı Kuvvetleri
SARIMA	Seasonal Autoregressive Integrated Moving Average
SDP	Sağlıkta Dönüşüm Programı
SİNA	Sağlıkta İstatistik ve Nedensel Analizler
SGK	Sosyal Güvenlik Kurumu
SPGK	Sağlık Projesi Genel Koordinatörlüğü
SRI	Sosyal Sorumluluk Yatırımları
SSE	Senior Application Enginer (Uygulama Mühendisliği)
SSK	Sosyal Sigortalar Kurumu
URL	Tekdüzen Kaynak Bulucu (Uniform Resource Loader)

vb.	ve benzeri
vd.	ve diğerleri
vs.	vesaire
YSA	Yapay Sinir Ağı
WHO	Dünya Sağlık Örgütü (World Health Organization)

TABLO LİSTESİ

Tablo 1. 1. Sağlık Sistemlerinde Temel İki Model	16
Tablo 1. 2. 10000 Kişiyeye Düşen Sağlık Çalışanları Sayısı En İyi İlk 20.....	19
Tablo 1. 3. 10000 Kişiyeye Düşen Sağlık Çalışanları Sayısı En Kötü İlk 20	20
Tablo 2. 1. Farklı Yaklaşımlara Göre Yapay Zeka Tanımları	47
Tablo 3. 1. 2013-2023 Aylık Acil Servis Hasta Sayıları	89
Tablo 3. 2. AR(1) Modeli Sonuçları	103
Tablo 3. 3. AR(2) Modeli Sonuçları	104
Tablo 3. 4. AR(3) Modeli Sonuçları	106
Tablo 3. 5. MA(1) Modeli Sonuçları	108
Tablo 3. 6. MA(2) Model Sonuçları	109
Tablo 3. 7. MA(3) Modeli Sonuçları	110
Tablo 3. 8. ARMA(1.1) Modeli Sonuçları.....	112
Tablo 3. 9. ARMA(2.2) Modeli Sonuçları.....	113
Tablo 3. 10. ARIMA(1.1.1) Modeli Sonuçları	115
Tablo 3. 11. ARIMA(2.2.2) Modeli Sonuçları.....	117
Tablo 3. 12. SARIMA(1.1.1) Modeli Sonuçları	119
Tablo 3. 13. SARIMA(2.2.2) Modeli Sonuçları	121
Tablo 3. 14. Zaman Serisi Modellerinin Karşılaştırma Tablosu	123
Tablo 3. 15. Acil Servise Başvuru Oranlarını Etkileyen Faktörler	125
Tablo 3. 16. Regresyon Model Sonuçlarının Karşılaştırılması.....	128
Tablo 3. 17. Doğrusal Regresyon(Bagged Trees) Sonuçları	129
Tablo 3. 18. Gerçek Veri Ve Tahmini Verilerin Karşılaştırılması	134
Tablo 3. 19. Bağımsız Değişkenlerin Hasta Sayısına Etkisi.....	135
Tablo 3. 20. Yapay Sinir Ağı Tahmin Sonuçları	149
Tablo 3. 21. Tahmin Modelleri Sonuçlarının Karşılaştırılması	150
Tablo 3. 22. 2024-2025 Yılı Tahmini Hasta sayıları.....	150

ŞEKİL LİSTESİ

Şekil 1. 1. Sağlık Hizmetleri ve Sağlık Kurumları	10
Şekil 1. 2. Yıllara Göre Sağlıkta Memnuniyet.....	27
Şekil 2. 1. Uzman Sistem Yapısı	53
Şekil 2. 2. Bulanık Mantık Sisteminin Yapısı	55
Şekil 2. 3. Genetik Algoritmanın Genel Akış Şeması	56
Şekil 2. 4. Yapay sinir hücresi.....	59
Şekil 2. 5. Delfi Metodu Döngüsü	63
Şekil 3. 1. 2013-2023 Yılları Bingöl Devlet Hastanesi Acil Servis Hasta Sayılarının Aylara Göre Grafikselsel Gösterimi	89
Şekil 3. 2. 2013-2023 Ocak Ayına Göre Yılların Karşılaştırılması.....	90
Şekil 3. 3. 2013-2023 Şubat Ayına Göre Yılların Karşılaştırılması	91
Şekil 3. 4. 2013-2023 Mart Ayına Göre Yılların Karşılaştırılması	91
Şekil 3. 5. 2013-2023 Nisan Ayına Göre Yılların Karşılaştırılması.....	92
Şekil 3. 6. 2013-2023 Mayıs Ayına Göre Yılların Karşılaştırılması	92
Şekil 3. 7. 2013-2023 Haziran Ayına Göre Yılların Karşılaştırılması	93
Şekil 3. 8. 2013-2023 Temmuz Ayına Göre Yılların Karşılaştırılması	93
Şekil 3. 9. 2013-2023 Ağustos Ayına Göre Yılların Karşılaştırılması	94
Şekil 3. 10. 2013-2023 Eylül Ayına Göre Yılların Karşılaştırılması	94
Şekil 3. 11. 2013-2023 Ekim Ayına Göre Yılların Karşılaştırılması.....	95
Şekil 3. 12. 2013-2023 Kasım Ayına Göre Yılların Karşılaştırılması.....	95
Şekil 3. 13. 2013-2023 Aralık Ayına Göre Yılların Karşılaştırılması	96
Şekil 3. 14. Aylık Hasta Sayılarının Otokorelasyonu.....	97
Şekil 3. 15. Kısmi Otokorelasyon	98
Şekil 3. 16. AR(1) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği	103
Şekil 3. 17. AR(2) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği	105
Şekil 3. 18. AR(3) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği	107
Şekil 3. 19. MA(1) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği	108
Şekil 3. 20. MA(2) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği	109
Şekil 3. 21. MA(3) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği	111
Şekil 3. 22. ARMA(1,1)Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği	112

Şekil 3. 23. ARMA(2,2) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği	114
Şekil 3. 24. ARIMA(1,1;1) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği	116
Şekil 3. 25. ARIMA(2,2,2) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği	118
Şekil 3. 26. SARIMA(1,1,1) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği	120
Şekil 3. 27. SARIMA(2,2,2)Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği	121
Şekil 3. 28. Model Tahminleri Grafiği	130
Şekil 3. 29. Dağılım Grafiği.....	131
Şekil 3. 30. Değişim Oranları Grafiği.....	131
Şekil 3. 31. Yapay Sinir Ağı Mimari Şeması	138
Şekil 3. 32. MSE Performansı Grafiği	143
Şekil 3. 33. Eğitim, Momentum ve Doğrulama Kontrolü Analizi Grafiği.....	144
Şekil 3. 34. Hata Dağılımı Histogram Grafiği	145
Şekil 3. 35. Doğrusal Regresyon Modelinin Performans Analizi Grafikleri	146

GİRİŞ

Sağlık sistemi, bir ülkenin gelişmişlik düzeyini belirleyen kritik bir unsurdur, çünkü ortalama yaşam süresi, yaşam kalitesi, kişi başına düşen doktor sayısı ve ölü doğum oranları gibi faktörler, bir ülkenin sağlık hizmetlerindeki etkinliğini yansıtan temel göstergelerdir. Sağlık sisteminin devlet tarafından denetlenmesi, sağlık hizmetlerinde devletin rolünün belirlenmesi ve devlet tarafından planlanıp yönetilmesi büyük önem taşımaktadır. Bu stratejik yaklaşım, toplumun genel sağlığını artırmak, erişilebilir ve etkili sağlık hizmetlerini sağlamak amacıyla sağlık kaynaklarını düzenlemek ve optimize etmek anlamına gelmektedir. Bunun sonucunda, sağlık sistemi daha anlaşılır, kapsamlı ve sürdürülebilir bir yapıya kavuşabilecektir (Temiz, 2014).

Tarihsel olarak devletler, vatandaşların sağlıklı bir yaşam sürmeleri için bilinçli bir çıkar ilişkisi içinde görülmüştür. Devletin sürekliliği ve destekleri, sağlık alanındaki hakların korunması açısından son derece kritik bir role sahip olmuştur. Geçmişte Mısır'da piramit inşaatında çalışan işçilerin sağlıklarına dikkat edilmesi veya savaşçıların hastalanmamaları için özen gösterilmesi gibi örnekler, devletin sağlıkla ilgili sorumluluklarını gösteren tarihsel referanslar olarak gösterilebilir. Aynı şekilde, Roma gladyatörlerinin sağlığına gereken önem verilmemiş olmasına rağmen, gladyatörlerin hastalanmamaları için sağlıklı beslenme konusunda önceden planlama yapılması devletlerin sağlık unsuruna olan hassasiyetini göstermektedir (Çiçek ve Öcal, 2016). Yukarıdaki örnekler, devletin sağlık konusundaki tarih boyunca üstlendiği rolün evrimini göstermektedir.

Devletlerin sağlık sistemine verdiği önem ve sağlık hizmetlerini bir sorumluluk olarak algılaması, tarihsel süreçte en kritik konular arasında yerini almıştır. Özellikle 1980'lerden sonra teknolojik gelişimlere paralel olarak sağlık, yönetimler için öncelikli bir konu haline gelmiş ve sürekli olarak kamu politikalarının merkezinde yer almıştır. Teknolojinin ilerlemesi, yaşam kalitesinde artış, yaşam süresinin uzaması ve bireylerin iş hayatındaki artan etkileşimi gibi faktörler, devletlere sağlık alanında yeni sorumluluklar ve yükümlülükler getirmiştir. Devletler, sağlık sistemlerini sürekli olarak geliştirme, yenileme ve iyileştirme süreci içerisinde olmuşlardır.

Sağlık unsuru, ekonomik, sosyal ve siyasi politikalarla sıkı bir ilişki içindedir. Sağlık sistemlerinin etkinlik, verimlilik, kullanılabilirlik ve uygulanabilirlik gibi prensipleri içerisinde barındırması önemlidir. Tüm devletler, sağlık politikalarını oluştururken kendi ülkelerinin sosyal, kültürel ve ekonomik koşullarını göz önünde bulundurarak hareket etmektedir. Siyasetçiler, yönetimde etkili olabilmek ve toplumsal refahı artırmak için sağlık konusuna odaklanmakta ve çeşitli politikalar üretmektedir. Ülkeler arasındaki sağlık politikalarındaki farklılıklar, her ülkenin kendi sağlık sisteminin benzersiz işleyişiyle ilgilidir. Ancak, temel amaçları, vatandaşlarına daha iyi bir sağlık sistemi sunarak sağlıklı bireylerle devletin sürdürülebilirliğini sağlamaktır.

Ekonomik perspektiften bakıldığında, günümüzde ekonominin üretilmesinde insan unsurunun öne çıkması, yani insan sermayesinin giderek artan bir önem kazanması, sağlıklı bireylerin rolünü daha da arttırmıştır. İnsan sermayesi yaklaşımı kavramı, 20. yüzyılın ortalarında ortaya çıkmış ve önemli bir konu haline gelmiştir. Bununla birlikte, ülkelerin sosyal, kültürel, politik ve ekonomik sorunlarına farklı bir bakış açısı getirilerek çeşitli perspektiflerin gelişmesinde beraberinde getirmiştir. Dünya genelindeki devletler arasındaki gelişmişlik düzeyi farklılıkları, insana yapılan yatırımlardaki farklılıklar tarafından şekillenmiştir. Günümüz dünyasında insan sermayesine yapılan yatırımlar, devletlere büyüme ve sürdürülebilirlik açısından önemli bir katkı sağlamıştır (Baric, 1985).

Sosyal, kültürel ve ekonomik gelişim açısından bakıldığında, üretim devamlılığı ve buna bağlı olarak ekonomik gelişmenin sağlanabilmesi için insan iş gücü önemli bir yere sahiptir. İnsan sermayesi, ekonomide ancak sağlıklı iş gücüyle sağlanabilmektedir. Diğer bir yandan, sağlık ekonomisi personel altyapı harcamalarıyla yakından ilgilidir. Yapılan harcamalar, devlet açısından yatırım niteliğindeyken, bireyler açısından bakıldığında tüketim niteliğindedir. Bireylere sunulan sağlık hizmeti, gittikçe daha önem kazanmakta ve teknolojiye gelişimler, sağlık sisteminde sürekli bir değişim ve gelişimi beraberinde getirmektedir (Erkan, 1997).

Dünya genelinde ülkeler, çeşitli sağlık politikaları benimsemiş ve benimsenen politikalar her ülkede farklılık göstermektedir. Avrupa Birliği'ne bakıldığında, üye ülkelerin birçok farklı sağlık politikasına rağmen aynı amaç ve kapsamda birleştikleri

görülmektedir. Teknolojinin gelişmesine paralel olarak sağlık sistemlerinde sürekli iyileşme ve değişim zorunluluğu ortaya çıkmaktadır. Ülkelerin, değişime ayak uydurabilmeleri ancak teknolojiyi etkili ve verimli bir şekilde kullanmalarıyla sağlanabilmektedir. Yapay zeka, günümüzde birçok sektörde kullanılmakta ve sektörlerdeki gelişime katkı sağlamaktadır. Aynı şekilde, sağlık sistemlerinde de yapay zekanın kullanılması birçok açıdan gereklidir. Gelişmiş toplumlar, gelişmiş sağlık sistemlerine sahip olmak için teknolojiyi etkili bir biçimde kullanmak zorundadırlar. Bundan dolayı, teknolojinin etkin kullanımı tüm ülkeler açısından oldukça önemli ve vazgeçilmez bir unsur haline gelmiştir (Alpaydın, 2014).

Dünya genelinde yaşanan hızlı değişimler, teknolojinin ilerlemesi, küresel salgınlar ve demografik değişiklikler gibi etmenler, sağlık sektörünü daha önce görülmemiş zorluklarla karşı karşıya bırakmaktadır. Hastaneler ve sağlık hizmeti sağlayıcıları, hızla artan taleplerle başa çıkabilme, kaynakları etkili bir şekilde yönetebilme ve en önemlisi, öngörülemeyen durumları daha iyi idare edebilme ihtiyacıyla karşı karşıyadır. Bundan dolayı, sağlık hizmetleri sunucuları, beklenmedik durumlar karşısında daha hızlı ve esnek bir şekilde yanıt verebilmek adına teknolojik çözümleri entegre etme ihtiyacı hissetmektedir. Büyük veri analitiği ve öğrenme modelleri gibi teknolojiler, sağlık sektöründe talep tahmininde önemli bir rol oynamıştır. Temeli insan ve doğal dinamiklerin benzetimine dayanan yapay zeka, gerçek dünya problemlerinin etkin ve verimli çözülmesi konusunda birçok başarıya imza atmıştır. Yapay zeka sayesinde birçok alandaki geleneksel yaklaşım, yöntem ve teknikler yerini ‘zeki’ çözüm süreçlerine bırakmıştır. Tahmin, optimizasyon, kontrol, yorumlama, bilgi işleme ve modelleme gibi birçok farklı çözüm yaklaşımını kullanan esnek yapıdaki yapay zeka teknikleri, zeki sistemlerin zaman içerisinde bilimsel çalışmalardan sıyrılarak günlük yaşamımızda yer edinmesine de olanak sağlamıştır (Copeland, 1993).

BİRİNCİ BÖLÜM: SAĞLIK SİSTEMİ

Birinci bölümde, "Sağlık sistemi" konusuna ayrıntılı bir şekilde odaklanılarak sağlığın önemi, tarihi, kapsamı ve türleri gibi temel konular ele alınmıştır. Sağlık kavramı, detaylı bir perspektifle incelenerek dünya genelinde ve Türkiye özelinde sağlık sistemine yönelik bir araştırma gerçekleştirilecektir. Sağlık sisteminin tarihine odaklanarak, Türkiye'de sağlık sisteminin geçmişi ele alınacak ve günümüzdeki sağlık sistemi hakkında bilgiler sunulacaktır.

1.1. Sağlık ve Sağlık Sistemi

İnsan yaşamının başlangıcıyla birlikte, sağlık konusu tarih boyunca ve her toplumda büyük bir yere sahip olmuştur. Zira insanın var oluşundan itibaren, hastalıklar, kazalar ve dış tehlikeler de yaşamın bir parçası olmuştur. Tüm toplumlar, geçmişten günümüze kadar sağlığa büyük bir öncelik vermiş ve sağlık alanında sürekli bir arayış ve gelişim içinde olmuşlardır. İnsanlar, sürekli olarak hastalıklarla mücadele etmiş ve daha sağlıklı bir yaşamın peşinde koşmuşlardır. Sağlık kavramı, tüm canlılar için ortak bir deneyimdir ve canlı yaşamla birlikte var olmuştur. Sağlık kavramı, insanlık tarihinde birçok dönüm noktasını şekillendirmiş ve hatta tarihi yönlendirmiştir (Akdur, 2006).

Sağlık, insanların veya toplumların sağlıklı bir yaşam sürmelerini, hastalıkların tedavisini gerçekleştirerek sağlıklı bir duruma getirmeyi ve yaşam koşullarını iyileştirmek için yapılan çalışmaları içermektedir. Sağlık kavramı, zaman, kültür ve coğrafi koşullara bağlı olarak değişiklik gösterebilmektedir. Kimi toplumlarda sağlık, herhangi bir hastalık veya kaza olmaması olarak kabul edilirken, başka toplumlarda fizyolojik, biyolojik, psikolojik ve sosyal açılardan değerlendirilmektedir. Sağlık kavramının, hem nesnel hem de öznel bir bakış açısıyla ele alınması gerekmektedir. Tıbbi testler, doktor muayeneleri gibi somut veriler sağlık durumunu nesnel olarak değerlendirirken, bireylerin duygusal, psikolojik ve sosyal durumları öznel sağlık kavramını şekillendirmektedir. Bireylerin sağlık durumunu anlamak için hem somut hem de soyut unsurların bir arada değerlendirilmesi gerekmektedir (Temizkan, 2015).

1.1.1. Sağlık Hizmeti

Sağlık, genellikle bireyin kendisinde herhangi bir fiziksel veya ruhsal kusur görmemesi veya vücut bütünlüğünde işlevsel bir bozukluk olmaması olarak basitçe tanımlanmaktadır. Halk arasında sağlık, hastalık olmaması olarak algılanabilmektedir. Ancak birçok bilim insanı, sağlığın sadece hastalığın olmaması durumu olmadığını belirtmektedir. Çünkü sağlık, genel bir kavramdır ve hastalığın zıttı olarak görülmemelidir. Hastalıkların çeşitli türleri ve etkileri olabilirken, sağlık bir bütün olarak ele alınmalıdır (Öztek, 2003). Günümüzde sağlık tanımı, geçmişe göre daha geniş bir perspektiften ele alınmaktadır. Temel olarak, sağlık vücutta hastalığın olmaması ve beden ile ruh sağlığının iyi olması olarak tanımlanabilir. Ancak daha kapsamlı bir bakış açısıyla, sağlık sadece fiziksel değil, aynı zamanda ruhsal ve sosyal iyilik hali olarak da ele alınmalıdır. Sonuç olarak sağlık, bireyin tam bir iyilik hali içerisinde olması olarak açıklanmalıdır (Öztürk, 1989).

Sağlık hizmeti, sağlığın korunması, meydana gelen kaza veya hastalıkların tedavisi, bireylerin eski sağlıklarına kavuşturulması ve iyileşemeyen bireylerin toplumda yaşamlarını sürdürebilmesi gibi geniş bir süreci kapsamaktadır. Sağlık hizmetleri, insan sağlığını tehdit eden çeşitli faktörlerin ortadan kaldırılması, toplumun olumsuz unsurların etkisinden korunabilmesi, hasta bireylerin tedavisi ve bedensel ile ruhsal yetenekleri azalmış olan bireylerin rehabilitasyonu için yapılan hizmetlerin tümünü içermektedir (Kavunçubaşı, 2010).

Temel Sağlık Hizmeti (TSH), bir topluluktaki kişilerin ve ailelerin tam katılımıyla ve kabulüyle sağlanan, ülkelerin en uygun harcamalarla karşılayabileceği bireylere ulaştırılan sağlık hizmetinin ilk evresidir. Temel sağlık hizmeti, ülkelerin temel sağlık politikalarının belirlendiği ve bu politikalar doğrultusunda toplumdaki bireylere sunulan sağlık hizmetlerinin çekirdeğini oluşturmaktadır. Temel Sağlık Hizmeti, sağlık sisteminin birinci basamağını oluşturmaktadır. İlk basamak sağlık hizmetlerinin bireylerin yaşam alanlarına yakın ve kolay erişilebilir bir yapıda olması gerekmektedir. Sadece hastalıkların tedavisiyle sınırlı olmayıp hastalıkların belirlenmesi, önlenmesi ve sağlık sistemlerinin geliştirilmesi gibi birçok konuyu içermektedir. Ayrıca, temel sağlık hizmeti genel olarak, bireyin sağlığını koruma ve hastalıkların tedavisi amacıyla sağlık hizmeti eğitimi almış personel tarafından sunulan işlemler bütünü olarak ifade edilmektedir (Kavuncubaşı, 2010).

1.1.2. Sağlık Sisteminin Önemi

Sağlık, toplumların ve ülkelerin refahı için kritik bir öneme sahiptir. Bir ülkenin sağlık sistemi, ekonomik ve sosyo-kültürel gelişimiyle doğrudan ilişkilidir ve toplumdaki diğer sistemleri etkileyerek sosyal düzenin temelini oluşturmaktadır (Öztürk, 1989). Bireylerin sağlığı, çevresel koşullar, davranışlar, yaşam tarzı, sağlık hizmetleri ve genetik faktörler gibi çeşitli etmenlere bağlıdır. Çevresel faktörler bireylerin sağlığını olumlu veya olumsuz yönde etkileyebilirken, bireylerin tercih ettiği yaşam tarzları ve alışkanlıklar (örneğin sigara kullanımı), sağlığı olumsuz etkileyebilmektedir. Sağlık hizmetleri, ülkelerin sağlık politikaları doğrultusunda toplumun sağlık ihtiyaçlarını karşılamakta ve uygulanan politikalar toplum sağlığı üzerinde önemli bir etkiye sahip olabilmektedir (Kavunçubaşı, 2010).

Toplumun sağlıklı ve uzun ömürlü birey sayısını artırmak, sağlık politikalarının tasarımında belirleyici bir rol oynamaktadır. Sağlık politikaları, bireylerin ihtiyaçlarını ve beklentilerini karşılayacak şekilde geliştirilmelidir. Özellikle yaşlı ve hasta nüfusun artışı, sağlık hizmetlerine olan talebin yükselmesine yol açmaktadır. Bu artan talepleri karşılamak için sağlık hizmeti sağlayıcıları, etkili stratejik eylem planları hazırlamalıdır. Planlama sürecinde dikkate alınması gereken faktörler aşağıda sıralanmıştır (Hoge vd., 2006):

- Toplumda ki bireylerin bağımsız kalabilmelerini, kişilerin refah düzeylerini üst seviyeye çıkarmayı ve sağlıkta iyileşmeyi amaç edinme,
- Ulaşılabilir ve üst seviyelerde, kaliteli sağlık hizmeti sunabilme ve ölçebilme.
- Sağlık sisteminde iyi bir iletişim ve koordinasyonu sağlayarak güçlü bir liderliğin oluşturulabilmesi,
- Uygun yer ve zamanda , sağlık hizmeti sunacak yetkin beceri ve deneyimlere sahip personel ihtiyacını karşılayabilme,
- Sistem içerisindeki personel desteğinin sağlanması ve daha hizmet oluşturabilmesi için personel gelişiminin amaç edinilmesi.

1.1.3. Sağlık Sistemi Özellikleri

Sağlık hizmetleri, genel hizmetlerden önemli ölçüde farklılık göstermektedir. Diğer hizmetlerin aksine, sağlık hizmeti rastlantısal bir ihtiyaçtan doğmakta ve bireylerin tercihleriyle belirlenmemektedir. Ayrıca, sağlık hizmetlerinin bir standartı

yoktur ve hizmeti alacak olanlar genellikle önceden bilgi sahibi olamamaktadır. Tedavi sonrası hizmet türü ve miktarı teşhise dayalı olarak belirlenmekte ve öngörümüsi oldukça zordur. Diğer hizmetlerde olduğu gibi, sağlık hizmetlerine erişim, kolaylıkla ertelenememekte ve ikame edilememektedir. Sağlık hizmetlerinin genel özellikleri aşağıda detaylı şekilde madde madde açıklanmıştır (Tengilimoğlu vd., 2017).

- Sağlık Hizmetlerinin Tüketiminin Rastlantısal Bir Özelliğe Sahip Olması: Sağlık hizmetleri, öngörülemeyen ve ani ihtiyaçlar nedeniyle diğer hizmetlerden ayrılmaktadır. Bireyler, sağlık hizmetine ne zaman ve nerede ihtiyaç duyacaklarını bilememektedir. Devlet politikaları, sağlık hizmetlerinin rastlantısal doğası gereği her duruma hazırlıklı olmayı zorunlu kılmaktadır.

- Sağlık Hizmetinin İkamesinin Olmaması: Sağlık hizmetlerinin diğerlerinden farkı, başka bir ürün veya hizmetle değiştirilemez olmasıdır. Diğer hizmetlerde, bireyler isteklerine ve zamanlarına göre farklı hizmetler seçebilirken, sağlık hizmetlerinde böyle bir seçenek ve daha uygun fiyatlı bir alternatif arama veya seçme şansı yoktur (Tengilimoğlu, Işık ve Akbolat, 2017).

- Sağlık Hizmetlerinin Sunumunun Ertelenememesi: Hemen hemen tüm hizmet sistemlerinde, acil bir durum olmadığı sürece bireyler ihtiyaç duydukları ürünleri veya hizmetleri daha sonra talep edebilirler. Ancak sağlık hizmetlerinde, sağlık sorunları acil bir şekilde çözüm gerektirir ve ertelenemez (Ateş, 2020).

- Sağlık Hizmetlerinin Boyutunu Ve Kapsamını Hizmetten Yararlanan Değil, Hekimin Belirlemesi: Sağlık hizmeti alırken birey, hekimin bilgi ve deneyimine güvenmek zorundadır. Hekim-hasta ilişkisi, diğer hizmet türlerinden farklıdır, çünkü bilgi ve karar alma süreci genellikle hekimdedir (Sayım, 2015).

- Sağlık Hizmetleri Tüketicilerinin Davranışlarının İrrasyonel Olması: Sağlık hizmetlerini diğer hizmetlerden ayıran temel bir özellik, tüketicilerin diğer hizmetlerden faydalandıklarında akılcı davranırken, sağlık hizmetlerinde ise hizmetten yararlanan kişilerin iradelerinin dışında gerçekleşmesidir. Diğer hizmet piyasaları gibi sağlık hizmetlerinde tüketicinin üstünlüğü söz konusu değildir (Tengilimoğlu, Işık, ve Akbolat, 2017).

- Hizmetten Sağlanan Doyum Ve Kaliteyi Önceden Belirlemenin Daha Zor Olması: Sağlık hizmetinde kalite ve doyumun ölçülebilmesi neredeyse imkansız

gibidir. Çünkü bireyler diğer hizmet sektörlerinden elde ettikleri doyumu ölçebilmekte ve kaliteli hizmet alımını hissedebilmektedirler. Oysa sağlık hizmetinde böyle bir durum mümkün değildir.

- Sağlık Hizmetlerinin Bir Bölümünün Toplumsal Nitelik Ve Kamu Malı Özelliği Taşınması: Dünyadaki hemen hemen tüm toplumlarda sağlık politikaları devletler tarafından oluşturulmaktadır. Sağlık hizmeti bireylerin kolay erişebileceği ve uygulanabilirliği gibi faktörler göz önüne alınarak planlanmalıdır (Mutlu, 2006).

- Sağlık Hizmetlerinin Çıktısının Paraya Çevrilememesi: Sağlık hizmetinde belirli somut ölçülerin olmaması, hizmette ortaya çıkacak sonuçların paraya çevrilememesine neden olmaktadır. Örneğin; salgında meydana gelen problemlerin önlenmesi amacıyla yapılan harcamaların diğer hizmet piyasalarındaki gibi maliyetlerin hesaplanması söz konusu değildir.

1.1.4. Sağlık Hizmetlerinin Etkili Kullanımı

Sağlık hizmetleri, devlet ve özel sektörün katılımıyla sunulur. Devletin sağlık hizmetine katkısı genellikle daha fazladır. Sağlık hizmetlerinin sunumu yönetimlerin etkisi altındadır ve ayrılan bütçenin etkili kullanımı önemlidir. Sağlık sistemi, toplumsal yapı içinde önemli bir rol oynar ve bütçenin verimli kullanılması gereklidir. Sağlık hizmetleri, bütünsel bir yaklaşımla sunulmalı ve kolay erişilebilirlik, süreklilik, kalite ve verimlilik gibi özelliklere sahip olmalıdır (Kavuncubası, 2010).

- Kolay Kullanılabilirlik: Bireyler ihtiyaç duydukları hizmetlere kendilerine yakın yerlerde ve uygun zamanlarda sağlık hizmetlerine kolay erişebilmelidirler. Sağlık hizmeti sunanlar açısından bakıldığında ise sağlık çalışanlarının hizmeti sunarken gerekli olan araç-gereç vb. unsurlara kolay erişebilme ve kullanabilmeyi ifade eder.

- Kalite: Kalite, sunulan hizmetlerin amaçlara uygun, bireylerin istek ve ihtiyaçlarına cevap verelebilmesiyle ilgilidir. Sağlık hizmeti sunucularının yeterli mesleki bilgi ve deneyime sahip olması, sağlık kuruluşlarının yeterli düzeyde olması, sağlık kuruluşlarında gerekli araç- gereç bulundurulması, bireylerin ve toplumların istek ve ihtiyaçlarının göz önüne alınarak sağlık hizmetinin oluşturulması kaliteyle ilgilidir.

- Süreklilik: Sağlık hizmeti, sadece bireylerin tedavi edilmesiyle ilgili değildir. Sağlık hizmeti hastalığın belirlenmesinden hastalığın tedavi edilmesi ve toplumsal düzeyde daha iyi bir sağlık hizmetinin belirlenmesi gibi birçok aşamayı içinde barındıran bir

süreçtir. Bu yüzden sağlık hizmetinde sürekliliği sağlayabilmek bireylere odaklanmış bakım hizmetleri, eşgüdümleyici birimlerin koordinasyonu ve eşgüdümlemiş hizmetlerin entegrasyonu ile mümkün olabilmektedir.

- **Verimlilik:** Sağlık hizmetlerine ayrılan bütçenin uygun ve yerinde kullanılması verimliliği ifade etmektedir. Sağlık hizmetlerinin verimli kullanılmasıyla sağlık harcamaları düşerek daha fazla bireye daha iyi hizmet edebilme olanağı oluşmaktadır.


1.1.5. Sağlık Hizmetine Erişim Sorunları

Sağlık hizmetlerine kolay, eşit, ücretsiz ve nitelikli şekilde erişim sağlanmalıdır. Sağlık sistemi, sağlık ihtiyaçlarına uygun olarak düzenlenmeli ve uygulanmalıdır. Eşit sağlık hizmeti, yeterli teknoloji ve kaynaklarla desteklenmelidir. Sağlık hizmetlerine erişimi engelleyen faktörler arasında yeterlilik, zamanlama, fiziksel altyapı gibi engeller bulunmaktadır (Gözlü ve Tatlıdil, 2015):

- Tedavide kullanılan tıbbi ürünlerin eksikliği veya ürünlerin kalitesizliği,
- Yeterli bilgi ve tecrübeye sahip olmayan personel,
- Hastaların mevcut sağlık hizmetine olan güvensizliği,
- Yönetimde iletişim eksikliği, eksik veri ve bilgi vb. nedenler,
- Sağlık hizmetlerinde uygun ve tutarlı olmayan bir dizi hizmet kullanımı,
- Genel sağlık hizmetleri politikalarında başarısızlıklar,
- Sağlık hizmetinde planlama, uygulama ve kontrol mekanizmasının eksikliği.

1.1.6. Sağlık Hizmetlerinin Sınıflandırılması

Sağlık hizmetleri, sağlık politikasının oluşturulmasından başlayarak, hizmet sunumu, sağlık sorunlarının çözülmesi ve sağlık sistemlerinin geliştirilmesi gibi bir dizi aşamayı kapsamaktadır. Sağlık hizmetlerinin toplumsal yapı içinde etkin işlemesi için bu hizmetlerin sınıflandırılması önemlidir. Sağlık hizmetlerinin temel amacı, bireylerin sağlığına etki eden hizmetlerin sunulmasıdır. Sağlık hizmetleri, koruyucu sağlık hizmetleri, tedavi edici sağlık hizmetleri, rehabilitasyon hizmetleri ve sağlığın geliştirilmesi olmak üzere dört ana başlık altında sınıflandırılmaktadır (Fişek, 1983; Kavuncubaşı, 2010).



Şekil 1. 1. Sağlık Hizmetleri ve Sağlık Kurumları

1.1.6.1. Koruyucu Sağlık Hizmetleri

Koruyucu sağlık hizmetleri, bir ülkenin gelişmişlik düzeyiyle doğrudan ilişkilidir. Türkiye'deki sağlık ocakları sistemi, bu tür hizmetlerin örneklerindendir. Gelişmiş ülkelerde etkili bir şekilde planlandığında, koruyucu sağlık hizmetleri birçok sağlık sorununun çözümüne katkı sağlamaktadır (Somunoğlu, 1999). Koruyucu sağlık hizmetleri kolay erişilebilirlikleriyle öne çıkmakta ve bireylerin sağlığını iyileştirmenin yanı sıra toplumun genel sağlık düzeyini yükseltmeyi amaçlamaktadırlar. Aile planlaması, anne ve çocuk sağlığı, kitlesel hastalıkların önlenmesi ve sağlıklı gıda denetimi gibi alanlarda etkili çözümler sunarlar (Öztek, 2003). Koruyucu sağlık hizmetleri, hastalıkların önlenmesi ve tedavi süreçlerini içermektedir. Koruyucu sağlık hizmetleri genellikle devlet tarafından yürütülür, çünkü toplumun genel sağlığını etkilemektedirler. Ayrıca, uluslararası boyutta salgın hastalıkların yayılma riski de göz önünde bulundurulmalıdır (Gürsoy, 2013).

Sağlık hizmetlerinin ilk aşaması olan koruyucu sağlık hizmetleri, kişiye ve çevreye yönelik olarak iki ana kategoride ele alınmaktadır.

- Yönelik Koruyucu Sağlık Hizmetleri: Sağlık sağlayıcıları tarafından direkt birey sağlığına yönelen, bireylerin ve bununla beraber toplumun sağlık sorunlarını ortadan

kaldırmayı amaçlayan, bireyi herhangi bir hastalığa karşı güçlü kılarak hastalıklardan etkilenmelerini engelleyen, hastalıklara yakalandıkları zaman hastalığının belirlenerek en uygun tedavi yöntemiyle sağlıklı hale gelmelerini sağlayan çabalar bu hizmetin konusudur (Arslantaş, 2013).

- **Çevreye Yönelik Koruyucu Sağlık Hizmetleri:** Günümüzde bir çok hastalığın ortaya çıkması çevresel faktörlerden dolayı meydana gelmektedir. Sanayileşmenin gelişmesiyle, birey sağlığını etkileyen fiziksel, biyolojik ve kimyasal birçok faktör ortaya çıkmıştır. Çevre koşullarının olumsuz etkisini ortadan kaldırarak hastalıkların meydana gelmesini engelleme ve bu olumsuz çevre koşullarını olumlu hale getirme çabalarının bütünü bu hizmetlerin kapsamına girmektedir (Arslantaş, 2013).

1.1.6.2. Tedavi Edici Sağlık Hizmetleri

Hastalığın tanımlanması, tedavi edilmesi ve yönetilmesini kapsayan önemli bir sağlık hizmeti aşamasıdır. Tedavi edici sağlık hizmetleri, bireylerin sağlık sorunlarına yanıt verirken kritik bir rol oynamakta ve hastalıkla mücadelede temel bir rol üstlenmektedir. Uygun tedavi yöntemleri uygulanarak hastalığın yönetilmesi ve kontrol altına alınması hedeflenmektedir. Buradaki hizmetler, hastaların iyileşme sürecini desteklerken aynı zamanda yaşam kalitesini artırmayı amaçlamaktadır. Bireylerin sağlık durumunu iyileştirerek toplumun daha sağlıklı ve aktif bir yaşam sürmesine katkı sağlamaktadır (Yüksel ve Arıkan, 2018).

-**Birinci Basamak Tedavi Hizmetleri:** Hastalığın ilk aşamasında kişilerin, sağlık kuruluşlarında veya evde tedavi ve teşhislerinin yapıldığı hizmetleri kapsar. Herhangi bir sağlık kurum veya kuruluşunda yatış olmadan ayakta tedavi edilme aşamasıdır. Birinci basamak sağlık hizmetleri tüm ülkeler açısından oldukça önemli yere sahiptir. Bundan dolayı tüm ülkelerin sağlık sistemlerini oluştururken sistemlerini birinci basamak sağlık hizmetleri üzerine inşa etmeleri gerekmektedir (Başer vd., 2015). Birinci basamak tedavi hizmetleri, sonraki ikinci ve üçüncü basamaktaki hizmetlerde meydana gelebilecek hasta mağduriyetlerinin, kuyrukların ve yığılmaların önüne geçebilmesi açısından önemli bir yere sahiptir (Öcek ve Soyer, 2007). Aile Sağlık ve Toplum Sağlığı Merkezleri bu hizmetlere örnek verilebilir.

-**İkinci Basamak Tedavi Hizmetleri:** Özel ve devlet kuruluşları tarafından çoğunlukla yataklı tedavi olarak verilen hizmetleri kapsamaktadır. Birinci basamak tedavi hizmetlerinde çözülemeyen sorunların, daha kapsamlı tedavi gerektirecek

hastalıkların veya yatarak tedavi gerektirecek hastalıkların giderilmesi için bu kuruluşlara başvurulur. Buradaki kuruluşlar birinci basamak tedavi hizmetlerindeki kuruluşlardan daha gelişmiş ve daha donanımlıdır. Şehir merkezleri ve ilçelerde bulunan devlet veya özel hastahaneler bu kuruluşlara örnektir (Durusoy, 2011).

-Üçüncü Basamak Tedavi Hizmetleri: Çoğunlukla yataklı tedavi yapan, belli bir alanda uzmanlaşmış ve odaklandıkları branşlara göre hizmet veren kuruluşlardır. Birinci ve ikinci basamak tedavi hizmetlerine göre daha gelişmiş teknoloji ve donanıma sahiptirler. Buradaki sağlık sağlayıcıları bilgi ve tecrübe ve eğitim açısından daha birikimlidirler. Devlet veya özel teşebbüslü Eğitim ve Araştırma Hastaneleri, Üniversite Hastaneleri, Kalp ve damar, nöroloji göz vb. dal hastaneleri 3. Basamak sağlık kuruluşlarına örnektir.

1.1.6.3. Rehabilitasyon Hizmetleri

Rehabilitasyon hizmetleri, sağlık sisteminde önemli bir yer tutar ve bireylerdeki sağlık sorunlarının tamamen giderilemediği durumlarda devreye girer. Örneğin, bir kaza sonrasında felçli kalan bir hastanın tedavi süreci rehabilitasyon hizmetlerini gerektirir. Buradaki hizmetlerin temel amacı, kalıcı sağlık sorunlarının etkisini en aza indirmek ve bireylerin sosyal hayatlarına yeniden adapte olmalarını sağlamaktır. Uzun süreç ve çaba gerektiren rehabilitasyon hizmetlerinde, iyi organize edilmiş bir sistem, nitelikli personel ve etkili örgütlenme önemlidir. Rehabilitasyon hizmetleri, tıbbi ve sosyal rehabilitasyon olmak üzere iki kategoride incelenmektedir (Yüksel vd., 2018).

-Tıbbi Rehabilitasyon: Kişilerde meydana gelen hastalıkların tedavi edilmesinden sonraki süreçteki kalıcı hasarların tıbbi yöntemler ile etkisinin en aza indirilmesi veya kişide meydana gelen herhangi bir organ kaybının görevini yerine getirecek yapay yöntemlerin kullanılması tıbbi rehabilitasyon hizmetlerini kapsamaktadır.

-Sosyal Rehabilitasyon: Kişilerde meydana gelen kalıcı sağlık problemleri, kişilerin sosyal yaşamlarını sürdürebilmelerini güçleştirmektedir. Bireyler günlük işlerini iyi biçimde yerine getirememektedir. Bu hizmetler kişilerin sosyal hayat içerisinde yaşamlarını sürdürebilmeleri açısından oldukça önemlidir.

1.2. Sağlık Sistemleri Modelleri

Sağlık hizmetlerinin kalitesi ve erişilebilirliği, gelir seviyesiyle doğrudan ilişkilidir. Ülkelerin kalkınma düzeyi, bireylerin yaşam kalitesini artırma ve sağlıklı yaşam sürdürebilme becerisine bağlı olarak değerlendirilmektedir. Dolayısıyla, toplumsal düzenin gelişimine katkı sağlamak için sağlık hizmetlerine yapılan yatırımlar ve politikalar büyük önem taşımaktadır (Tüylüoğlu ve Tekin, 2009). Sağlık harcamaları, bir ülkenin sağlık hizmetlerinin değerlendirilmesinde kritik bir role sahiptir. Gelişmiş ülkeler genellikle daha yüksek sağlık harcamalarına sahip olup yapılan harcamalar, toplumun sağlık bilinci ve teknolojinin ilerlemesi gibi faktörlerden kaynaklanmaktadır. Ancak, artan harcamaların her zaman olumlu sonuçları olmayabilir. Doğru ve etkili yatırımların yapılması, sağlık hizmetlerine yapılan harcamaların yönetilmesi ve sürdürülebilirliği önemlidir (Kılavuz, 2010).

Sağlık hizmetlerine yapılan yatırımların, ülke kaynaklarını zorlayıcı bir şekilde etkileyerek diğer sektörlerde yapılan yatırımları kısıtlaması olumsuz sonuçlara neden olabilir. Sağlık hizmet harcamalarının değerlendirilmesinde iki temel ölçüt kullanılmaktadır. Birincisi, sağlık hizmet harcamalarının Gayri Safi Milli Hasıla (GSMH) içindeki oranıdır. İkinci ölçüt ise sağlık hizmet harcamalarının diğer sektörleri ne derecede etkilediğidir. Ayrıca, kaynakların sektör içinde hangi hizmetlere ayrıldığı da göz önünde bulundurulur. Ulusal ve uluslararası değerlendirmelerde genellikle bu ölçütler kullanılmaktadır (Akdur, 2008).

Sağlık sistemi, sağlık hizmetlerinin belirlenmesi, uygulanması, denetlenmesi ve finansmanı gibi önemli süreçleri içerir. Sağlık hizmetleri, bireylerin ve toplumun genel sağlığını etkiler ve toplumsal düzeni şekillendirir. Dolayısıyla, sağlık hizmetleri devlet kontrolünde olmalı ve herkesin erişimine açık olmalıdır. Sağlık sigortası, kişilerin gelecekteki sağlık masraflarını karşılamak için önceden tedbir almayı sağlar. Devlet veya özel kuruluşlar tarafından sunulan sağlık sigortası, vatandaşların sağlık hizmetlerine erişimini kolaylaştırır ve koruyucu bir rol oynar.

Her ülke vatandaşlarına sağlık hizmeti sunarken belirli bir bütçeye ihtiyaç duymaktadır. Sağlık hizmetlerine ayrılan bütçenin miktarı sağlık hizmet kalitesine etki etmektedir. Gelişmiş ekonomilere sahip ülkelerin sağlık hizmetlerine ayıracakları kaynakların yüksek olması sağlık hizmetlerinin de kaliteli olmasına katkı sağlamaktadır. Sağlık hizmetlerinde gelişen teknolojiyle birlikte yeni teknolojinin

kullanılabilmesi için finansman kaynaklarına ihtiyaç duyulmaktadır. Bu nedenle varlık ve sağlık arasında önemli bir bağlantı vardır. Etkin ve verimli bir sağlık sistemi ancak yeterli kaynaklarla mümkündür (Dağdemir, 2009).

Dünyadaki birçok ülke sağlık hizmetlerinin sunulmasında farklı sağlık sistemleri kurmuşlardır. Devletler sağlık sistemlerini kurarken bireylerin sağlık sorunlarına çözüm üretme, yeterli düzeyde sağlık hizmeti sunma, bu hizmetleri sunarken gerekli kişi ve kuruluşları sağlama ve bu hizmetlerin sunulmasında ortaya çıkacak ekonomik harcamaları kontrol etme amacı gütmektedirler. Ülkelerin sağlık hizmetlerindeki temel amaçları bireylere en doğru ve uygun hizmeti vermektir. Bu amaç doğrultusunda kurulacak sağlık sisteminin hukuki, ekonomik, sosyal ve politik gibi birçok faktörün göz önüne alınarak dizayn edilmesi oldukça önemlidir (Culyer ve Newhouse, 2000). Dünyada birçok sağlık modeli geliştirilmiştir. kullanılan modeller başlıklar halinde aşağıda açıklanmıştır.

1.2.1. Beveridge Modeli (Ulusal Sağlık Hizmeti)

William Beveridge tarafından tasarlanan ve kamu sağlık modeli olarak bilinen sistem, tüm sağlık hizmetlerinin finansmanının kamu tarafından karşılandığı bir yaklaşımı ifade eder. Bu modelde, sağlık hizmeti, diğer temel kamu hizmetleri gibi devletin sorumluluğu altındadır. Örnek olarak İngiltere, bu sistemin başarılı bir örneğini sunmaktadır. Devletin belirlediği finansman kaynaklarıyla, hem devlet hem de özel sağlık hizmeti sağlayıcılarına eşit şekilde destek sağlanır. Devlet kontrolü altındaki bu sistem, sağlık hizmetlerinin maliyetlerini düşürmekte ve etkin bir denetim imkanı sunmaktadır (Daştan, 2015).

Ulusal sağlık modeli, sağlık hizmetlerinin finansmanının kamu kaynaklarıyla karşılandığı bir yaklaşımı temsil eder. Bu modelde, sigorta kuruluşlarının birleştirilmesi amaçlanır ve sağlık hizmetlerinin finansmanı genellikle vergilere dayanır. Sağlık hizmetlerinden faydalananlar sadece prim ödeyen kişiler değil, ülkedeki tüm bireylerdir ve finansman yükünün tüm halk tarafından karşılanması hedeflenir. Sağlık hizmetlerine erişim basittir ve sağlık hizmetleri güvenlik, ulaşım, çevrecilik gibi diğer kamu hizmetleriyle aynı kategoride değerlendirilir. Dünyada en yaygın olarak uygulanan sağlık hizmeti finansman modelidir ve İngiltere, İskoçya, İspanya, Yeni Zelanda ve İskandinav ülkeleri gibi birçok ülke tarafından benimsenmiştir (Immergut, 1992).

1.2.2. Bismarck Modeli

Otto Von Bismarck tarafından 1881'de, Doğu ve Batı Almanya'nın birleşmesinin ardından kurulmuştur. Bu modelde, sağlık hizmetlerinin finansmanı işverenler ve işçilerin maaşlarından kesilen kaynaklarla sağlanır. Önemli olan nokta, sağlık hizmetlerinden sadece işveren ve işçilerin değil, ülkedeki tüm vatandaşların yararlandığı bir sistem olmasıdır. Kar amacı güdülmeyen bu model, birçok gelişmiş ve gelişmekte olan ülke tarafından benimsenmiştir. Almanya, Hollanda, Belçika, Fransa, Japonya, İsviçre ve bazı Güney Amerika ülkeleri bu modeli kullanmaktadır (Barnighausen ve Sauerborn, 2002).

Model, başlangıçta işçilerin korunmasını hedefleyerek oluşturulmuştur. Bu model, sosyalist akımlara karşı mücadele ederek işçilerin sağlık hizmet ihtiyaçlarını karşılamayı ve ülkenin refahını artırmayı amaçlamıştır. Zamanla, sadece işçileri değil, diğer grupları da kapsayacak şekilde genişlemiştir. Sisteme katılımın zorunlu hale getirilmesiyle, ülkedeki tüm vatandaşların çıkarları gözetilmiştir. Model, zamanla gelişerek günümüze kadar gelmiştir. Temel özellikleri arasında, sağlık hizmetlerinin hizmet başına ödenmesi, devlet ve özel sağlık hizmet teşebbüslerinin birlikte yer alması, sağlık harcamalarının çoğunlukla primlerden oluşması, sağlık hizmetlerinin devlet tarafından organize edilmesi ancak devlet tarafından işletilmemesi ve sağlık harcamalarının finansmanının işçilere ve işverenlere yüklenmesi bulunmaktadır (Özmen, 2017).

Bu modelde, Beveridge modeline göre bireylerin sağlık sağlayıcılarına ulaşımı daha basit ve kolaydır. Ülkedeki sigorta kuruluşları, sağlık hizmet kuruluşlarıyla toplu sözleşme yaparak kişiler adına hizmet alımı yapmaktadır. Bu model sürekli değişerek ve gelişerek kendini güncellemektedir. Beveridge ve Bismarck modelinin karşılaştırılması aşağıdaki Tablo 1.1.'de verilmiştir (Öztürk ve Karakaş, 2015; Lamerie vd., 1999).

Ulusal Sağlık Sistemi/Beveridge	Sosyal Sağlık Sistemi/Bismarck
Fonların finansmanı genel vergilerle	Fonlar çoğunlukla katkılar yoluyla finanse edilir
Sağlık hizmetleri evrensel kapsamdadır	Sağlık sigorta fonları yoluyla, meslek grupları başına fonlama, bölge ayrımına göre veya politik gruplara göre kapsam

Kamusal Altyapı	Kamu ve özel olarak Karma Altyapı
Sağlık sağlayıcıları maaşlı olarak çalışır	Hizmet başına ödeme
Önemli seviyede devletin müdahalesi	Organizasyon devlet tarafından yapılır ama devlet tarafından işletilmez
Sağlık hizmetleri merkezi olarak planlanır	Kompleks yapılar mevcuttur, birçok sayıda kuruluş vardır
İngiltere, İspanya, İtalya, İrlanda, Portekiz, İsveç Fillandiya gibi ülkelerde uygulanır	Almanya, Hollanda, Fransa, Belçika Lüksemburg gibi ülkelerde uygulanır

Tablo 1. 1. Sağlık Sistemlerinde Temel İki Model

1.2.3. Karma Model

Bismarck (sosyal sağlık sistemi) ve Beveridge (ulusal sağlık sistemi) dünyada bir çoğu ülkede benimsenip kullanılmaktadır. Zamanla ortaya çıkan ihtiyaçlar nedeniyle değişime uğrayarak ve gelişerek günümüze kadar gelmişlerdir. Genellikle bir tek modelin kullanımı yeterli olmamıştır. Bu yüzden her ülke kullandığı modele ek özellikler getirerek kullanmıştır. Her iki modelinde bazı özelliklerinden oluşan karma model kullanılmıştır. Örnek verecek olursak; bir ülkeden sağlık hizmet finansmanı primler yoluyla karşılanırken aynı zamanda devlet katkısıyla da karşılanabilmektedir. Bazı ülkelerde sağlık hizmetlerinin yönetimi merkezi yönetim yoluyla karşılanmakta ve aynı zamanda hizmet yönetimi için kuruluşlarda oluşturulabilir (Özmen, 2017).

1.2.4. Ulusal Sağlık Sigortası Modeli

Bismarck ve Beveridge modelinin bazı özelliklerini içerisinde bulunduran, karma modele birçok yönüyle benzeyen, hatta bazı kaynaklarda karma model olarak adlandırılan sağlık sigortası modelidir. Bu sağlık sisteminde devlet müdahalesi söz konusudur. sistemin işletilmesi devlet yoluyla olur, vergilerle ve primlerle finansa edilir. Sistem temel olarak kar amacı gütmeyen ve bireylerin çıkarlarına yönelik hizmet sunumu söz konusudur. Bu açıdan bakıldığında fonlar tek kaynaktan karşılandığı için önceki sistemlere göre organize edilmesi, yönetilmesi, uygulanması, denetimi ve kontrolü daha basit ve kolaydır. İyi organize edildiği ve yönetildiği takdirde maliyetlerin düşmesiyle beraber diğer modellere göre daha ucuz bir sistem olabilmektedir. Kanada bu modeli kullanan ülkelerin başında gelmektedir. Tayland ve

Güney Kore gibi gelişmekte olan ülkeler tarafından kullanılan bir modeldir (Woolhandler vd., 2003).

1.2.5. Cepten Ödeme Modeli

Dünyada birçok ülke tarafından kullanılan bir sistemdir. Bu model genellikle gelişmemiş ve sağlık hizmetleri bakımından iyi organize edilmemiş ülkeler tarafından kullanılır. Bu sistemde sağlık hizmetinin alınabilmesi ancak ödeme yoluyla gerçekleşmektedir. Ülkedeki vatandaşların yaptıkları bu ödemelerle gerekli mali kaynağın toplanmasıyla sistemin işlemesi, yönetilmesi ve denetimi sağlanmaktadır. Bu modelde ödemeler doğrudan sağlık hizmet sağlayıcılarına hizmetlerin alındıkları yerlerde yapılmaktadır. Ödemesini yapmayan hastalar sağlık hizmetinden yararlanmakta bu yüzden kalıcı sağlık problemlerine maruz kalmakta hatta ölebilmektedirler. Hindistan, Çin, birçok Afrika ülkesi ve bazı Güney Amerika ülkeleri dünyada bu sistemin kullanıldığı ülkelere örnektir (Lameire vd., 1999).

1.2.6. ABD Modeli

ABD sağlık sistemi, dört ana modelin özelliklerini bir araya getiren bir karma modele sahiptir. Örneğin, yaşlılara yönelik sağlık hizmetlerinde ulusal sağlık modeli kullanılırken, gazilere ve ailelerine hizmet sunumunda Beveridge modeli benzeri bir yaklaşım benimsenir. Çalışanlara yönelik hizmet sunumunda ise Bismarck modeline benzer özellikler bulunur. Ülkedeki nüfusun çoğunluğunun sağlık sigortası olmaması nedeniyle sağlık hizmetlerinin ödeme yoluyla alınması, cepten ödeme modeline benzer bir sistem oluşturur. ABD'deki sağlık sistemi eyaletlere göre farklılık gösterir, burada temel bir sağlık hizmetinden bahsetmek mümkün değildir. Bu modelde bireyler, doktor ve hastane seçme özgürlüğüne sahiptir. Düşük gelir seviyesine sahip bireyler için Medicaid ve yaşlılar için Medicare gibi kamu kurumları, özel sağlık sigortası yaptıramayan bireylerin sağlık hizmetlerine erişimini sağlamak amacıyla kurulmuştur. ABD bilindiği gibi ekonomik açıdan yüksek potansiyele sahip, teknoloji bakımından gelişmiş bir teknolojiye sahip ülkedir. Bununla beraber kişi başına sağlık harcaması yüksek olan bir ülkedir. Buna rağmen sağlık sistemi konusunda problemlere sahip bir ülkedir. Gelişmiş ülkeler arasında sağlık hizmet performansına göre gerilerde kalmaktadır (Steinbrook, 2012).

1.2.7. Türkiye Modeli (Genel Sağlık Sigortası)

Türkiye'de kullanılan sağlık modeli, kamu hizmeti olarak sunulan ve devletin sorumluluğunda olan bir sistemdir. Sağlık hizmetlerinin uygulanması, yönetilmesi ve denetlenmesi, Sağlık Bakanlığı tarafından yürütülmektedir. Ülke genelinde sağlık hizmeti sağlayıcıları arasında, devlete ait sağlık kuruluşları, özel hastaneler, üniversite hastaneleri, kamu ve özel sektöre ait poliklinikler bulunmaktadır. Sağlık hizmetlerinin finansmanı, vergiler, sosyal güvenlik primleri, özel sağlık sigortaları ve bireylerin kendi ceplerinden yaptıkları ödemelerle sağlanmaktadır. Sağlık hizmetlerine erişimde genel olarak bir kamu sağlık sigortası sistemi kullanılmakta olup, vatandaşlar bu sistem aracılığıyla sağlık hizmetlerinden yararlanmaktadırlar (Pekten, 2006).

1.2.8. Ülkelerin Sağlık Sistemlerinin İşgücü Açısından Karşılaştırılması

Tarihsel süreçte sağlık kavramına baktığımızda tüm toplumlar açısından çok önemli bir kavram olarak karşımıza çıkmıştır. Sağlık hizmetleri var olduğu tarihte toplumsal yapı içerisinde hep bir sistem olarak bulunmaktadır. Sağlık hizmetlerinin gelişimi beraberinde ekonomik ve sosyal yüküde getirmiştir (Kahraman ve Bolışık, 2014). Ülkeler bütçelerinin önemli bir kısmını sağlık hizmetlerine ayırmışlardır. Zamanla gerçekleşen ekonomik büyüme ile bireylerin gelir artışı, sağlık hizmetlerine olan talebi de arttırmıştır. Teknolojik gelişim, sağlık hizmetlerinde kullanılan teknolojinin ilerlemesine katkı sağlamış ancak yeni teknolojinin maliyetlerini artırmıştır (Mendelson ve Schwartz, 1993).

Her ne kadar sağlık hizmetlerinde ekonomik kaynaklar önemli olsada insan işgücünün yeri de en az ekonomik kaynaklar kadar önemlidir. Çünkü sağlık hizmeti sağlayıcılarının büyük bir bölümünü insan unsuru oluşturur. Bir ülkedeki sağlık hizmetlerinin etkin ve verimli bir şekilde uygulanması ve sağlık hizmetlerinin yüksek kalitede olabilmesi ancak insan faktörüyle olabilmektedir. Sağlık hizmetlerinde insan emeğinin etkili ve verimli bir şekilde kullanılması, iyi bir şekilde planlanmış insan kaynaklarıyla gerçekleşir. Sağlık sisteminde, yeterli sayıda sağlık personeli ihtiyacı, vasıflı işgücü, bu işgücünün dengeli dağılımı, planlaması ve kontrolü gibi konular önemli yer tutmaktadır (Hongoro ve McPake, 2004).

Gelişmiş ülkelerde sağlık hizmetlerine erişim, gelişmemiş ülkelere kıyasla genellikle daha kolaydır ve sağlık sistemleri daha etkin bir şekilde çalışır. Bu ülkelerdeki vasıflı sağlık personeli sayısı oldukça yüksektir ve sağlık hizmetlerine

ulaşmak daha basittir (Çelik, 2014). Örneğin, yüksek gelirli ülkelerde sağlık personeli sayısı oldukça yüksektir ve bu ülkeler genellikle sağlık hizmetlerinde başarıyla sıralanırlar. Ancak, düşük ve orta-alt gelir seviyesindeki ülkelerde sağlık personeli ve kuruluşlarının yetersizliği nedeniyle sağlık hizmetlerine ulaşmak daha zordur. Sonuç olarak ülkelerdeki insanların sağlık hizmetlerine erişimini olumsuz yönde etkileyebilmektedir.

	Ülkeler	Gelir Grubu	10.000 Kişiye Düşen İstihdam Sayısı
1	Norveç	Yüksek	1049
2	Danimarka	Yüksek	901
3	Japonya	Yüksek	860
4	Hollanda	Yüksek	858
5	İsviçre	Yüksek	801
6	Finlandiya	Yüksek	769
7	İsveç	Yüksek	745
8	Avusturalya	Yüksek	711
9	Kanada	Yüksek	703
10	Abd	Yüksek	682
11	İzlanda	Yüksek	677
12	Almanya	Yüksek	669
13	İngiltere	Yüksek	664
14	Yeni Zelanda	Yüksek	663
15	Belçika	Yüksek	630
16	Fransa	Yüksek	619
17	İrlanda	Yüksek	590
18	İsrail	Yüksek	558
19	Avusturya	Yüksek	531
20	Lüksemburg	Yüksek	519
21	Türkiye	Üst-Orta	173

Tablo 1. 2. 10000 Kişiye Düşen Sağlık Çalışanları Sayısı En İyi İlk 20

Tablo 1.2' ye bakıldığında, yüksek gelir grubundaki ülkelerin genellikle 10.000 kişiye düşen sağlık çalışanı sayılarının oldukça yüksek olduğu görülmektedir. Norveç,

Danimarka, Japonya ve diğer yüksek gelirli ülkeler, sağlık hizmetlerine ulaşımı kolaylaştıran yüksek sağlık çalışanı sayılarına sahiptir. Ancak, Türkiye gibi üst-orta gelir grubundaki ülkelerde bu sayılar daha düşüktür. Bu durum, sağlık hizmetlerine erişimdeki farklılıkları göstermektedir. Yüksek gelirli ülkelerde daha fazla sağlık personeli bulunması, sağlık hizmetlerine ulaşımın daha etkin ve kolay olmasını sağlamaktadır (İLO, 2020).

	Ülkeler	Gelir Grubu	10.000 Kişiye Düşen İstihdam Sayısı
1	Vanuatu	Alt-Orta	9
2	Mali	Düşük	12
3	Malawi	Düşük	16
4	Papuayenigine	Alt-Orta	16
5	Nijerya	Düşük	19
6	Gambia	Düşük	24
7	Lao Demokratik Halk	Alt-Orta	24
8	Burkina Faso	Düşük	28
9	Sierra Leone	Düşük	29
10	Yemen	Düşük	29
11	Madagaskar	Düşük	30
12	Miyanmar	Alt-Orta	30
13	Bahreyn	Yüksek	31
14	Uganda	Düşük	31
15	Morokko	Alt-Orta	32
16	Bangladeş	Alt-Orta	34
17	Kamboçya	Alt-Orta	35
18	Zimbabve	Düşük	35
19	Kongo	Düşük	37
20	Etiyopya	Düşük	37

Tablo 1. 3. 10000 Kişiye Düşen Sağlık Çalışanları Sayısı En Kötü İlk 20

Tablo 1.3'e bakıldığında, düşük ve alt-orta gelir grubundaki ülkelerin 10.000 kişiye düşen sağlık çalışanı sayılarının oldukça düşük olduğu görülmektedir. Özellikle Mali, Malawi, Nijerya gibi düşük gelirli ülkelerde bu sayılar oldukça azdır. Bu durum, bu ülkelerde sağlık hizmetlerine erişimin zorluğunu ve sınırlılığını göstermektedir. Sağlık hizmetlerinin yetersiz olduğu ve sağlık personelinin azlığı, sağlık hizmetlerine ulaşımı ve kalitesini olumsuz etkileyebilir. Bu ülkelerde sağlık hizmetlerinin iyileştirilmesi ve sağlık personeli sayısının artırılması önemlidir. Bu, toplumun sağlık durumunun ve yaşam kalitesinin artırılmasına katkı sağlayabilmektedir (İLO, 2020).

1.3. Türkiyede Sağlık Sisteminin Tarihçesi

Ülkemizdeki sağlık sistemlerinin gelişimi, Selçuklu ve Osmanlı dönemlerine kadar uzanmaktadır. Bu dönemlerde tıbbi hizmetlerin organize edilmesinde belirli bir süreklilik bulunmuş, ancak sağlık hizmetleri 19. yüzyılın sonlarına kadar devletin ana sorumluluğu olarak kabul edilmemiştir. Bu süreçte sağlık hizmetleri genellikle saray erkanına ve ordu mensuplarına yönelik olmuştur. Cumhuriyet dönemiyle birlikte sağlık sistemleri yapılanması başlamış, dünyadaki sağlık alanındaki ilerlemelere paralel olarak sağlık hizmeti politikalarının oluşturulması ve örgütlenmesi önem kazanmıştır (Akdur, 1999).

Cumhuriyetin kuruluşuyla beraber sağlık kavramına önem verilmeye başlanmış ve sağlık bakanlığı kurulmuştur. Bu dönemden sonra sağlık sisteminin kurumsallaştırılması, ve sağlık hizmetlerinin yaygınlaştırılması hızlanmıştır. Sağlık sistemini değiştirilmesi ve geliştirilmesi çabaları devletin temel konularından biri haline gelmeye başlamıştır. Zamanla dünyada ortaya çıkan sosyal devlet, refah devlet gibi kavramlarla birlikte sağlık hizmetlerinin tüm halkı kapsayıcı ve bu hizmetlerin devlet garantisine alınmasına neden olmuştur. Sağlık hizmetleri 5 dönemde incelenmiştir (Çavmak ve Çavmak, 2017):

- Anadolu Selçukluları ve 19. Yüzyıla kadar Osmanlı Dönemi,
- Cumhuriyet Dönemine kadar Osmanlı Dönemi,
- Cumhuriyet Dönemi,
- 21. Yüzyıla Kadar Atatürk Sonrası Dönem,
- 21. Yüzyıl Başları.

1.3.1. Anadolu Selçukluları ve 19. Yüzyıla Kadar Osmanlı Dönemi

Geçmişe baktığımızda Anadolu Selçuklular dönemine kadar türklerde herhangi bir sağlık sisteminden bahsetmek mümkün değildir. Anadolu Selçuklulardan sonra ortaya çıkmış ve zamanla gelişen bir sağlık sistemi vardır. Bu dönemde sağlık hizmetleri vakıflar tarafından darüşşifalar aracılığıyla verilmektedir. Hekimlik eğitimi usta-çırak ilişkisine dayanmaktadır. Hekimlerin bağlı olduğu hekim başılık sistemi mevcuttur. Bu sistem Osmanlıda da aynı şekilde devam etmiş ve 19. Yüzyılın ortalarına kadar sürmüştür (Seçim, 1985).

Osmanlı devleti kurulduğunda Anadolu Selçuklu devletinden kalan sağlam bir sağlık sistemi mevcuttur. Ülkenin birçok büyük şehrinde vakıf hastahaneleri(Darüssıhha, Darüşşifa, Bimaristan, Maristan) mavcuttur. Bu kuruluşlar tarafından sağlık hizmeti ülkedeki tüm vatandaşlara hizmet sunmaktadır. Osmanlı devleti kurulduktan sonra bu kuruluşlar geliştirilmiş ve bu kuruluşlara yenileri eklenmiştir. Bu kuruluşlar genellikle devlet eliyle kurulmamış zengin şahıslar, devlet adamları veya oluşturulan yardım birlikleri tarafından halkın faydasına sunulan yardım kuruluşları olarak karşımıza çıkmaktadır. Bu sistem Osmanlı devletinde 380 sene boyunca devam etmiştir (Aydın, 2004).

3. Selim döneminde sağlık alanında köklü değişiklikler yapılmıştır. Ancak 19. Yüzyılın ortalarına kadar Osmanlı imparatorluğuda dahil dünyadaki hiçbir ülkede planlı bir sağlık sistemi yoktur. 1899-1923 yılları arasında asya ve avrupada ortaya çıkan kolera salgınının ortaya çıkardığı korku, ülkelerin sağlık hizmetleri politikalarında bilinçlenmesine ve planlı bir sağlık sistemi oluşturmalarına neden olmuştur. Ortaya çıkan gelişmeler, Osmanlıyı da etkisi altına almış ve sağlık sisteminde düzenlemeler yapmaya yöneltmiştir (Çavdar ve Karcı, 2014). 19. yüzyıla kadar olan dönemdeki Osmanlı sağlık sistemi genel özellikleri itibariyle klasik ve geleneksel bir yapıdadır. Sağlık hizmetleri toplumsal yapıyı kapsayıcı nitelikte değildir. İyi organize edilmiş ve iyi yönetilen bir sağlık sistemi yoktur. Devletin sağlık konusunda teşvikleri yok denecek kadar azdır (Tok, 2008).

1.3.2. 19. Yüzyıldaki Osmanlı'dan Cumhuriyet Dönemine

Halk birçok sağlık sorunuyla karşı karşıya kalmış ve bu sorunlarını çözmek için bilim dışı kişi ve kuruluşlara yönelmeye başlamıştır. Sağlık sistemindeki eksiklikler toplumsal düzende aksaklıklar meydana getirmiştir. Bu dönemde halkın bu sorunlarına

çözüm bulabilmek için sağlık hizmetlerinde düzenlemeye gidilmiştir. Batıdaki sağlık alanındaki gelişmeler Osmanlının sağlık sisteminin değişimine neden olmuştur. Bu dönemde tüm konularda batının gerisinde kalan Osmanlının batıya yönelimi söz konusudur (Fişek, 1983).

Osmanlıda sağlık hizmetleri, 19. Yüzyılın başlarında kurulan belediyeler tarafından sağlanmıştır. Belediyeler halka sağlık hizmeti verebilmek için belediyelerde sağlık örgütü yapılanması kurulmuştur. Sağlık hizmetleri içişleri bakanlığına(Dahiliye Nezareti) bağlı Sıhhiye Müdüriyet-i Umumiye (Sağlık İşleri Genel Müdürlüğü) kurumu tarafından sunulmaya başlanmıştır. 1869 yılında Cemiyeti Tıbbiye-i Mülkiye kurularak sağlık hizmet personellerinin atanması, eczane hizmetlerinin yerine getirilmesi ve hekimlik yapacak kişilere ruhsat verilmesi gibi birçok işin yerine getirilmesi sağlanmıştır. Kurulan bu kurum işlevsel olarak Sağlık Bakanlığının temelini oluşturmuştur (Çavdar ve Karcı, 2014). 1871 yılında İdare-i Umumiye-i Tıbbiye-i Mülkiye Nizamnamesi ile birlikte Sıhhiye Müfettişlikleri ve Memleket Tabiplikleri kurulmuş ve bu kuruluşla birlikte sağlık sistemin kapsayıcı hizmetlerin hukuk alt yapısı oluşturulmuştur. Sağlık sistemindeki bu çabalar beraberinde iyi ve planlı bir örgütlemenin temellerini inşa etmiştir. Sağlık hizmetleri halkı kapsayıcı bir niteliğe kavuşmuş ve devletin temel görevleri arasında görülmeye başlanmıştır (Akdur, 2006).

Sağlık hizmetlerinin ilk defa devletin sorumluluğunda ve kamu görevi olarak görülmesi ilkesi Türkiye Büyük Millet Meclisi'yle beraber sağlanmıştır. Meclis 1920 de Suret-i İntihabına Dair Kanun ile sağlık hizmetlerinin ayrı bir bakanlıkça yürütülmesine karar vermiştir. Ancak sağlık hizmetlerinin sunulması ve yönetilmesi için altyapı eksikliği, sağlık hizmet anlayışı ve yasal düzenlemeler gibi bir çok konuda eksikliklerin olduğu görülmüştür. Bu yüzden bu dönemde, sağlık sisteminin kurulması için gerekli altyapının temelleri atılmıştır. Sağlık hizmetlerinin ülkenin her tarafına yayılması ve uygulanmasının iyi şekilde yapılarak daha iyi sağlık hizmetinin verilmesi amaçlanmıştır (Ertaş vd., 2016). Bu dönemde 2 önemli olay gerçekleşmiştir.

-Memleket Tabipliğinden Hükümet Tabibliğine Geçiş: 1913 yılında Vilayeti İdare-i Sıhhiye Nizamnamesi çıkarılarak sağlık hizmetlerinin daha iyi örgütlenmesi ve bu hizmetlerin iyi bir şekilde yönetilmesi amaçlanmıştır. Bu çabalar sonucunda merkezi yönetimin sağlanması için alt birimler oluşturulmuştur. Burada sağlık hizmetlerinin

sunulmasında hükümetin sorumluluğu ön olana çıkarılmış ve sağlık hizmetlerinde devletin sorumluluğu artmıştır. Ayrıca ilçelerdeki sağlık problemlerinin giderilmesini sağlama amacıyla Sıhhiye Meclisleri kurulmuştur. Bu meclislerde sorunların çözümüne yönelik seçenekler arasında görüşülüp, en uygun çözüm arayışı üzerinde durulmuştur (Aydın, 2004).

-Tıp Eğitimi : Büyük şehirlerin haricindeki diğer şehirlerin hekim ihtiyacını karşılamak oldukça zordur. Çünkü halka hizmet verebilecek özel hekim sayısı azdır ve bu hekimler genellikle yabancı uyrukludurlar. Bu yüzden sivil hekimlerin yetiştirilebileceği tıp okulları açma ihtiyacı doğmuştur. Bu gelişmelerin sonunda 2. Mahmut döneminde 1827 yılında Tıphane-i Amire adıyla batıda ki okullara benzer ilk tıp okulu açılmıştır. Bu dönemde hekimler denetlenmiş, hekimlik belgesine sahip olmayan hekimler görevden alınmış yada sınava tabi tutularak hekimlik yapabilmeleri sağlanmıştır (Ortaylı, 2000).

Bu dönem genel olarak sağlık sisteminde iyi örgütlenmenin amaçlandığı dönemdir. 1871’de devlet taşrada ve kırsal kesimde yaşayan vatandaşlarına sağlık hizmeti verebilmek için hekimler görevlendirmiş ve bu dönemde Memleket Tabiblikleri kurularak tüm halka sağlık hizmeti götürme amaçlanmıştır. Burada amaç tüm halkın sağlık hizmetlerinden faydalanmasını sağlamaktır. Tüm şehir ve taşra bölgelerinde bütün halka sağlık hizmetinin verilebilmesi için 1866 yılında ilk tıp okulu açılmıştır. Mektebi Tıbbiye-i Mülkiye adında ki bu okul Türkçe olarak eğitime başlamış ve 1874 yılında ilk mezunlarını vermiştir. 1909 yılına kadar toplamda 725 hekim mezun olmuştur. Ancak bu sayı oldukça yetersiz kalmıştır (Aydın, 2004).

1.3.3. Cumhuriyet Dönemi

Çağdaş türk sağlık sisteminin temellerinin atıldığı bu dönemde, sağlık alanında köklü değişiklikler yapılmıştır. Bu dönem sağlık hizmetlerinin tüm halka ulaştırılması ve bütün halkı kapsaması bakımından bir dönüm noktası olarak görülebilir. Sağlık alanında politikaların belirlenmesi, sağlık sisteminin organize edilmesi, örgütlenmesi ve kurumsallaştırılması bu dönemde gerçekleşmiştir. Ayrıca bu dönemde yasal, beşeri ve fiziki oluşumların temelleri atılmıştır. Sağlık alanındaki politikalar halkın bütününe kapsayıcı nitelikte ve halkın yararına olacak şekilde belirlenmiştir (Cansever, 2018).

Cumhuriyetin kurulmasından sonra, bakanlığa bağlı illerde sağlık müdürlükleri ilçelerde ise hükümet tabiblikleri kurulmuştur. Bu örgütlenme beraberinde yurdun

geneline sađlık hizmetlerinin g t r lmesini sađlamıştır. Sađlık hizmet maliyetlerinin kaynađı h k metin b t cesinden karřılanmıştır. Sađlık hizmetlerinde insan unsurunun  nemi  zerinde durulmuř, daha iyi ve kaliteli hizmet sađlanabilmesi i in eđitimi ve kalifiye iřg c n n sađlanmasına  ncelik verilmiřtir (Akdur, 2006). Sađlık hizmetlerinin t m halka ulařtırılması devletin temel ama ları arasında yer almıştır. Sađlık hizmet sađlayıcıları kiři ve kuruluřlar bu amaca g re dizayn edilmiř ve halkın basit ve kolay eriřebileceđi yerlerde sađlık hizmet kuruluřları oluřturulmuřtur.

1921 yılında sađlık bakanlıđı g revine getirilen Dr. Refik Saydam, 1937 yılına kadar sađlık bakanlıđının bařında bulunmuřtur. Bu d nemde, sađlık sisteminin kurumsal altyapısı belirlenmiř, sađlık hizmetlerinin t m  lke  apında yayılması sađlanmış, sistemin  rg tsel yapısı oluřturulmuřtur. Bu d nemde yapılan  alıřmaların temel ama ları ařađıda sıralanmıştır (Yavuz, 2011):

- Sađlık sisteminin altyapısını kurmak ve geliřtirmek,
- Sađlık hizmetlerin iřleyiřini sađlayacak yasal d zenlemeleri yapmak,
- Sađlık hizmetlerini tařra ve kırsal kesimlere kadar g t rmek,
- Tam donanımlı sađlık kurumları kurmak,
-  lkedeki hekim sayısını arttırarak sađlık kaliteyi y kseltmek,
- Sađlık personeli (Ebe, Hemřire, sađlık memuru vb.) sayısını arttırmak,
- Verem, Sıtma, Frengi vb. gibi bir ok salgın hastalıkla m cadele etmek,
-  ocuk ve dođum bakımevleri kurmak.

1.3.4. Atat rk Sonrası D nemden 2000'li Yıllara Geliřim

Bu d nemde  lkede sađlık politikalarında deđiřim ve geliřim hızla devam etmiřtir. 1946 yılında, on yıllık sađlık planı tasarlanarak halkın b y k kısmına sađlık hizmeti verilmesi planlanmıştır. Bu planla kırsal kesimlere kadar  lkenin her yerine sađlık merkezleri kurulması hedeflenmiřtir. Ancak bu amaca ulařılamamış, sađlık merkezleri il e merkezleriyle sınırlı kalmıştır. Halkın t m n n eřit řekilde faydalanacađı sađlık hizmeti, sađlık hizmetlerinin devletin asıl g revi olarak g r lmesi, sađlık hizmetlerinin kaltesinin y kseltilmesi, daha eriřilebilir ve kolay sađlık hizmetlerinin sunumu gibi bir ok konuya  nem verilmiřtir (Tengilimođlu ve  ıtak, 2003).

1960'lı yıllarda hekim, hemşire, ebe ve sağlık personelleri sayısı artmıştır. Ülkede ki sağlık sisteminin geliştirilmesi ve örgütlenmesinin kurulması için uzmanlardan yardım alınmıştır. Batı takip edilmiş ve batıdaki gelişmeler yol gösterici olmuştur. 1982 yılında yeni anayasayla birlikte sağlık alanında yeni politikalar belirlenmiştir (Seçim, 1985). 1980'lerde tüm Dünyada ortaya çıkan Neo Liberal akımdan türkiyede etkilenmiştir. Özel sektörün ön plana çıktığı ve devletin geri plana itildiği bu akımla birlikte sağlık sektöründe özelleşme eğilimi içerisine girmiştir. Sağlık hizmetlerinin finansmanı devlet tarafından değil, aracı kuruluşlarla kendi kendini finansman eden bir sistem haline getirilmesi amaçlanmıştır (Ak, 2021).

Ülkemizde sağlık alanında köklü değişiklikler 1980 sonrasında gerçekleşmiştir. Bu yıllarda çıkarılan Sağlık Hizmetleri Temel Kanunu'yla devlet tarafında kurulan hastanelerin merkeziyetçi yapısının kaldırılması hedeflenmiştir. 1989'da Dünya Bankasından alınan destekle yeni bir sağlık politikası oluşturulmuş, reform sayılacak yeni sağlık planları yapılmıştır. Bu planların tam olarak yasal zemine oturtulması ancak 2000 yılında gerçekleşmiştir. Sağlık hizmetlerinin örgütsel yapısının işleyişini sağlamak adına 2001 yılında Sağlık Hizmetlerinin Yürütülmesi Hakkında Yönerge ile sağlık personellerinin görev ve yetkileri açıkça belirtilmiştir (Aktel vd., 2013).

1.3.5. 2000'li Yıllarda Sağlık

Dünyadaki teknolojik ve sosyal gelişmelerinde etkisiyle sağlık alanında da değişim ve gelişim kaçınılmaz olmuştur. Türkiye de ki sağlık sistemi de bundan etkilenmiştir. Ülkede hem sağlık sağlayıcıları, hemde sağlıktan faydalanalarda bir memnuniyetsizlik söz konusudur. Bu gibi birçok problem sağlık alanında yenilenme ihtiyacını beraberinde getirmiştir (Sülkü, 2011). 3 Kasım 2002 tarihinde yapılan genel seçimlerle birlikte sağlık alanında büyük değişimler hedeflenmiştir. 16 Kasım 2002 tarihinde 'Herkese Sağlık' adıyla acil eylem planı yapılmıştır. Programın hazırlanmasında batıdaki gelişmiş sağlık sistemleri örnek alınmıştır (Akdağ, 2008). Bu kapsamda temel problemler belirlenmiş ve bu problemlerin ortadan kaldırılması için Sağlıkta Dönüşüm Programı belirlenmiştir. Bu temel problemler şu şekildedir (Yılmaztürk, 2013):


- Anne, bebek ve çocuk sağlık verilerine göre Türkiye, Avrupa'nın gerisindedir,
- Yönetimsel aksaklıklar nedeniyle eğitimli ve kalifiye sağlık personeli yetiştirilmesini engellemektedir,
- Sağlık hizmetleri ülkedeki her bireye eşit derece sunulamamaktadır,

- Finansman kaynaklarındaki bölünmüş yapı, hizmetlerde verimsizliğe yol açmaktadır,
- Ülkedeki birçok donanımlı hastane sevk sistemindeki eksiklikler nedeniyle, birinci basamak sağlık kuruluşları gibi hizmet vermektedir,
- Sağlık hizmet sağlayıcılarının kırsal kesimlerde çalışmak istememeleri ve bu nedenle sağlık hizmetlerine erişimin zorlaşması,
- Nusufun büyük bölümünün sosyal güvenlik kapsamına alınamaması,
- Hizmetlerin ülkenin kırsal kesimlerine verilmesinin oldukça zor olması.

Bu yıllarda sağlık sisteminin yeniden yapılandırılması ve geliştirilmesiyle ilgili çalışmalar yapılmıştır. Bu planlamaların belirlenmesiyle birlikte 2003 yılında, SDP(Sağlıkta Dönüşüm Programı) ile planlamanın uygulama aşamasına geçilmiştir. Bu program çerçevesinde, düzenleyici ve denetleyici bir sağlık yönetim sistemi, tüm bireyleri aynı çatı altında birleştiren bir sağlık sigortası, erişilebilmesi kolay ve kaliteli sağlık hizmeti, sağlık sistemini destekleyici eğitim kurumları, bilgili ve donanımlı sağlık personeli vb. birçok konu üzerinde durulmuştur. Birinci basamak sağlık hizmetleri ve koruyucu sağlık hizmetleriyle bireylere hızlı ve kolay erişilebilir hizmetler verilmesi amaçlanmıştır (Akdağ, 2007).

1.3.5.1. Sağlık Hizmetlerinde Gelişim

Sağlık alanında yapılan iyileştirme geliştirme ve sağlık hizmetlerinin ülkenin bütününe kapsayıcı nitelikteki politikalar sağlık hizmetlerinde memnuniyeti yüksek oranda arttırmıştır. Aşağıdaki grafikte program kapsamında sağlık hizmetlerinden memnuniyet yıllara göre yüzdelik olarak gösterilmektedir.



Şekil 1. 2. Yıllara Göre Sağlıkta Memnuniyet

Bu verilere bakıldığında Sağlıkta Dönüşüm Programının etkileri apaçık görülmektedir. Programla birlikte memnuniyet oranları sürekli artış eğilimi göstermektedir. 2003 yılında % 39,50 olan bu oran 2016 yılında %75,40 seviyesine yükselmiştir (TÜİK, akt., Atasever vd., 2017). Sağlık sisteminde uygulanan bu değişiklikler sağlık hizmetlerine olumlu yönde katkı sağlamıştır. Ülkemizdeki sağlık sistemi bu programla birlikte önemli düzeyde değişim içine girmiş ve bu değişim sisteme yüksek düzeyde katkı sağlamıştır. Belirlenen sağlık politikaları, sağlık erişimindeki sorunların ortadan kaldırılması ve birinci basamak sağlık hizmetlerinde iyileştirme vb. birçok alanda yapılan yenilikler halkın sağlık hizmetlerine olan memnuniyetini yükseltmiştir (Kasapoğlu, 2016).

Türkiye’de sağlık sisteminin yeniden yapılandırılması ihtiyacı, artan ekonomik yük, karşılaşılan sorunlar ve değişen hizmet beklentileri nedeniyle kaçınılmaz hale gelmiştir. Sağlık maliyetlerinin etkin yönetimi, hizmet kalitesinin ve verimliliğin artırılması, önleyici sağlık hizmetlerinin sunulması ve yaşam kalitesinin yükseltilmesi amacıyla dijital teknolojilerden yararlanmak zorunlu hale gelmiştir. 2000’li yılların başında başlayan dijital dönüşüm süreci, pandemiyle birlikte hız kazanarak, hastalar ve sağlık çalışanları için e-nabız, MHRS ve İlaç Takip Sistemi gibi uygulamalarla devam etmiştir. Bu uygulamalar sayesinde sağlık verilerine erişim ve randevu alma gibi işlemler dijital platformlar üzerinden kolayca gerçekleştirilebilmektedir. Sağlıkta dijital dönüşüm, hizmet kalitesini artırırken, sağlık sisteminin sürdürülebilirliğine de önemli katkılar sağlamaktadır (Ey, 2023).

1.3.5.2. Sağlık Hizmetlerinde Dijitalleşme

Türkiye’de sağlık hizmetlerinin dijitalleşmesi, 1990 yılında sağlık projelerinin hazırlanması ve faaliyete geçirilmesi amacıyla kurulan Sağlık Projesi Genel Koordinatörlüğü (SPGK) ile başlamıştır. 1996’da Sağlık Bakanlığı Bilgi İşlem Daire Başkanlığı’nın faaliyete geçmesiyle birlikte dijitalleşme süreci hız kazanmıştır. 1990’lı yıllarda Hastane Bilgi Yönetim Sistemi (HBYS) geliştirilmesine yönelik çalışmalar başlamış ve bu sistem, 2000’li yıllardan itibaren etkin ve yaygın olarak kullanılmaya başlanmıştır. 2003 yılında başlatılan “Sağlıkta Dönüşüm Programı (SDP)” ise sağlık sisteminde dijitalleşme sürecine önemli bir ivme kazandırmıştır. Bu dönemde internet hizmetleri ağı olarak “Sağlık-Net” projesi yürürlüğe girmiş ve hastanelerde planlama kapasitesi artırılmıştır. Türk sağlık sistemi son yıllarda önemli bir dönüşüm geçirmiştir.

1996 yılında kurulan ve 2011 yılında yeniden yapılandırılan Sağlık Bilgi Sistemleri Genel Müdürlüğü, çağdaş bir yapıya kavuşturulmuştur. Günümüzde Türkiye'de sağlık hizmetleri, kamu ve özel hizmetlerin karışımıyla sağlanmaktadır (Sağlık Bakanlığı, 2015).

2020 yılında sağlıkta dijitalleşme, COVID-19 pandemisinin etkisiyle hızla yükselen bir trend haline gelmiştir. Türkiye'deki "Hayat Eve Sığar" gibi sağlık uygulamaları, dünya genelinde benzer çözümlerle yaygınlaşmaya başlamıştır. Pandemi sürecinde, basit hastalıklar için doktoruyla uzaktan iletişime geçerek muayene olmak isteyenlerin sayısı artmış; bu oran 2019'da %38 iken 2021'de %61'e yükselmiştir. Ayrıca, doktor ile tele-sağlık hizmetleri üzerinden sanal ortamda yapılan görüşmelerin yüz yüze yapılan muayene kadar verimli ve kaliteli olacağını düşünen katılımcıların oranı %40 olmuştur. Fikir önderleri, pandemi döneminde dijital sağlık teknolojilerinin sunduğu fırsatlar konusunda toplumun farkındalığının arttığını belirtmektedir. Buna ek olarak, hekimlere mobil mesajlaşma uygulamaları üzerinden danışma, online konsültasyon ve terapi hizmetleri, online randevu ve sağlık verisi sistemlerine olan ilginin arttığına dikkat çekilmektedir (Philips, 2021).

Bakanlığa bağlı sağlık kurumlarından randevu almayı sağlayan Merkezi Hekim Randevu Sistemi (MHRS), vatandaşların Sağlık Bakanlığına bağlı 2. ve 3. basamak hastaneler ile Ağız ve Diş Sağlığı Merkezleri için telefonla veya web üzerinden randevu alabileceği bir uygulama olarak devreye alınmıştır. 2010 yılında ilaçların üreticiden vatandaşa kadar olan tüm sürecini takip eden İlaç Takip Sistemi (İTS) uygulamaya konulmuştur. Sağlıkta dijital dönüşüm basamaklarından bir diğeri, kişisel sağlık bilgilerinin yönetilebildiği kişisel sağlık kaydı sistemi olan e-Nabız'dır. E-Nabız'ın mevcutta yaklaşık 68 milyon kullanıcısı bulunmaktadır. 2018 yılında hayata geçirilen SİNA (Sağlıkta İstatistik ve Nedensel Analizler), kaynakların daha etkin yönetilmesi amacıyla geliştirilen, Sağlık Bakanlığına ait yerli karar destek sistemi platformudur. Sağlık hizmetlerinde dijitalleşmenin bir diğer örneği ise dijital hastanelerdir (Ey, 2023).

Kamu sektörü yatırımları, sağlık bilgi sistemi altyapısının geliştirilmesi için ayrılan bütçeyle önemli bir ivme kazanmıştır. 2020 yılında bu amaçla 96 milyon TL bütçe ayrılmıştır. 2021 yılında Sağlık Bakanlığı, sağlık bilgi sistemleri altyapısı ve teknolojisinin geliştirilmesi için bütçeyi 112 milyon TL'ye çıkarmıştır. 2022 yılında ise

bütçe önemli bir artışla 666 milyon TL'ye yükseltilmiştir. Ayrıca, 2023 ve 2024 yıllarında da bütçe tahminlerinin artış eğiliminde olduğu gözlemlenmektedir (Ey, 2023).

1.3.5.3. Pandemi ile Birlikte Meydana Gelen Değişim ve Gelişmeler

Pandemi sonrasında meydana gelen değişimler çeşitli alanlarda önemli etkiler oluşturmuştur. Bu etkiler, ekonomi ve sosyal yapılar, sağlık sistemleri, iş ve istihdam, eğitim ve öğrenme, toplumsal ve davranışsal değişimler gibi geniş bir yelpazede incelenmiştir.

1.3.5.3.1. Pandemi Sonrası Ekonomik ve Sosyal Değişimler

Pandemi sonrası ekonomik ve sosyal değişimler, küresel ölçekte önemli dönüşümlere yol açmıştır. COVID-19 pandemisi, ekonomik sistemleri yeniden şekillendirerek toplum üzerinde derin ve kalıcı etkiler bırakmıştır. Bu süreç küresel ekonomiyi dönüştürmüş ve toplumlar bu dönüşümden etkilenmişlerdir. Pandemi, iş yapma biçimlerinden tedarik zincirlerine kadar pek çok alanda köklü değişikliklere neden olmuş, ekonomik faaliyetlerin yeniden düzenlenmesini zorunlu kılmıştır. COVID-19 pandemisi, sadece geçici bir kriz olarak değil, aynı zamanda küresel ekonominin temel dinamiklerini değiştiren bir dönüm noktası olarak görülmelidir. Pandemi, ekonomik eşitsizlikleri ve sosyal adaletsizlikleri daha belirgin hale getirerek, hükümetleri ve şirketleri daha kapsayıcı ve sürdürülebilir stratejiler benimsemeye yönlendirmiştir. Özellikle dijitalleşmenin hızlanması, iş gücü piyasasında ve ticaretin doğasında önemli değişiklikler getirmiştir. Uzaktan çalışma modelleri, dijital ödeme sistemleri ve e-ticaretin yaygınlaşması, pandemi sonrası dönemde kalıcı hale gelmiştir (Schwab ve Malleret, 2020).

Pandemi nedeniyle küresel tedarik zincirlerinde yaşanan aksaklıklar dijital dönüşümün önemini artırmıştır. Pandemi, tedarik zincirlerindeki kırılganlıkları ortaya çıkararak, firmaların daha dayanıklı ve esnek tedarik zinciri stratejileri geliştirmelerini zorunlu kılmıştır. Dijital dönüşüm, bu süreçte kritik bir rol oynamış, şirketlerin tedarik zincirlerini daha iyi yönetmelerine ve krizlere daha hızlı yanıt vermelerine olanak tanımıştır. Pandemi sürecinde yaşanan bu dönüşümler, ekonomik ve sosyal yapıları derinden etkilemiş ve gelecekteki kalkınma politikaları ve iş stratejileri üzerinde kalıcı etkiler bırakmıştır. Pandemi sonrası dönemin, sadece ekonomik toparlanma değil, aynı zamanda sosyal ve çevresel sürdürülebilirliğin de ön planda olduğu yeni bir ekonomik

düzenin habercisi olduğu görülmektedir. Bu yeni dönemde, dijitalleşme, inovasyon ve kapsayıcı büyüme politikaları, ekonomik ve sosyal refahın artırılmasında kilit rol oynayacaktır (Ivanov ve Dolgui, 2020).

Özetle, pandemi sonrası dönemde ekonomik ve sosyal değişimler, dijitalleşme ve inovasyonun hızlanması, tedarik zincirlerinin yeniden yapılandırılması ve daha sürdürülebilir ve kapsayıcı ekonomik politikaların benimsenmesi gibi önemli unsurları içermektedir. Bu dönüşümler geçici değil, uzun vadeli ve kalıcı etkiler oluşturmuş ve gelecekteki ekonomik stratejilerin bu yeni gerçeklikler doğrultusunda şekillendirilmesi gerekliliğininde beraberinde getirmiştir.

1.3.5.3.2. Pandemi'nin Sağlık Sistemlerine Etkisi

Pandemi sonrası dönemde sağlık sistemleri üzerindeki etkiler oldukça kayda değerdir. COVID-19 pandemisi, küresel sağlık hizmetleri üzerinde büyük bir baskı oluşturarak, sistemin zayıf noktalarını ve geliştirilmesi gereken alanları gün yüzüne çıkarmıştır. Bu süreçte, sağlık hizmetleri sunumunda önemli değişiklikler yaşanmış ve birçok yenilikçi çözüm hızla devreye alınmıştır. Pandeminin sağlık hizmetleri üzerindeki baskısı artmış, özellikle tele-sağlık uygulamalarının hızla benimsenmesine neden olmuştur. Tele-sağlık, hastaların sağlık hizmetlerine uzaktan erişimini sağlayarak, hem hasta hem de sağlık çalışanları için güvenli ve etkili bir çözüm sunmuştur. Pandemi döneminde sağlık hizmetlerine olan talebin hızla artması, hastaneler ve sağlık kuruluşları üzerinde büyük bir yük oluşturmuştur. Bu durum, sağlık sistemlerinin hızla adapte olmasını ve yenilikçi çözümler geliştirmesini zorunlu kılmıştır (Greenhalgh vd., 2020).

Pandemi sağlık inovasyonlarını, dijital sağlık teknolojilerinin ve yapay zeka uygulamalarının sağlık sistemine entegrasyonunu hızlandırmıştır. Örneğin, yapay zeka destekli tanı sistemleri, hastaların hızlı ve doğru bir şekilde teşhis edilmesini sağlayarak, sağlık hizmetlerinin etkinliğini artırmıştır. Ayrıca, uzaktan izleme cihazları ve mobil sağlık uygulamaları, hastaların sağlık durumlarını evlerinden takip etmelerine olanak tanımış ve bu sayede hastane ziyaretleri ve sağlık sistemi üzerindeki yük azaltılmıştır. Sağlık inovasyonları, pandeminin oluşturduğu acil ihtiyaçlar doğrultusunda hızla gelişmiş ve uygulanmıştır. Özellikle dijital sağlık çözümleri, sağlık sistemlerinin daha esnek ve dayanıklı olmasını sağlayarak, gelecekteki olası

salgınlar ve sađlık krizleri karřısında daha iyi bir hazırlık düzeyi sunacaktır (Topol, 2020)

Pandeminin sađlık sistemleri üzerindeki etkileri, sadece teknolojik inovasyonlarla sınırlı kalmamıř, aynı zamanda sađlık politikaları ve yönetim stratejilerinde de önemli deđiřikliklere yol açmıřtır. Sađlık hizmetlerinin daha entegre, hasta odaklı ve veri temelli bir yaklařımla sunulması gerektiđi anlayıřı, pandemi sürecinde daha da pekiřmiřtir. Sonuç olarak, COVID-19 pandemisi, sađlık sistemleri üzerinde derin ve kalıcı etkiler bırakmıřtır.

1.3.5.3.3. Pandemiyle Birlikte İř ve İstihdam Alanındaki Deđiřimler

Pandemi, iř ve istihdam alanında büyük deđiřimlere yol açmıř ve çalıřma biçimlerini köklü bir řekilde dönüřtürmüřtür. Bu süreçte, uzaktan çalıřma modelinin yaygınlařması, iř dünyasında kalıcı deđiřikliklere neden olmuřtur. COVID-19 sonrası iř dünyasında uzaktan çalıřma kalıcı bir yer edinmiř ve bu durum iř yerleri için yeni bir norm haline gelmiřtir. Pandeminin bařlangıcında geçici bir çözüm olarak görülen uzaktan çalıřma, zamanla iř süreçlerinin vazgeçilmez bir parçası haline gelmiř ve birçok řirket bu modelin avantajlarını keřfetmiřtir. Çalıřanlar açısından bakıldıđında, esnek çalıřma saatleri ve evden çalıřma imkanları sayesinde iř-yařam dengeleri iyileřmiř ve genel iř memnuniyeti artırmıřtır. Ayrıca, uzaktan çalıřma modeli, iř gücü maliyetlerinin de azaltmıřtır. Ofis alanı kiralari, yol masraflari ve diđer ofis içi giderler gibi maliyetlerin azalması, řirketlerin bütçelerinde önemli tasarruflar yapmalarını sađlamıřtır (Vyas ve Butakhieo, 2021).

Uzaktan çalıřma modelinin bařarısı, iř yerlerinde güçlü bir dijital altyapı kurulmasına bađlıdır. Güvenilir internet bađlantıları, bulut tabanlı veri depolama ve paylařım sistemleri, sanal toplantı platformlari ve diđer dijital araçlar, uzaktan çalıřmanın etkinliđini artıran unsurlardandır. Ayrıca, yöneticiler ve liderler, uzaktan çalıřan ekipleri etkin bir řekilde yönetebilmek için yeni liderlik becerileri geliřtirmiřerdir. Sanal ortamda takım ruhunu korumak, çalıřan motivasyonunu yüksek tutmak ve etkin iletiřim kurmak, bu yeni dönemde önem kazanan liderlik becerilerindendir. Pandemi sonrası dönemde, uzaktan çalıřmanın kalıcı hale gelmesi, iř yerlerinde yeni bir kültürel dönüřümü de beraberinde getirmiřtir. İřverenler, çalıřanlarının fiziksel olarak ofiste bulunmalarını zorunlu kılmaktan ziyade, performans ve çıktılara odaklanan bir yönetim anlayıřını benimsemeye bařlamıřtır. Bu

durum, çalışanların iş tatminini artırırken, aynı zamanda işverenlerin de daha esnek ve verimli iş modelleri geliştirmelerine olanak tanımıştır (Kniffin vd., 2021).

Sonuç olarak, pandemi, iş ve istihdam alanında büyük değişimlere neden olmuş ve uzaktan çalışma modelinin kalıcı bir yer edinmesine yol açmıştır. Uzaktan çalışma iş dünyasında yeni bir norm haline gelmiş ve sürdürülebilir geçişler için önemli bir çerçeve sunmuştur. Bu değişimler, iş yerlerinde daha esnek, verimli ve çalışan odaklı yaklaşımların benimsenmesine katkı sağlamıştır.

1.3.5.3.4. Pandeminin Eğitim ve Öğretim Alanına Etkisi

Pandemi sonrası dönemde eğitim ve öğrenme alanında önemli dönüşümler yaşanmıştır. Bu süreçte, eğitim sistemleri hızla değişen koşullara adapte olmak zorunda kalmış ve bu adaptasyon süreçlerinde çeşitli zorluklar ve fırsatlar ortaya çıkmıştır. Pandemi, eğitim kurumlarını çevrimiçi ve uzaktan öğrenme modellerine geçmeye zorlamış, bu da hem öğrenciler hem de eğitimciler için önemli değişiklikler ve uyum süreçlerini beraberinde getirmiştir. Öğretimde, özellikle altyapı eksiklikleri, dijital bölünme ve öğrenci-öğretmen etkileşiminin azalması gibi sorunlar ortaya çıkmıştır. Birçok öğretim kurumu, çevrimiçi eğitime geçişte teknolojik altyapı eksiklikleriyle karşı karşıya kalmış ve bu durum, eğitimin sürekliliğini sağlama konusunda ciddi zorluklar ortaya çıkarmıştır. Ayrıca, çevrimiçi eğitimde öğrenci-öğretmen etkileşiminin azalması, eğitimin kalitesini ve öğrencilerin öğrenme motivasyonunu düşürmüştür. Zamanla çevrimiçi öğrenme platformlarının geliştirilmesi ve dijital eğitim kaynaklarının artması, eğitimde yenilikçi ve esnek öğrenme modellerinin benimsenmesine olanak tanımıştır. Bu süreçte, eğitim teknolojilerinin kullanımı yaygınlaşmış ve öğretim yöntemleri çeşitlenmiştir. Pandemi, yüksek öğretim kurumlarının dijital dönüşümünü hızlandırarak, gelecekte daha esnek ve öğrenci merkezli eğitim modellerinin yaygınlaşmasının önünü açmıştır (Marinoni vd., 2020).

Çevrimiçi öğrenme, pandemi sürecinde eğitimde sürekliliği sağlamada önemli bir araç olarak öne çıkmıştır. Ancak, bu öğrenme modelinin başarılı bir şekilde uygulanabilmesi için çeşitli zorlukların aşılması gerekmektedir. bu zorluklara yönelik çözümler arasında, eğitim kurumlarının dijital altyapılarını güçlendirmeleri, öğrenci ve öğretmenlerin dijital becerilerini artırmaları için eğitim programları düzenlemeleri ve çevrimiçi öğrenme platformlarının etkileşimli ve kullanıcı dostu hale getirilmesi

gibi öneriler öne çıkmaktadır. Ayrıca, çevrimiçi öğrenmede pedagojik yaklaşımların yeniden gözden geçirilmesi ve öğrenci merkezli öğretim yöntemlerinin benimsenmesi gerekliliği oluşmuştur. Öğrencilerin aktif katılımını teşvik eden, işbirliğine dayalı ve etkileşimli öğrenme ortamlarının oluşturulması, çevrimiçi eğitimin kalitesini artırmada önemli bir rol oynamıştır (Dhawan, 2020).

Sonuç olarak, pandemi sonrası dönemde eğitim ve öğrenme alanında önemli dönüşümler yaşanmış ve bu süreçte çeşitli zorluklar ve fırsatlar ortaya çıkmıştır. Pandemi, eğitimde dijital dönüşümü hızlandırmış ve çevrimiçi öğrenmenin yaygınlaşmasını sağlamıştır. Ancak, bu süreçte karşılaşılan zorlukların aşılması ve eğitimde fırsat eşitliğinin sağlanması için yenilikçi çözümlerin ve esnek öğrenme modellerinin benimsenmesi gerekmektedir.

1.3.5.3.5. Pandemi ile Birlikte Toplumsal Davranışlarda Değişim

Toplumsal ve davranışsal değişimler, pandeminin bir diğer önemli boyutunu oluşturmaktadır. Pandemi, sosyal davranışlar, toplumsal etkileşimler ve bireysel refah üzerinde derin etkiler oluşturmuş, bu değişimler toplumsal dinamikleri önemli ölçüde etkilemiştir. Pandeminin neden olduğu izolasyon, stres ve belirsizlik gibi faktörlerin, toplum genelinde artan ruh sağlığı sorunlarına yol açmıştır. Özellikle, kaygı ve depresyon oranlarında gözle görülür bir artış yaşandığı ve bu durumun bireylerin günlük yaşamlarını olumsuz yönde etkilenmiştir. Pandemi sürecinde sosyal etkileşimlerin sınırlandırılmasının, toplumsal bağların zayıflamasına ve bireylerin sosyal destek sistemlerinden yoksun kalmasına neden olmuştur. Bu durum, yalnızlık ve izolasyon duygularının artmasına yol açarak, bireylerin ruh sağlığını olumsuz etkilemiştir. Ancak, dijital iletişim araçlarının yaygınlaşması ve çevrimiçi platformların kullanımı, sosyal etkileşimlerin devam etmesine olanak tanımış ve bireylerin bu zorlu süreçte sosyal bağlarını korumalarına yardımcı olmuştur (Pfefferbaum ve North, 2020).

Pandemi sürecinde, sosyal etkileşimlerin azalması ve ekonomik belirsizliklerin artması, toplum genelinde genel mutluluk düzeylerinin düşmesine neden olmuştur. Ancak, bazı bireyler ve topluluklar, bu zorlu sürece karşı direnç göstermiş ve olumlu başa çıkma mekanizmaları geliştirmiştir. Pandemi sürecinde toplumsal dayanışma ve yardımlaşma duyguları artmış ve bireylerin genel mutluluğunu olumlu yönde etkilemiştir. Özellikle, topluluklar arası yardımlaşma ve destek faaliyetleri, bireylerin

kendilerini daha değerli hissetmelerine ve toplumsal aidiyet duygularının güçlenmesine katkı sağlamıştır. Ayrıca, pandemi sürecinde doğa ile etkileşimin ve açık hava aktivitelerinin artması, bireylerin ruh sağlığı ve genel mutluluğu üzerinde olumlu etkiler oluşturmuştur (Helliwell vd., 2021). Sonuç olarak, pandemi, toplumsal ve davranışsal değişimler üzerinde derin etkiler oluşturmuş ve bu değişimlerin toplumsal dinamikleri önemli ölçüde etkilediği görülmüştür.

1.3.6. Acil Servislerin Sağlık Sisteminde Yeri ve Önemi

Acil servisler, hastanelerin en kritik ve yoğun birimleridir; tıbbi acil durumlar, travmalar, hayati tehlike arz eden vakalar ve beklenmedik sağlık sorunları yaşayan hastalara hızlı ve etkili müdahale sağlamak amacıyla faaliyet gösterirler. Bu servisler, acil tıbbi bakımın ilk adımını gerçekleştirir ve hastaların sağlık durumlarını titizlikle değerlendirerek gerekli tedavi veya müdahaleye yönlendirirler. Acil servisler, kaza ve yaralanmalardan şiddet ve istismar vakalarına, acil psikiyatrik durumlara kadar geniş bir yelpazede hizmet verirler. Ayrıca, bulaşıcı hastalıklar gibi toplumu tehdit eden sağlık sorunlarında da kritik bir rol üstlenirler. Bu birimler, 24 saat kesintisiz hizmet sunarak, hastaların her türlü acil durumunda yanlarında olmayı hedefler. Acil servislerin etkin işleyişi, modern tıbbın ve sağlık sistemlerinin en önemli unsurlarından biridir. Bu servisler, en basit ilk yardım müdahalelerinden, karmaşık ve geniş kapsamlı acil tıbbi işlemlere kadar her türlü gereksinimi karşılayacak şekilde donatılmıştır. Acil servislerin altyapısı, donanımı ve personelinin yetkinliği, acil sağlık hizmetlerinin kalitesini doğrudan etkiler. Sonuç olarak, acil servisler toplum sağlığı açısından vazgeçilmez bir öneme sahiptir (Khosroshani ve Aydın, 2019).

Sağlık sistemi içindeki en hayati unsurlardan biri, hastaların acil durumlarında hızlı ve etkili müdahale sağlayan acil servis hizmetleridir. Bu servisler, hastalığın türünden bağımsız olarak her türlü acil durumu ele alması yönüyle, yaşamsal öneme sahiptir. Ancak dünya genelinde acil servislerin gereksiz kullanımı, sağlık hizmetlerinde önemli maliyetlerin ortaya çıkmasına sebep olmaktadır. Gereksiz acil servis talepleri, sağlık sistemlerinin verimliliğini ve kalitesini düşürerek maliyetleri arttırmaktadır. Dünya genelinde sağlık sistemlerinin sürdürülebilirliği ve etkinliği için acil servislerin etkin kullanımı kritik bir öneme sahiptir. Bu bağlamda, toplumun bilinçlendirilmesi, sağlık profesyonellerinin eğitimi ve alternatif sağlık hizmetlerinin teşvik edilmesi gibi stratejilerle gereksiz acil servis taleplerinin azaltılması

hedeflenmelidir. Bu çaba, hem sağlık sistemi kaynaklarını daha etkili bir şekilde kullanmayı hem de hastalara daha hızlı ve uygun sağlık hizmeti sunmayı sağlayabilecektir (Derlet, 2002).

1.3.6.1. Acil Servis Hizmetlerinin Özellikleri

Acil servisler, sağlık sistemi içinde hayati bir role sahip olmalarına rağmen, tüm sağlık hizmeti ihtiyaçlarını karşılamak için uygun değildir. Geleneksel acil servis misyonu, akut durumların tedavisine odaklanmaktadır ve bu nedenle sağlık davranışlarını değiştirmeye veya kronik hastalıkları yönetmeye yönelik yeterli kaynaklara sahip değildir. Acil servisler, ani ve ciddi sağlık sorunlarına hızlı müdahale sağlamak amacıyla tasarlanmış olup, uzun vadeli sağlık yönetimi ve hastalıkların önlenmesi gibi konularda sınırlı bir etkiye sahiptirler. Acil servislerin kullanımı, aynı zamanda yüksek maliyetli bir sağlık hizmeti sunmaktadır. Bu birimlerin sık kullanımı, sağlık harcamalarında önemli bir artışa neden olmaktadır. Bu nedenle, sağlık hizmetlerinin etkin bir şekilde yönetilmesi ve acil servislerin yalnızca gerçekten gerekli durumlarda kullanılması, sağlık sisteminin sürdürülebilirliği açısından büyük önem taşımaktadır (Margaret ve Keith, 2019). Aşağıda acil servislerin genel özellikleri maddeler halinde açıklanmıştır:

1.Hızlı Erişim ve Triaaj Sistemi: Acil servislerin en belirgin özelliği, hastaların sağlık hizmetlerine hızlı bir şekilde erişimini sağlamaktır. Acil durumlarda, her dakika önemlidir ve acil servisler, zaman kaybını en aza indirgeyerek hastaların hızlı bir şekilde değerlendirilmesini ve tedavi edilmesini sağlar. Bu bağlamda, triaj sistemi önemli bir rol oynar. Triaaj, hastaların aciliyet durumlarına göre sınıflandırılmasını ve önceliklendirilmesini sağlayan bir süreçtir. Bu sistem, en kritik durumda olan hastaların öncelikli olarak tedavi edilmesine olanak tanır ve kaynakların etkin kullanımını sağlar (Oredsson vd., 2011).

2.Geniş Kapsamlı Tanı ve Tedavi İmkanları: Acil servisler, geniş kapsamlı tanı ve tedavi imkanları sunar. Laboratuvar testleri, radyolojik görüntüleme (röntgen, tomografi, MRI gibi) ve diğer tanı araçları acil servislerde hızla uygulanabilir. Ayrıca, çeşitli tıbbi prosedürler ve cerrahi müdahaleler de acil servislerde gerçekleştirilebilir. Bu kapsamlı imkanlar, hastaların durumu hızlı bir şekilde değerlendirilip gerekli müdahalelerin yapılmasına olanak tanır. Acil servislerde çalışan sağlık profesyonelleri,

acil tıbbın yanı sıra, kardiyoloji, travmatoloji, nöroloji ve diğer tıbbi alanlarda da uzmanlık bilgisine sahip olmalıdır (Pines vd., 2009).

3.Multidisipliner Ekip Çalışması: Acil servislerde, farklı tıbbi disiplinlerden gelen profesyoneller bir arada çalışır. Bu ekip, acil tıp uzmanları, hemşireler, teknisyenler, radyologlar, cerrahlar ve diğer sağlık profesyonellerinden oluşur. Ekip çalışması, acil durumların hızlı ve etkin bir şekilde yönetilmesini sağlar. Her bir ekip üyesinin özel bilgi ve becerileri, hastaların ihtiyaçlarına yönelik en uygun bakımın sağlanmasına katkıda bulunur. Ayrıca, acil servislerdeki ekiplerin düzenli olarak eğitim alması ve en güncel tıbbi bilgileri kullanması önemlidir (Cole ve Crichton, 2006).

4.Sürekli Eğitim ve Kalite İyileştirme: Acil servislerde kalite ve hasta güvenliğini artırmak için sürekli eğitim ve kalite iyileştirme çalışmaları yapılmaktadır. Sağlık profesyonellerinin bilgi ve becerilerini sürekli olarak güncellemeleri, acil durumlarda en iyi bakımın sağlanmasına katkıda bulunur. Eğitim programları, simülasyon eğitimi, vak'a analizleri ve sürekli mesleki gelişim kursları gibi çeşitli yöntemlerle gerçekleştirilebilir. Ayrıca, acil servislerde yapılan kalite iyileştirme çalışmaları, hasta bakımını iyileştirmek için sürekli olarak veri toplanmasını ve bu verilerin analiz edilerek hizmet süreçlerinin optimize edilmesini içerir (Curtis vd., 2016).

Acil servislerde hizmet kalitesini artırmak için çeşitli modeller ve yöntemler üzerinde çalışmalar yapılmaktadır. Özellikle hasta triaj sistemlerinin geliştirilmesi ve uygulamaların standart hale getirilmesi konularına odaklanılmaktadır. Bu çalışmalar, hastaların acil servislerde karşılaştıkları sorunları ve beklentileri anlamayı amaçlamakta ve hasta memnuniyetini artırmayı hedeflemektedir. Ayrıca, acil servislerde hasta memnuniyetinin ve bakım kalitesinin ölçülmesi ve iyileştirilmesi için anketler ve analizler gerçekleştirilmiştir. Bu analizler, hastaların hizmet kalitesiyle ilgili geri bildirimlerini toplamakta ve hizmetlerin iyileştirilmesi için yol gösterici olmaktadır (Al, 2018).

1.3.6.2. Acil Servis Hizmetlerinin Amacı

Acil servisler, sağlık sistemlerinin en kritik bileşenlerinden biridir ve hasta bakımında önemli bir rol oynamaktadır. Bu birimlerin etkinliği ve hizmet kalitesi üzerine yapılan çalışmalar, acil servislerin sağlık hizmetleri içindeki yerini ve önemini vurgulamaktadır. Acil servislerin başlıca amacı, acil tıbbi durumlarla karşılaşan hastalara hızlı, etkili ve kapsamlı bakım sağlamaktır. Bu hizmetler, yaşamı tehdit eden

durumları hızla tanıma ve tedavi etme, hastaların durumlarını stabilize etme ve gerektiğinde ileri tedavi için uygun birime sevk etme süreçlerini kapsamaktadır (Al, 2015).

Acil servislerin başlıca amacı, acil tıbbi durumlarla karşılaşan hastalara hızlı, etkili ve kapsamlı bakım sağlamaktır. Bu hizmetler, yaşamı tehdit eden durumları hızla tanıma ve tedavi etme, hastaların durumlarını stabilize etme ve gerekirse ileri tedavi için uygun birime sevk etme süreçlerini içerir. Acil servisler, 24 saat erişilebilir olup, travma, ani hastalıklar, kronik hastalıkların akut alevlenmeleri ve diğer acil durumlarla başvuran hastalara multidisipliner bir yaklaşımla bakım sunar. Ayrıca, acil servisler halk sağlığı gözetimi ve hastalık salgınlarının erken tespiti gibi önemli toplumsal sağlık rollerini de üstlenir. Eğitim ve araştırma faaliyetleri aracılığıyla sağlık hizmetlerinin kalitesini sürekli olarak artırmayı hedeflerler (Wiler vd., 2012).

Acil servislerin öncelikli amacı herhangi bir sağlık riski veya kaza durumunda acil vakalara hizmet vermektir. Bu servisler yılın her günü ve her saatinde hizmet vermeye hazır durumdadırlar. Acil servisler, sağlık sistemindeki tüm birimlere hizmet etmektedir. Bu yüzden acil servisler tüm uzmanlıkların birleştiği bir birim olarak karşımıza çıkmaktadır. Bu servislerde tüm vakalar kabul edildiği için karmaşık ve dinamik yapıya sahiptir. Son zamanlarda bu servislerin yönetilmesi oldukça zorlaşmıştır. Çünkü bu servisler gittikçe yoğun ve daha karmaşık hale gelmişlerdir. Acil servislerin temel amaçları şu şekilde sıralanabilir (Carret vd., 2007):

- Kaliteli hizmet anlayışıyla sürekli geliştirilebilir ve en uygun sağlık hizmeti,
- Hastalara daha iyi bir hizmet için hizmet sunumunun planlanması, organizasyonu, koordinasyonu ve kontrolü,
- Basit ve kolay erişilebilir bir sağlık hizmeti,
- Bilgi ve becerisi yüksek kalifiye sağlık personeli temini,
- En uygun ve etkili tedavi hizmetlerinin verilmesi.

Acil servisler, sağlık sistemi içinde hayati bir sağlık hizmeti sunum ortamıdır. Bu birimlerin temel özelliği, ani gelişen ve hızlı müdahale gerektiren sağlık sorunlarında ilk başvuru noktası olmalarıdır. Acil servisler, hastaların acil durumlarda hızlı ve etkili bir şekilde müdahale edilmesini sağlayarak, hayati tehlike arz eden durumlarda kritik bir rol oynar. Acil servislerin bu temel işlevinin yanında, toplum ve sağlık sistemi açısından önemli bazı işlevleri de bulunmaktadır. Acil servis kullanımı,

aynı zamanda başvuranların diğer sağlık kurumlarında karşılanamamış sağlık hizmeti ihtiyacının bir göstergesi olabilir. Erişim engeli yaşayan toplum kesimleri için acil servisler, ulaşılabilir tek sağlık hizmeti türü olabilmektedir. Bu nedenle, acil servisler çoğu durumda toplumun sağlık hizmetleri ile ilk temas noktasıdır. Sağlık sisteminin diğer unsurlarındaki aksamalar ve yetersizlikler, hastaların acil servislere başvurmasına neden olabilmektedir. Acil servislerin sunduğu hizmetler, toplum sağlığı açısından büyük bir öneme sahiptir. Bu birimler, ani ve ciddi sağlık sorunları yaşayan bireylerin hızlı bir şekilde tedavi edilmesini sağlar ve hastaların sağlık durumlarını stabilize ederek gerekli görülen durumlarda hastaneye yatışlarını gerçekleştirir. Ayrıca, acil servisler toplum sağlığının korunmasında ve iyileştirilmesinde kritik bir rol oynamaktadır. Sonuç olarak, acil servisler sağlık sistemi içinde önemli bir yer tutar ve toplumun sağlık hizmetleri ile ilk temas noktası olarak kritik bir rol oynar. Erişim engeli yaşayan bireyler için ulaşılabilir tek sağlık hizmeti türü olan acil servisler, ani sağlık sorunlarında hızlı ve etkili müdahale sağlayarak, sağlık sisteminin genel işleyişine büyük katkı sağlar. Sağlık sisteminin diğer unsurlarındaki aksamaların acil başvurusu olarak sonuçlanması mümkündür, bu nedenle acil servislerin etkin ve verimli çalışması, genel sağlık hizmetlerinin kalitesini doğrudan etkiler (Hong vd., 2018 ; Hoot ve Aronsky, 2008).

1.3.6.3. Dünyada ve Türkiyede Acil Servisler

Acil servisler, sağlık sistemlerinin en kritik bileşenlerinden biridir ve dünya genelinde hastaların acil tıbbi ihtiyaçlarına hızlı yanıt vermek için hayati bir rol oynar. Gelişmiş ülkelerde acil servisler genellikle iyi donanımlı, yüksek teknolojiye sahip cihazlarla donatılmış ve geniş kapsamlı hizmetler sunmaktadır. Bu hizmetler, travma, kalp krizi, felç ve diğer acil durumlarda uzmanlaşmış ekipler tarafından sağlanır. Acil servislerde hızlı triaj sistemleri kullanılarak hastaların aciliyet durumlarına göre önceliklendirilmesi sağlanır, böylece en kritik durumda olan hastalar öncelikli olarak tedavi edilir. Bu sistemler, hasta akışını optimize eder ve hizmet kalitesini artırır (Sun vd., 2013).

Türkiye'de ise acil servisler, son yıllarda önemli gelişmeler kaydetmiştir. Türkiye'nin sağlık sistemi, acil servis hizmetlerinin kalitesini artırmak amacıyla çeşitli iyileştirme çalışmaları yürütmektedir. Özellikle büyük şehirlerdeki hastanelerde, acil servislerin donanımı ve personel kapasitesi artırılmış, modern triaj sistemleri

uygulanmaya başlanmıştır. Ancak, kırsal bölgelerdeki acil servislerde hala bazı zorluklar bulunmaktadır. Bu bölgelerde, acil tıbbi müdahalelerin zamanında yapılabilmesi için altyapı ve personel eksikliklerinin giderilmesi gerekmektedir (Aksay vd., 2019).

Türkiye'deki acil servislerin bir diğer önemli özelliği, doğal afetler ve kitlesel acil durumlar için hazırlıklı olmalarıdır. Ülke, deprem gibi doğal afetlere karşı sık sık acil durumlarla karşı karşıya kalmakta ve bu durumlarda acil servislerin etkin bir şekilde çalışabilmesi için özel planlar ve tatbikatlar yapılmaktadır. Ayrıca, acil servis personeline yönelik sürekli eğitim programları düzenlenerek, bilgi ve becerilerinin güncel tutulması sağlanmaktadır. Bu sayede, acil servislerin hizmet kalitesi artırılmakta ve hastaların ihtiyaçlarına daha hızlı ve etkili bir şekilde yanıt verilmektedir (Gülalp vd., 2010)

Türkiye'nin deprem gibi doğal afetlere karşı hazırlıklı olabilmesi için acil servislerin rolü oldukça büyüktür. Acil servislerin afet durumlarında etkin bir şekilde çalışabilmesi için gerekli planlar ve tatbikatlar üzerinde yoğunlaşmaktadır. Bu çalışmalar, acil servislerin doğal afetler ve kitlesel acil durumlar için hazırlıklı olmaları gerektiğini vurgulamaktadır. Ayrıca, acil servis personeline yönelik sürekli eğitim programları düzenlenerek bilgi ve becerilerinin güncel tutulması sağlanmaktadır. Bu sayede, acil servislerin hizmet kalitesi artırılmakta ve hastaların ihtiyaçlarına daha hızlı ve etkili bir şekilde yanıt verilmektedir (Al, 2017).

1.3.6.4. Çalışmanın Acil Serviste Yapılmasının Nedenleri

Çalışmanın acil serviste yapılmasının pek çok nedeni bulunmaktadır. Acil servisler, hastanelerin en yoğun, karmaşık ve kritik birimleri arasında yer almaktadır. Hasta akışını doğru bir şekilde tahmin etmek, hastane operasyonlarının etkinliği ve verimliliği açısından büyük bir önem taşımaktadır. Bu nedenler aşağıda detaylı olarak açıklanmıştır (Gordon ve Casalino, 2020):

- 1. Acil Servislerin Dinamik ve Karmaşık Yapısı:** Acil servisler, haftanın her günü ve günün her saati kesintisiz hizmet vererek diğer hastane birimlerine kıyasla daha dinamik bir hasta akışına sahiptir. Sürekli hizmet, hasta akışının zaman zaman çok yoğun olabileceği ve bu yoğunluğun aniden artabileceği anlamına gelmektedir. Ayrıca, acil servisler, trafik kazaları, kalp krizi, inme gibi ani ve ciddi acil durumlarla karşı karşıya kalabilir ve bu durumlar hızlı bir

müdahale gerektirir. Bu nedenle, acil servislerin hasta sayılarının tahmin edilmesi hem daha karmaşık hem de kritik bir süreçtir.

2. **Kaynak Yönetimi ve Planlama:** Doğru tahminler, acil serviste çalışacak personelin ve kullanılacak tıbbi ekipmanın etkin bir şekilde dağıtılmasını sağlamaktadır, bu da özellikle yoğun saatlerde ve acil durumlarda hayati önem taşımaktadır. Örneğin, yoğun bir gecede yeterli sayıda doktor ve hemşirenin mevcut olması, hasta bakımının kalitesini artıracaktır. Ayrıca, kaynakların verimli kullanımı, hastane bütçesinde önemli tasarruflar sağlayacaktır. Gereksiz harcamaların önlenmesi ve ihtiyaç duyulan alanlara yatırım yapılması, genel maliyet yönetimini iyileştirecek ve acil servislerde gereksiz kaynak kullanımını önleyecek, hastane genelinde maliyetlerin düşürülmesine yardımcı olacaktır.
3. **Hizmet Kalitesinin Artırılması:** Hasta akışının doğru tahmin edilmesi, bekleme sürelerinin azaltılmasına yardımcı olacaktır. Bekleme sürelerinin kısaltılması, hasta memnuniyetini arttıracak ve acil serviste hizmet kalitesini yükseltecektir. Ayrıca, personelin hasta yoğunluğuna göre planlanması, her hastaya daha fazla zaman ve dikkat ayrılmasını sağlayacaktır. Bu, tedavi kalitesini olumlu yönde etkileyecektir. Özellikle karmaşık vakaların daha dikkatli ve özenli bir şekilde ele alınabilmesi, hasta sağlığı açısından kritik öneme sahiptir (Smith ve Roberts, 2022).
4. **Acil Durumlara Hızlı Müdahale:** Kriz yönetiminde, doğal afetler, salgınlar veya büyük kazalar gibi olağanüstü durumlarda acil servislerin hasta akışını doğru tahmin edebilmesi büyük bir avantaj sağlar. Bu, hastanenin hazırlıklı olmasını ve hızlı bir şekilde müdahale edebilmesini mümkün kılar (Örneğin, bir salgın sırasında acil servislerde yaşanacak yoğunluğu önceden tahmin etmek, hastanenin bu duruma hazırlıklı olmasına olanak tanır ve kriz durumları için etkili stratejiler geliştirilmesini sağlar. Ayrıca, beklenmedik hasta artışlarına karşı önceden planlama yaparak, personel ve kaynakların önceden ayarlanması sağlanabilir.
5. **Acil Servislerin Özgün Veri Yapısı:** Acil servisler geniş bir hasta profili yelpazesine hizmet verir. Bu çeşitlilik, veri analizi ve tahmin modelleri için zengin bir bilgi kaynağı oluşturur. Farklı yaş gruplarından, farklı sağlık durumlarına sahip hastaların verileri, daha kapsamlı ve doğru tahminler

yapılmasını sağlar. Bu zengin veri çeşitliliği, sağlık hizmetlerinin planlanması ve yönetiminde önemli bir rol oynar, çünkü hastaların değişken ihtiyaçlarına göre daha etkili stratejiler geliştirilebilir (Davis ve Lee, 2024).

6. **Kritik Kararların Alınması:** Acil servislerdeki hasta akışının doğru tahmin edilmesi, hastane yönetiminin uzun vadeli stratejik planlamalar yapmasına olanak tanır. Bu tür tahminler, yeni personel alımları, ekipman yatırımları ve hizmet iyileştirmeleri gibi kritik konularda daha bilinçli kararlar alınmasını sağlar. Doğru tahminler, hastanenin gelecekteki ihtiyaçlarını daha iyi anlamaya ve mevcut kaynakları daha etkin bir şekilde kullanmaya olanak tanır, böylece operasyonel verimlilik ve hizmet kalitesi artırılır. Bu süreç, politika yapıcıların, sağlık hizmetlerinin kalitesini ve erişilebilirliğini artıracak stratejiler geliştirmesine olanak tanır (Harris ve Adams, 2024).
7. **Toplum Sağlığına Katkı:** Acil servislerde toplanan veriler, halk sağlığı istatistiklerinin oluşturulmasında ve toplumsal sağlık sorunlarının belirlenmesinde önemli bir rol oynar. Bu veriler, toplum sağlığının durumunu anlamak ve sağlık politikalarını oluşturmak için temel bilgiler sağlar. Örneğin, acil servislerdeki hasta sayıları, hastalık türleri ve acil durumların sıklığı gibi veriler, sağlık hizmetlerinin ihtiyaçlarını belirlemeye ve toplumsal sağlık sorunlarına yönelik çözümler geliştirmeye yardımcı olur. Ayrıca, acil servis verileri, epidemiyolojik çalışmalar için değerli bir kaynak sağlar. Salgın hastalıkların yayılımının izlenmesi ve kontrol altına alınması gibi çalışmalarda, bu veriler salgınların erken tespiti ve etkili müdahale stratejilerinin geliştirilmesi açısından kritik öneme sahiptir. Bu tür veriler, epidemiyolojik analizlerin yanı sıra, sağlık krizlerinin yönetimi ve halk sağlığı stratejilerinin iyileştirilmesine katkıda bulunur (Garcia vd., 2023).

Bu nedenlerden dolayı, çalışma acil servislerdeki hasta sayılarının tahmin edilmesine odaklanmıştır. Acil servislerde yapılan doğru tahminler, hastane genelinde operasyonel verimliliği artırır ve sağlık hizmetlerinin kalitesini iyileştirir. Özellikle acil durumlara hazırlıklı olma ve hızlı müdahale edebilme yeteneği, hasta güvenliği ve memnuniyeti açısından büyük önem taşır. Bu çalışmanın bulguları, acil servislerin daha etkin yönetilmesine katkıda bulunarak, sağlık hizmetlerinin genel kalitesini artırmayı hedeflemektedir. Acil servis hasta sayılarının doğru bir şekilde tahmin edilmesi, genel sağlık sistemine birçok önemli fayda sağlar. Öncelikle, bu tahminler

sağlık kurumlarının kaynaklarını daha etkin bir şekilde yönetmelerine yardımcı olur, böylece personel ve ekipman dağılımı optimize edilir ve bekleme süreleri azaltılır. Bu, hasta memnuniyetini artırırken aynı zamanda acil durumlara daha hızlı ve etkili müdahale edilmesini sağlar. Ayrıca, doğru tahminler kriz anlarında hastanelerin hazırlıklı olmasını ve başa çıkabilmesini sağlar. Genel sağlık sisteminin dayanıklılığını artırarak, toplum sağlığını korumak için gerekli olan hızlı ve etkili tepkilerin verilmesine olanak tanır. Uzun vadede, acil servislerin hasta akışını tahmin etme becerisi, sağlık hizmetlerinin kalitesini artırarak, daha iyi hasta bakımının yanı sıra maliyet tasarrufu ve daha verimli sağlık politikalarının geliştirilmesine de katkıda bulunur (Baker ve Thompson, 2018).

Acil servis hasta sayılarının tahmin edilmesinin polikliniklere olan etkileri de oldukça önemlidir ve sağlık sisteminin genel etkinliğini artırabilir. İlk olarak, acil servislerin hasta sayılarındaki değişkenliklerin doğru tahmin edilmesi, polikliniklerin iş yükünü daha iyi yönetmelerine yardımcı olur. Acil servislerde yaşanan yoğunluk, polikliniklerin de etkilenmesine neden olabilir, çünkü acil servislerdeki hastaların bir kısmı polikliniklerdeki tedaviye ihtiyaç duyabilir. Bu nedenle, acil servislerdeki yoğunluk tahminleri polikliniklerin hasta kabul kapasitelerini ve randevu sistemlerini daha etkin bir şekilde planlamalarına olanak tanır. Ayrıca, acil servislerdeki yüksek hasta sayıları, polikliniklerdeki hasta yoğunluğunu da etkileyebilir. Tahminler sayesinde, poliklinikler acil servislerdeki olası yoğunluk dönemlerini öngörerek, bu dönemlerde ek personel veya ek hizmet saatleri planlaması yapabilirler. Tahminlerin doğruluğu, polikliniklerin acil servislerdeki hasta akışını ve bu akışın polikliniklere olan etkisini daha iyi anlamalarına yardımcı olur. Sağlık sisteminin tüm bileşenlerinin uyumlu bir şekilde çalışması, hem acil servislerin hem de polikliniklerin daha verimli hizmet sunmasını sağlar. Sonuç olarak, acil servis hasta sayılarının tahmin edilmesi, polikliniklerin iş yükünü dengelemeye, kaynakları etkili bir şekilde kullanmaya ve hasta bakım kalitesini artırmaya katkıda bulunur (McCarthy ve Aronsky, 2019).

Sonuç olarak, acil servislerde hasta sayılarının doğru bir şekilde tahmin edilmesi, sağlık hizmetlerinin genel etkinliği ve kalitesi üzerinde belirleyici bir etkiye sahiptir. Tahminler, acil servislerin karmaşık ve dinamik doğasını göz önünde bulundurarak, kaynak yönetimini optimize eder, personel ve ekipman dağılımını daha verimli hale getirir ve maliyetleri yönetilebilir düzeyde tutar. Ayrıca, doğru tahminler,

acil durumlarda bekleme sürelerini azaltarak hasta memnuniyetini artırır ve her hastaya daha dikkatli bir bakım sunulmasını sağlar. Kriz durumlarına hazırlıklı olma ve hızlı müdahale etme yeteneği, hastane yönetiminin stratejik planlamalarını destekler ve sağlık politikalarının etkin bir şekilde şekillendirilmesine olanak tanır. Bu bağlamda, acil servislerde elde edilen detaylı veriler ve tahmin modelleri, toplum sağlığı üzerindeki etkileriyle birlikte halk sağlığı istatistiklerinin oluşturulmasına ve epidemiyolojik çalışmaların yürütülmesine katkıda bulunur (Weiss & Derlet, 2022). Bu nedenlerle, acil servislerde hasta sayılarının tahmin edilmesi, sağlık hizmetlerinin kalitesini ve verimliliğini artırma amacıyla temel bir strateji olarak değerlendirilmektedir.

İKİNCİ BÖLÜM:YAPAY ZEKA İLE TAHMİN

İkinci bölümde, yapay zekanın tarihçesi ve temel unsurları incelenerek, çeşitli kullanım alanlarına odaklanılacaktır. Ayrıca, yapay zeka çeşitleri arasında uzman sistemler, bulanık mantık, genetik algoritmalar, yapay sinir ağları, bilgisayarlı görme, makine öğrenmesi, doğal dil işleme ve anlama ile robotik gibi alt başlıklar detaylı bir şekilde ele alınacaktır. Tahmin yöntemleri, kalitatif ve kantitatif yaklaşımlar olmak üzere iki ana kategoriye ayrılacak; regresyon analizi, zaman serisi yöntemleri ve Box-Jenkins tahmin modelleri gibi teknikler incelenecektir. Son olarak, yapay zeka ile tahminin avantajları ve dezavantajları detaylı bir şekilde ele alınacaktır.

2.1.Yapay Zeka Ve Talep Tahmini

Sağlık sektöründe önemli bir yer tutan yapay zeka (YZ) ve talep tahmini, geleceğin sağlık hizmetlerinin daha etkili ve sürdürülebilir olmasına katkı sağlayabilecek stratejik araçlardır. Yapay zeka, bilgisayar sistemlerine insan benzeri öğrenme ve düşünme yetenekleri kazandırmayı hedefleyen bir teknoloji alanını temsil ederken, talep tahmini ise belirli bir alandaki gelecekteki talebi önceden belirleme sürecini ifade etmektedir. Yapay zeka destekli talep tahmini, sağlık kuruluşlarına daha hassas ve etkili bir planlama süreci sunarak kaynakların daha verimli kullanılmasını sağlamaktadır. Aynı zamanda, sağlık kuruluşlarının hizmet kalitesini artırma, hasta memnuniyetini yükseltme ve rekabet avantajı elde etme fırsatı tanımaktadır. Sonuç olarak yapay zeka ve talep tahmini, sağlık sektöründe stratejik birer araç olarak önemli bir rol oynamaktadır.

2.1.1.Yapay Zeka

Yapay zeka'nın temelleri, 1956'da Dartmouth Koleji'nde düzenlenen konferansla atılmıştır. Bu dönem, bilim dünyasında önemli bir devrimin başlangıcını işaret eder. Alan Turing, yapay zeka fikrinin öncüsü olarak kabul edilir ve o dönemdeki önde gelen bilim insanları, yapay zekanın tasarlanması, araştırılması ve geliştirilmesi için bilimsel önerilerde bulunmuşlardır (Adalı, 2017). Yapay zeka, tarihin akışını değiştiren, insanoğlunun varoluşuna yeni bir boyut katan olaylardan biridir. İnsanlık için ateşin keşfi, yazının icadı veya tekerleğin bulunuşu kadar önemli bir icat olarak kabul edilebilir. Bu nedenle, yapay zeka, insanlığın tarihindeki önemli dönemlerden biri olarak kabul edilir (Franchi ve Güzeldere, 2005).

Yapay zekanın kesin bir tanımını yapmak oldukça zordur, çünkü bu kavram sürekli evrilen ve karmaşıklaşan bir alan içerisinde. Genel bir ifadeyle, zeka; bilgi ve becerilerin kazanılması ve bu bilgi ve becerilerin uygun yer ve zamanda kullanılmasını sağlayan bir yetenektir. Yapay zeka ise; bu yeteneklerin, bilgisayarlar aracılığıyla yapay olarak kazanılması olarak tanımlanabilir (Legg ve Hutter, 2007). Yapay zeka, birçok sektörde yoğun araştırma ve geliştirme faaliyetlerine konu olan, hızla evrim geçiren bir alandır. Yapay zeka, gün geçtikçe yeni icatlar ve inovasyonlarla karşımıza çıkmakta, bu da yapay zekanın farklı özelliklerini ortaya çıkarmakta ve bu özellikler, teknolojinin insan benzeri algılamaya, düşünmeye, uygulamaya ve karar vermeye yeten bir seviyeye ulaşmasına neden olmaktadır (Bozüyük vd., 2005).

Yapay zekanın temel amacı, insan düşünme ve karar verme yeteneklerini taklit ederek benzer bir kapasiteye ulaşmaktır. Ancak, birçok bilim insanı yapay zekanın bu hedefe tam olarak ulaşamayacağını düşünmektedir. Mikroçiplerin icadıyla daha enerji verimli ve karmaşık bilgileri işleyebilen makineler haline gelen yapay zeka, insan zekasıyla yarışır hale gelmiş ve bazı durumlarda onu geçmiştir (Dore, 2012). Yapay zeka, bilgiyi anlama, işleme ve karar alma yetenekleriyle öne çıkarken, mantıksal fikirler üretme ve sonuç çıkarma süreçlerinde insan zekasını taklit eder. Aşağıda tablo 2.1'de farklı yaklaşımlara göre yapay zeka tanımları verilmiştir (Anderson, 1990; Cohen, 1987; Russell ve Norvig, 2016):

İnsana Özgü Düşünce	Rasyonel Düşünce
-İnsanlar gibi düşünebilen makinaların ortaya çıkarılması çabası. -İnsanlar gibi anlama,algılama ve karar verme özelliklerine sahip yapay bir zeka.	-Zihinsel yeteneklerin araştırılması ve geliştirilmesinde birçok hesaplama model ve uygulamaların kullanılması. -Anlama, öğrenme, karşılaştırma ve seçme gibi davranışların araştırılması ve geliştirilmesi.
İnsana Özgü Davranma	Rasyonel davranma

-İnsan zekasının yerine getirdiği davranışları yapma yeteneğine sahip yapay makinalar	-Yapay zekanın zeki bir şekilde hesaplama davranışlarının araştırılması."
-İnsanların başarılı bir şekilde yerine getirdikleri şeylerin yapay zeka tarafından ne derece başarılı olacağı.	-Yapay zekanın herhangi bir olgu karşısında davranış biçimlerinin konu edinmesi.

Tablo 2. 1. Farklı Yaklaşımlara Göre Yapay Zeka Tanımları

2.1.1.1. Yapay Zekanın Tarihi

Yapay zeka kavramının ilk izlerinin, antik medeniyetlere kadar uzandığı görülmektedir. Eski çağlardaki birçok medeniyet, cansız varlıkları canlandırma ve harekete geçirme arzusunu taşımıştır. Yunan mitolojisine bakıldığında, tanrıların yapay insanlar oluşturma çabalarına dair efsanelere rastlanmaktadır. Yapay zeka, sadece modern bilim ve teknoloji ile sınırlı kalmayıp, tarihsel derinliğe sahip zengin bir geçmişe de sahiptir. Antik Yunan'da başlayan bu yapay varlık oluşturma arzusu, günümüzdeki yapay zeka çalışmalarının temelini atmış ve insanoğlunun oluşturma güdüsünü yansıtmıştır. Bu tarihsel bağlamda, yapay zekanın geçmişi, günümüzdeki teknolojik gelişmeleri anlamamıza ve gelecekteki potansiyelini değerlendirmemize ışık tutacaktır (McCorduck, 2004).

1623 yılında Wilhelm Schickard'ın tasarladığı bilinen ilk hesap makinası, yapay zeka alanındaki ilerlemeye daha somut bir katkı sağlamıştır. Ardından, 1642 yılında Blaise Pascal'ın icat ettiği Pascaline adlı hesap makinası, popülerlik kazanarak yaygın bir kullanıma ulaşmıştır. Gelişmeler devam ederek, 1672 yılında Gottfried Leibniz'in Pascaline'i geçen, toplama ve çıkarma işlemlerinin yanı sıra çarpma ve bölme işlemlerini de gerçekleştirebilen çok basamaklı bir hesap makinasını bulmasıyla devam etmiştir (Russell ve Norvig, 2016). Bu dönemdeki matematiksel hesaplamalara yönelik icatlar, bilgisayar teknolojisinin temellerini atan önemli adımlardır ve günümüzdeki yapay zeka gelişimine zemin hazırlayan geçmişin izlerini taşımaktadır (Pirim, 2006).

Yapay zekanın temel amacı insanların yapabileceği bütün işlemleri yapabilecek makinaların oluşturulmasıdır. İnsanlar gibi algılayabilen, tahminlerde bulunabilen, ortaya çıkan problemleri çözme yeteneğine sahip, seçenekler arasında seçim yapabilen

ve sonrasında kontrol yapma özelliğine sahip makinaların oluşturulması amaçlanmıştır (Boden, 2018). Yapay zekayla birlikte insanlar gibi verileri elde edip bunları belirli algoritmalarla işleyen ve karar verebilen makinalar ortaya çıkmıştır. Bu makinaların hayatımıza girmesiyle birlikte insan eliyle yapılan birçok işin makineler tarafından yapılmasına neden olmuştur. Makinalar, insanların yaptıkları işlerin daha kolay hale gelmesine sebep olmuş ve birçok işi de insanların elinden almıştır (Pöhler vd., 2018).

Yapay zeka, yapılan araştırma ve çalışmalarla her geçen gün gelişim göstermiştir. Aşağıda geçmişten günümüze bazı yapay zeka çalışmaları kronolojik olarak sıralanmıştır:

- Yapay zeka alanında ilk çalışma, 1956'da 12 kişinin katılımıyla Dartmount Çalıştayında gerçekleşmiştir. Bu çalışmada yapay zekanın, insanların karşılaştıkları problemleri çözebilmesi ve kendi kendilerini nasıl geliştireceği üzerinde durmuşlardır (Tegmark, 2019).
- 1959 yılında Arthur Samuel tarafından geliştirilen, dama oynayabilen bir bilgisayar programı ile yapay zeka alanında önemli bir kilometre taşını ortaya koymuştur. Bu program, yapay zekaya sahip ilk oyun programlarından biridir ve yapay zeka araştırmalarının başlangıcını işaret etmektedir. Ancak, başlangıçta sadece algoritmanın izin verdiği sınırlı hamleleri yapabilen bu program, Arthur Samuel'e karşı sürekli olarak mağlup olmuştur. Zamanla, programın hamle yapma yeteneği geliştirilerek daha doğru kararlar alabilmesi sağlanmıştır. Program, zaman içinde yapılan hesaplamalarla dama oyununda ustalaşmaya başlamış ve kendi oluşturucusu olan Arthur Samuel'e karşı üstünlük sağlamıştır (Eberl, 2019).
- 1980 yılının ortalarına kadar, yapay zeka gelişimsel sürecini devam ettirmiştir. Bu yıllarda yapay zeka alanında devrim sayılacak “nöron ağları” kavramı ortaya çıkmıştır. İnsan beynindeki sinir ağları yapay zekaya uyarlanmıştır (Eberl, 2019).
- 1996 yılında IBM'nin Deep Blue adlı bilgisayarı, Dünya Satranç Şampiyonu Garry Kasparov ile tarihi bir müsabakaya girişmiştir. Ancak, bu ilk maçta Kasparov'a karşı mağlup olmuştur. 1997 yılında aynı bilgisayar, Kasparov'u yenmiştir. Bu olay, yapay zeka ve bilgisayarların insanların uzmanlık

alanlarında üstünlük sağlamaya başladığı bir döneme işaret etmiştir (Koç, 2018).

- 2010'da Apple şirketi tarafından Siri adında bir asistan program oluşturulmuştur. Program sorulan soruları cevaplamakta, belirli konularda tavsiylerde bulunmakta ve internet hizmetlerini gerçekleştirmektedir (Eberl, 2019).
- 2011 yılında, doğru bilgi, yorum ve hızın ölçüldüğü Jeopardy (Riziko) adlı yarışmada, bir bilgisayar olan Watson, iki insan rakibiyle mücadele etmiştir. Birinci yarışmacı, 74 galibiyetle yarışmanın en başarılı ve uzun süre yenilmeme özelliğine sahip yarışmacı, diğer yarışmacı ise en yüksek ödülü kazanan yarışmacıdır. Watson, yapay zeka olarak, rakiplerine karşı büyük bir üstünlük sağlayarak birinci olmayı başarmıştır (Mesko, 2018).
- 2015 yılında Google DeepMind şirketi, aynı anda birçok oyunu öğrenebilen ve bu oyunlarda yüksek becerilere ulaşabilen bir yapay zeka programı geliştirmiştir. Şirket, 2016 yılında Go oyununu oynayabilen ve oldukça karmaşık olan AlphaGo adlı yapay zekayı oluşturmuştur. Yapay zeka, 1997'de Kasparov'u yendiğinden bu yana geçen yaklaşık 20 yılda Go oyununda ustalaşma seviyesine ulaştığını göstermiştir (Tegmark, 2019 ; Koç, 2018).
- Bir sene sonra, AlphaGo Zero adlı yeni bir yapay zeka programı geliştirilmiştir. Bu yapay zekaya oyunun temel kuralları öğretilmiş ve makine, kendi kendini geliştirerek AlphaGo'yu mağlup etmeyi başarmıştır. Bu yeni yapay zeka, yaklaşık 2500 yıldır oynanan Go oyununda, bugüne kadar hiçbir insanın üretemediği yeni stratejiler bulmuş ve yeni hamleler keşfetmiştir. Go oyununun dünyadaki en iyi oyuncusu olan Lee Sedol, programa karşı ezici bir yenilgi almıştır (Koç, 2018,).

2.1.1.2. Yapay Zekanın Temel Unsurları

Yapay zeka programlarının etkili bir şekilde oluşturulması için sistematik bir yaklaşım benimsemek oldukça kritiktir. Bu programların sağlam bir temel üzerine inşa edilmesi, yapay zekanın temel unsurlarını içermelidir. Yapay zekanın bu temel unsurları, doğrulama, geçerlilik, güvenlik ve denetim olarak dört ana başlık altında sıralanabilir. Bu dört temel unsur, yapay zeka programlarının sağlam, güvenilir ve

etkili bir şekilde çalışmasını sağlamak adına önemli bir temel oluşturur. Bu 4 temel unsur açıklanmıştır.

-Doğrulama: Doğrulama süreci, bir varsayımın doğru veya yanlış olduğunun belirlenen yöntemlerle incelenmesidir. Yapay zeka tabanlı programlar, oluşturulma ve geliştirilme sürecinde sürekli deney ve gözlem yaparak doğrulukları denetlenmelidir. Temel amaç, programların belirlenen hedeflere uygunluğunu kontrol etmektir. Bu amaçlar net olmalı ve elde edilecek sonuçların niteliği önceden belirlenmelidir. Yapay zeka programları belirli aralıklarla doğrulanarak etkin, verimli ve güncel kalması sağlanır. Bu süreç, ortaya çıkan hataların önceden tespit edilmesine ve zamanında müdahale edilmesine olanak tanır (Russell vd., 2015).

-Geçerlilik: Geçerlilik unsuru, yapay zeka için hayati öneme sahip bir kavramdır. Herhangi bir yapay zekanın doğruluğunun belirlenmesi, geçerlilik unsuruyla mümkündür. Programın tasarımı, işlevselliği, donanımsal özellikleri ve özelliği belirlenen hedeflere uygunluğu geçerlilik açısından değerlendirilir. Elde edilen sonuçların hedeflenenle karşılaştırılması ve eksikliklerin belirlenmesi, geçerliliği sağlamak için önemlidir. Bu eksikliklerin giderilmesiyle yapay zekanın geçerliliği ve etkinliği artacaktır (Russell vd., 2015).

-Güvenlik: Günümüzde yaygın olarak kullanılan yapay zeka tabanlı cihazlar ve programlar, bireylerin ve toplumun çeşitli zorlukları aşmasına büyük ölçüde yardımcı olmaktadır. Hayatımızı kolaylaştıran etkili çözümler sunan bu araçlar, günlük yaşantımızın vazgeçilmez bir parçası haline gelmiştir. Ancak, bu hızlı gelişim beraberinde güvenlik endişelerini de getirmiştir. Gelecekte robotların insanlığı tehdit etme endişesi, yapay zeka uygulamalarının belirli bir güvenlik protokolünden geçirilmesi ve sürekli olarak kontrol edilmesi gerekliliğini vurgulamaktadır. Bu önlemler, yapay zeka teknolojisinin toplum için daha güvenli ve sürdürülebilir hale gelmesini sağlamak adına kritik bir rol oynamaktadır (Scherer, 2016).

-Denetim: Yapay zeka tabanlı makineler veya uygulamalar geliştirildikten sonra sürekli denetlenmeleri gerekmektedir, çünkü sonradan ortaya çıkabilecek çeşitli sorunlar ciddi risklere yol açabilmektedir. Örneğin, günümüzde kendi kendini kullanabilen arabaların sadece yapay zekaya bırakılmaması, gerektiğinde insan kontrolünün devreye alınmasını gerektirmektedir. Yapay zeka, günümüzde gelişmiş bir

alan olmasına rağmen, hala insan müdahalesinin olmaması mümkün değildir (Russell vd., 2015).

2.1.1.3. Yapay Zekanın Kullanım Alanları

Yapay zeka geçmişten günümüze hızlı bir şekilde insan hayatına girmiştir. Teknolojinin gelişmesiyle birlikte maliyetler azalmış ve yapay zeka tabanlı makinelerin üretilmesi kolaylaşmıştır. Buda beraberinde yapay zeka'nın birçok sektöre etki etmesine, birçok sektörde kullanılmasına ve birçok sektöre yön vermesini sağlamıştır. Aşağıda yapay zekanın kullanıldığı başlıca sektörler sıralanmıştır (Mesko, 2018):

- **Otomotiv Sektörü:** Yapay zeka'nın otomotiv sektöründe kullanılması beraberinde çeşitli avantajları bize sunmaktadır. Örneğin: Yapay zeka tabanlı sürücü asistanları birçok sensöre sahiptir. Bu sensörler gerektiği durumda sürücüye yardımcı pilot görevi üstlenebilmektedir.
- **Dil Çevirici Sistemler:** Günümüz dünyasında küreselleşme sonucunda farklı dilleri konuşan insanların birbirini anlayabilmesi için yapay zekanın bu alanda kullanılması yaygınlaşmıştır.
- **Eğitim sistemleri:** Yapay zeka günümüzde birçok eğitim uygulamalarında kullanılmaktadır. Örneğin: yapay zeka tabanlı değerlendirme, otonom bir şekilde test oluşturma, verilerin analizi, eğitimde veri madenciliği gibi.
- **Hukuk sistemi:** ABD'de bulunan bir hukuk firması, IBM'in geliştirdiği Robot Yargıç ROSS'u işe almıştır. Bu yapay zeka, makine öğrenmesiyle davaları incelemiş ve sonuca ulaşmıştır. Ancak yapay zeka'nın henüz avukat ve hakimlerin yerini alacak düzeyde gelişmediği görülmüştür. Çünkü ROSS %79'luk bir oranda doğru karar vermiştir. Bu da hukuk alanı için oldukça düşük bir orandır (Gürel, 2017).
- **Askeri sistemler:** Yapay zeka'nın askeri alanda etkin kullanılması, o ülkenin savaş üstünlüğü kazanması demektir. Bu yüzden, savunma sanayisinde yapay zeka veri tabanlı teknolojiler oldukça önemlidir. Birçok askeri aracın insan müdahalesi olmadan işlemesi, yazılımlarla daha etkili ve verimli savaş aletleri üretilmesi, askeri personelleri koruyucu birçok araç-gerecin üretilmesi bunlara örnektir.

- **Finans sistemi:** Finans sektörünün kullandığı yapay zeka tabanlı uygulamalar, bankacılığa ait tüm işlemlerin yapılmasına olanak sağlamaktadır. Bu yüzden finans sektörü işlemleri daha da hızlı yapmak, müşteri memnuniyetini arttırmak ve yeni müşteriler kazanmak için yapay zeka kullanımına önem vermektedirler (Işkın, 2012).
- **Sağlık ve tıp sektörü:** Günümüzde sağlık ve tıp alanında yapay zeka kullanımı her geçen gün artmaktadır. Kliniklerde yardımcı karar desteği, hastaların düzenli bir şekilde izlenmesi, hastalığı teşhis etmede yardımcı araçlar, cerrahi müdahaleleri kolaylaştırmak için kullanılan teknolojiler, bazı değerlerin ölçümünü yapan makineler vb. birçok uygulama sağlıkta yapay zeka'nın ne kadar yaygın olduğunu gösteren örneklerdir. (Chen vd., 2016).

2.1.2. Yapay Zeka Çeşitleri

Yapay zekanın hızlı gelişimi ve yaygınlaşması, günlük yaşantımızın pek çok alanında etkin bir rol oynamaktadır. Akıllı telefonlardan ev otomasyon sistemlerine, otomobillerden iş hayatına kadar birçok alanda yapay zeka teknolojileri entegre edilmiştir, bu da yaşam biçimimizi dönüştürmüş ve bir dizi sektörde verimliliği artırmıştır. Yapay zeka, teknolojik gelişmelerin ötesinde, sağlık hizmetlerinden eğitim sistemlerine kadar geniş bir yelpazede toplumsal etkileşimleri ve günlük rutinleri etkilemiştir (McPherson, 2018).

Yapay zeka'yla birlikte insanların yapabildikleri birçok iş yapay zeka tarafından yapılmaya başlanmıştır. Herhangi bir işte profesyonel bir insanın yapabildiği işi yapay zeka daha iyi bir şekilde yapabilecek seviyeye gelmiştir. Yapay zeka karmaşık ve oldukça zor problemleri basit bir şekilde çözebilecek ve birçok seçenek arasında en doğru kararı verebilecek hale gelmiştir. Yapay zekanın geldiği bu nokta oldukça ileri seviye olmasına rağmen henüz tam anlamıyla gerçek gelişimine ulaşmamıştır. Her geçen gün yapay zeka biraz daha gelişmekte ve yeni sektörlerde yerini almaktadır (Boden, 2018).


2.1.2.1. Uzman Sistemler

1974'te T. Shortliffe tarafından geliştirilen 'MYCIN' programı, tıpta tanı yapabilme yeteneğiyle uzman sistemlerin temelini atmıştır. Bu sistemler, uzman bir insanın problem çözme sürecine benzer şekilde çalışarak kararlar verebilmektedirler.

Uzman bir kişinin bilgi, beceri ve yetenekleri bu programlara aktarıldıktan sonar, karşılaşılan herhangi bir problemde bu uzmanlık düzeyinde davranabilmektedirler. 1980'li yıllarda, uzman sistemler hem Amerika hem de Avrupa'da popüler hale gelmiş ve birçok ticari kuruluş tarafından kullanılmaya başlanmıştır. Ancak, bu dönemde uzman sistemlerin kullanımı belirli alanlarda ve sınırlı uygulamalarda gerçekleşmiştir (Alpaydın, 2016).

Uzman sistemler belirli bir alanda uzmanlık isteyen sistemleri kapsamaktadır. Bir işin veya eylemin gerektirdiği özel bilgileri içermektedir. Bilgisayar modellemesi yapılarak bu programların uzman olmayan kişiler tarafından kullanılmasında olanak tanınmaktadır. Sağlık ve askeri alanlarda kullanılan uygulamalar örnek verilebilir. Uzman olmayan kişiler bu uygulamaları kullanarak uzman kişilerin yapabileceği işleri yapabilirler (Nabiyev, 2012). Uzman sistemler, bilgilerin depolandığı bilgi tabanlı bir sistemdir. Bu sistemler, belirli bir algoritmaya dayanmamaktadır. Programa girilen bilgiler yada önceden mevcut olan bilgilere göre arama yapar ve birçok veriye ulaşır. Sonrasında uygun olan bilgileri alır ve bu verileri işleyerek yeni verileri üretir (Allahverdi, 2002).

Yapay zeka alanının alt dallarından en fazla bilineni Uzman Sistemlerdir. Birnevi bir işteki yapay uzman niteliğindedir. Uzman kişinin zekasının taklit edilme prensibine dayanmaktadır. Bilgiler, bilgi tabanında depolanır, herhangi bir sorunla karşı karşıya gelme durumunda içerisinde bulunan bilgiler kullanılır ve bu bilgiler ışığında bir çıkarım yapılır (Naser ve Alhabbash, 2016). Şekil 2.1'de uzman sistemlerin yapısı gösterilmiş ve açıklanmıştır (Bozdemir, 2019).



Şekil 2. 1. Uzman Sistem Yapısı

-Bilgi Tabanı (Knowledge Base): Uzman sistemlerin bilgi tabanı, belirli bir uzmanlık alanındaki bilgileri ve kuralları içerir. Bu bilgiler, uzman bir kişinin deneyim ve bilgisini yansıtan ifadeler, kavramlar ve kurallar şeklinde temsil edilir. Örneğin, bir tıbbi uzman sistemde, hastalıklar, semptomlar ve teşhis yöntemleri gibi tıbbi bilgiler bulunabilir.

-Çıkarım Motoru (Inference Engine): Çıkarım motoru, bilgi tabanındaki kuralları ve bilgileri kullanarak sonuç çıkaran bir mekanizmadır. Kullanıcıdan alınan sorular veya girdiler, çıkarım motoru tarafından işlenir ve bilgi tabanındaki kurallar ve bilgilerle eşleştirilerek sonuç üretilmektedir.

-Kullanıcı Arabirimi (User Interface): Kullanıcı arabirimi, sistemi kullanmak için kullanıcının etkileşimde bulunduğu arayüzdür. Kullanıcılar genellikle sistemden sorular alır veya belirli bir konuda tavsiyelerde bulunmaları istenir. Kullanıcı arabirimi, sistemin girdi almasını, çıktı üretmesini ve kullanıcıyla etkileşim kurmasını sağlar.

-Açıklama Modülü (Explanation Module): Bazı uzman sistemler, algoritmanın nasıl bir sonuca ulaştığını veya nasıl oluşturduğunu açıklayabilen bir açıklama modülü içermektedir. Kullanıcılara sistem tarafından verilen tavsiyelerin veya sonuçların arkasındaki düşünce sürecini anlama konusunda yardımcı olabilmektedir.

2.1.2.2. Bulanık Mantık

1965'te Lütü Aliasker Zade tarafında yayınlanan bir makale sonucunda ortaya çıkmış bir mantık yapısıdır. Bu mantığın temeli bulanık kümeler ve altkümelere dayanmaktadır. Burada temel konu bilgisayarların insan gibi muhakeme yeteneğine sahip olmamasıdır. Çünkü bilgisayarlar rakamsal ifadelerle dayanır. Örneğin: Sıcaklık kavramı kişiden kişiye göre değişkenlik gösteren bir kavramdır. Kars ilinde yaşayan bir insan için hava sıcaklığının 30 derece olması yüksek algılanırken, güneydeki bir ilimizde(Şanlıurfa) yaşayan insan için 30 derece çokta sıcak olarak algılanmayabilir (Şen, 2004). Bu modellerin kullanılmasıyla bir çok akıllı sistem oluşturulabilmektedir. Mantık kavramına klasik bakış açısıyla bakıldığında, küme elemanları belirli ve kesindir. Yani bir şey ya o küme elemanıdır ya da değildir. Bulanık mantıkta ise bu durum böyle değildir. Belirli bir kesinlik veya netlik yoktur. Herhangi bir eleman birden fazla kümeye ait olabilir ya da herhangi bir kümenin kısmi olarak üyesi olabilmektedir (Tiryaki ve Kazan, 2007).

Bulanık mantığın ticari anlamda ilk defa kullanılması 1982’ de Danimarka’daki bir çimento fabrikasında fırının kontrol edilmesi amacıyla kullanılmıştır. Oldukça zor ve karmaşık yapıdaki fırınların işleyişini iyi bir şekilde yapmış ve fırınların içindeki karışım malzemelerinin oranını hassa bir şekilde ayarlamıştır (Bai ve Wang, 2006). Bulanık mantık 1987’de Japonyada Sendai Metrosundaki trenlerin denetiminde kullanılmıştır. Ortaya çıkan sonuca göre bulanık mantığın kullanıldığı trenlerdeki enerji tüketimi, diğer trenlere göre %10 daha düşük olmuştur. Bu gelişmeler bulanık mantığın kullanılmasını yaygınlaştırmıştır (Schwartz ve Klir, 1992). Sonrasında 1989’ da bu sistemlerin başarılı olmasından dolayı, bulanık mantığa olan ilgi iyice artmış ve bu alanda çalışmalar başlamıştır. Japonya’da 28 Mart 1989 tarihinde, 50 şirket, birleşerek Laboratory for International Fuzzy Engineering Research (LIFE) adında araştırma laboratuvarı kurup, bulanık mantık alanında ortak inceleme ve çalışmalar yapmışlardır (Davis, 1994).Aşağıda şekil 2.2’de Bulanık Mantık yapısı gösterilmiş ve açıklanmıştır (Gündoğdu vd., 2016):



Şekil 2. 2. Bulanık Mantık Sisteminin Yapısı

-Bulanıklaştırma: Bu aşamada, giriş değişkenleri bulanık kümeler halinde ifade edilir. Bu kümeler, üyelik fonksiyonları ile tanımlanır ve her bir giriş değişkeni için belirli bir üyelik derecesine sahip olabilir. Örneğin, sıcaklık giriş değişkeni, "soğuk", "ılıman" ve "sıcak" gibi bulanık kümelerle ifade edilebilir.

-Kural Tabanı: Bulanık mantık, "eğer - o zaman" kurallarını kullanır. Bu kurallar, giriş değişkenlerinin bulanık kümeleri ile çıktı değişkeninin bulanık kümeleri arasındaki ilişkiyi ifade eder. Örneğin, "Eğer sıcaklık sıcaksa, o zaman vantilatör hızını artır" gibi bir kural olabilir.


-Çıkarım Birimi: Bu aşamada, belirli bir durum için çıktı değişkeninin bulanık kümeleri hesaplanır ve bu değişkenlerinin bir araya getirilmesiyle yapılır.

-Durulaştırma: Belirleme aşaması, bu bulanıklığı daha anlaşılır bir çıktıya dönüştürmek için kullanılır. Genellikle, bulanık çıktıyı bir kesin değere çevirme işlemidir.

2.1.2.3. Genetik Algoritmalar

Bu algoritma Charles Darwin'in evrim teorisinin temellerine dayanmaktadır. Burada evrim teorisinin doğal seçim sürecinin bir taklidinin oluşturulması söz konusudur. Bu süreç evrim teorisine benzer bir şekilde programlarla oluşturularak en uygun seçilimin yapılması sağlanır. Genetik algoritmanın en temel özelliği, problemlere tek çözüm üretmek yerine, birçok çözüm üretebilmektir. Ortaya çıkan sonuçlar birbirinde bağımsızdır ve en iyi sonuca ulaşma amaçlanmaktadır (Elmas, 2011).

Genetik algoritmalar tıpkı doğadaki gibi en iyi olanın sağ kalması ve hayatını devam ettirebilmesi kuralına göre çalışırlar. Bu yüzden sürekli en iyiyi arama süreci içerisindedirler. Herhangi bir sorunun çözümü sürecinde, seçenekler arasındaki en iyi çözüm yöntemini belirlenmesi uygunluk fonksiyonuyla, sonrasında daha iyi bir çözüme ulaşmak için ise kopyalama veya değiştirme fonksiyonlarını kullanırlar (Çalışkan, Yüksel ve Dayık, 2016). Aşağıda Şekil 2.3' te genetik algoritmanın akış ve çalışma şeması gösterilmiştir (Holland, 1975):



Şekil 2. 3. Genetik Algoritmanın Genel Akış Şeması

Yukarıdaki şekilde de görüldüğü gibi genetik algoritmanın aşamaları şu şekildedir:

1.Adım (Başlangıç Popülasyonunun Oluşturulması): Bu aşamada herhangi bir problemin ortaya çıkabilecek çözümleri oluşturulmaktadır. Kromozomların gelişigüzel bir şekilde seçilerek, başlangıç popülasyonunun oluşturulma aşamasıdır.

2.Adım (Sınır Şartlarının Ve Uygunluk Fonksiyonunun Belirlenmesi): Bu aşamada belirli sınır çerçevesinde kromozomların belirlenmesi ve belirlenmiş hedef fonksiyonları uygunluk derecelerine göre değerlendirilmeye alınırlar.

3.Adım (Başlangıç Popülasyonunun Oluşturulması Ve Uygunluk Değerlerinin Belirlenmesi): Sistem içerisindeki her kromozomun uygunluk dereceleri hesaplanır. En iyi dereceye sahip kromozomlar seçilir. Seçilen bu 2 ebeveyne çaprazlama operatörü uygulanır. Bunlara çaprazlama operatörü uygulandıktan sonra, genetik bilgisinin değiştirilmesiyle yeni bir kromozom elde edilir. Diğer bir evrede mutasyon aşamasıdır. Burada bir geni meydana getiren kromozonların değiştirilmesi söz konusudur (Bağış ve Özçelik, 2008).

4.Adım (Sonlandırma kriterinin sağlanması): Tüm bu aşamalardan sonra hedeflenen çözüm sağlanıyorsa süreç sona erer. Eğer sağlanma gerçekleşmezse tekrar yeniden üretim adımına geri dönülür (Vatansever ve Şen, 2013).

2.1.2.4. Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin çalışma sistemini taklit eden ve insan beyni gibi, bilgileri algılama ve öğrenme fonksiyonlarını yerine getirebilen bilgisayar programlarıdır. Bu öğrenme fonksiyonunu gerçekleştirirken birbirine bağlı ağlar yardımıyla yaparlar. Bu ağlarda birbirlerine bağlı yapay sinirlerden oluşur. Bu yöntemin, günümüz dünyasında her alanda başarılı örnekleri mevcuttur. Herhangi bir yapay sinir ağının oluşturulmasında çok karmaşık bir süreç olmasına rağmen, bu sisteme olan ilgi gittikçe artarak devam etmektedir. Sistem tanımlaması ve kontrolü, ses ve görüntü tanıma sistemleri, iş analizi, sağlık, ulaşım ve haberleşme sistemleri, tahminleme vb. birçok alanda kullanılan yaygın bir yöntemdir (Öztemel, 2012).

Biyolojik sinir sistemi, insan beyninin tepki verme süresinin kusursuz olmasını sağlayan, aynı anda algılayan, seçenekler oluşturabilen ve bu seçenekler arasında karar verebilen sinir ağlarından oluşmaktadır. Biyolojik sistemde, sinir ağları duyu

organlarından alınan bilgilerin beyne ulaştırılması ve bu bilgilerin gereken yerlere taşınması işlevini görürler. Tüm bu görevler nöron denilen sinir hücreleri tarafından gerçekleştirilirler. Yapay sinir ağları tıpkı insan biyolojik sinir sistemiyle benzer şekilde ve onu taklit ederek çalışmaktadır. Bu yapı, bilgilerin alınması, mantıklı bir biçimde algılanması, bu bilgilerin merkeze gönderilmesi ve sonrasında bilgilerin gereken yerlere taşınması işlevini gerçekleştirirler (Sharma, Rai ve Dev, 2012).Yapay sinir ağlarının esas işlevleri aşağıdaki şekilde açıklanmaktadır(Uğur ve Kınacı, 2006):

-Öngörü yada Tahminleme: Yapay sinir ağlarıyla birçok sektörde ileriye yönelik öngöründe bulunulabilmektedir. Örneğin: Bir firmanın gelecekteki satış miktarı, şans oyunlarının tahmini, gelecekte karşılaşılailecek çevresel risklerin öngörülmesi gibi.

-Sınıflandırma yada Kümeleme: Aynı veya benzer unsurları herhangi bir özellik yönünden sınıflandırma yada bir ayrıma göre kümeleme. Örneğin: Ticari bir şirketin müşterileri profillerini sınıflandırması, sağlık alanında benzer vakaların teşhisi gibi.


-Kontrol: Birçok alanda ortaya çıkabilecek sorunların engellenmesi adına sürekli kontrol edilmesi. Örneğin: yangın uyarı sistemleri gibi.

-Veri İlişkilendirme: Yapay sinir ağlarının önceden sahip olduğu bilgileri kullanarak eksik olan bilgileri tamamlaması. Örneğin: eksik olan bir resmin tamamlanması, bir firmanın muhasebe biriminde eksik olan sayısal verilerin tamamlanması gibi.

-Verileri Yorumlama: Yapay sinir ağları sahip olduğu verileri analiz ederek yeni yorumlamalar yapabilir. Örneğin: ticari bir firmanın finansal oranlarının yorumlanması, öğrencilerin sınav sonuçlarının yorumlanması gibi.

-Veri Filtreleme: Birçok veri arasında seçim yaparak uygun verileri belirleme.

Aşağıdaki şekilde yapay sinir hücresinin genel yapısı gösterilmiştir (Kaynar ve Taşkan, 2009):



Şekil 2. 4. Yapay Sinir Hücresi

Yapay sinir hücresi, biyolojik sinir hücresine benzer şekilde çalışmaktadır. Bu hücreler tıpkı insan sinir hücreleri gibi algılayabilme, anlamlandırabilme ve öğrenebilme özelliğiyle yeni bilgiler üretebilme, bu bilgilerin uygun zamanda gereken yerlere iletebilmesi işlemini gerçekleştirirler. Daha basit anlatılacak olursa; birçok bilgiyi aynı anda işleyebilen, karmaşık yapıdaki bilgileri anlamlandırabilen, birçok çözüm arasında en iyi çözümü seçip karar verebilen insan bu işlemleri yaparken insan beynini takip eden birimlerdir. Biyolojik sinir hücresine benzer şekilde 5 ana bileşeni vardır. Bu ana bileşenler girdiler, ağırlıklar, toplama işlevi, aktivasyon fonksiyonu ve çıkış bileşenleridir.

2.1.2.5. Bilgisayarlı Görme (Vision)

Yapay görme olarak isimlendirilen bu yöntem nesneleri insan gözünün gördüğü gibi algılamayı, tanımlayı ve sınıflandırmayı amaçlayan oldukça yaygın kullanılan yapay zeka'nın alt dalarından biridir. Nesnelerin şekilleri, renkleri gibi nesnel özelliklerini tanımlayarak insan gibi görebilmeyi amaçlayan uygulamalardır. Her geçen gün bilgisayarlı görme örnekleri hayatımızın her alanında karşımıza çıkmaktadır. Örneğin: Otoparklara girerken kamera sistemlerinin plaka tanıma uygulamasıyla, giriş ve çıkış yapan plakaları algılayarak bilet vermesi, günlük hayatta kullandığımız harita uygulamalarının havadan görüntü alarak çalışması, film ve dizi sektöründe görüntü yakalama yöntemiyle çalışılması, yapay görme yöntemiyle trafik denetlemelerinin yapılması vb. birçok alanda kullanılmaktadır. Bu yöntemle hem zaman hemde finansal açıdan maliyetler azaltılmakta ve hizmetler daha etkin ve verimli olmaktadır (Szeliski, 2011).

2.1.2.6. Makine Öğrenmesi

Makine Öğrenmesi insanların algılama, tanımlama ve öğrenme süreçlerinden esinlenerek ortaya çıkmıştır. İnsan sürekli bir öğrenme döngüsü içerisinde, doğumdan ölüme kadar sürekli öğrenerek gelişir. Bir nesnenin tanımlanabilmesi geçmiş deneyim ve tecrübelerle dayanmaktadır. Örneğin: Herhangi bir nesne hakkında bilgi alarak ve zamanla bunu anlamlandırarak sonrasında bunu öğrenerek tanıyabilmekteyiz. Bir meyvenin kokusu, rengi, tadını deneyimleyerek onun elma veya portakal olduğunu öğrenerek tanımlayabiliriz. İşte makine öğrenmesi de aynı bu mantıkla çalışmaktadır. Elde edilen bilgileri algılama yoluyla öğrenerek tanımlama yapar. Bunu yaparken insanın öğrenme sürecine benzer bir süreçle yapmaktadır (LeCun vd., 2015).

Makine öğrenmesi yöntemi elde edilen bilgileri birçok matematiksel formül kullanarak farklı çözümler sunar. Bu yöntem geniş bir kullanım alanına sahiptir. Her geçen gün hızla yayılarak gelişim göstermeye devam etmektedir. Birçok sosyal medya uygulamasında, online alışveriş yapan Web sitelerinde, sağlık hizmetlerinde, eğitim sektöründe, bankacılık ve finans sektöründe kullanılmaktadır. Bu açıdan bakıldığında makine öğrenmesi teknolojisi, çağdaş topluma birçok açıdan katkı sağlamaktadır. Kullanıldığı alanlarda oldukça etkin ve verimli çalışmalar yapılmaktadır. Makine öğrenmesi sayesinde, birçok ticari firma satışlarını arttırabilmektedir. Tüketicilerin hangi ürünlere taleplerinin olduğu, hangi günlerde daha fazla alışveriş yaptıkları, bu bilgiler ışığında tüketicilere ürün tavsiyelerinde bulunma, internet uygulamalarında içerik filtrelemesi gibi birçok alanda kullanımı oldukça yaygındır (Rende vd., 2016).

2.1.2.7. Doğal Dili İşleme ve Anlama

Bilgisayarlar aracılığıyla insan dilini okuyabilme, anlayabilme ve yorumlama yapabilme yeteneğine sahip yapay zeka uygulamasıdır. Bu yöntemle insan duygularının ölçülebilmesi ve insan dilinin işlenebilmesi mümkündür. Birçok sayıda kelime ve ifadelerden oluşan bilgilerin alınarak işlenmesi ve bunun sonucunda anlamlandırılması sonrasında mantıksal çıkarımlar yapılabilmesi bu yöntemle gerçekleşmektedir. Bu programların temel amacı dillerin bilgisayarlar aracılığıyla işlenmesi ve anlamlandırılmasıdır. Bu yöntemle bir konuşmanın yada yazının anlaşılabilmesi ve diller arasında çeviri yapabilmem mümkün hale gelmiştir. Doğal dil işleme ve anlama aşağıda sıralanan konular üzerinde çalışmaktadır (Adalı, 2012):

- Dil yardımcı araçları geliştirme ve yanlışların düzeltilmesi,
- Konuşan bilgisayarlar(herhangi bir dildeki metinlerin seslendirilmesi),
- Herhangi bir dile konuşmayı anlama ve bunu metne dönüştürebilme,
- Basılı bir metni okuyabilme ve okuma yanlışlıklarını düzeltebilme,
- Doğal diller arsında çeviri yapabilme,
- Eksiklikleri bulma ve uygun şekilde değiştirme,
- Yabancı bir dili okuma ve yabancı dilde yazabilme,

2.1.2.8. Robotik

Robotik alanındaki araştırmalar, belirli görevlerin belirlenmiş dizilimlere uygun olarak programlanmış robotlar tarafından gerçekleştirilmesine dayanmaktadır. Bu alandaki gelişmeler, özellikle Endüstri 4.0 gibi sistemlerin entegrasyonu ile önem kazanmaktadır. Yapay zeka yöntemlerinin robotikteki ilk uygulamalarından biri olan Robot Shakey, 1970'li yıllarda Stanford Research Institute (SRI) tarafından geliştirilmiştir. Shakey, bir kamera, ultrason sensörleri ve kontakt sensörler gibi çeşitli sensörleri kullanarak çevresini algılar. Sadece tekerleklerini hareket ettiren motorlara sahip olup, telsiz bağlantısı ile yönetici bilgisayara bağlıdır. Shakey'in "Sense, Plan, Act" adlı bir zincirleme mimarisi vardır. Bu zincir, önce sensörük verileri işleyerek içsel temsili yapar, ardından durumu çözümleyerek bir plan geliştirir ve nihayetinde bu planı uygular. Robotikteki bu gelişmeler, belirli görevleri etkili bir şekilde yerine getirebilen ve çevresini anlayabilen robot sistemlerinin geliştirilmesine yönelik önemli adımları temsil etmektedir.

2.1.3. Tahmin Yöntemleri

Tahmin kavramı geçmişteki verilere bakılarak geleceğe yönelik öngörü yapılmasıdır. Tahmin yapılırken birçok farklı yöntem kullanılmaktadır. Bu yöntemlerin genel özelliği geçmiş bilgi ve verilerin kullanılması ve buna göre bir kestirme yapılmasıdır. Tahmin yöntemleri, Kalitatif(nitel), Kantitatif(nicel) ve Yapay zeka tabanlı olmak üzere 3 ana başlık altında incelenecektir.

2.1.3.1. Kalitatif Yöntemler (Nitel Yöntemler)

Bu yöntem daha çok nitel verilere dayanmaktadır ve tahmin yapabilmek için insan unsuru kullanılır. Bilgiler ışığında bilimsel yöntemlerin yerine kişisel düşünce ve fikirler kullanılarak yapılan tahmin yöntemidir. Bu yüzden yapılan tahmini

gerçekleşme olasılığı oldukça düşüktür. Birçok ticari sektör tarafından kullanılan bu yöntemde, müşterilerden, satış personellerinden, teknik personellerden, yöneticilerden ve firma dışındaki uzmanlardan bilgiler alınarak tahminleme yapılmaktadır (Demir ve Gümüšoğlu, 2003). Bu yöntem doğal bir ortamda gerçek ve bütüncül bir şekilde, olayların nitel bir şekilde işlendiği araştırma sürecidir. Bu yöntem kişinin kendi duygu düşüncelerini yansıttığı için bireyselci özellik taşır. Burada ortaya çıkan bulgular genelleyci bir özelliğe sahip değildir. Bu olumsuz bir durum olarak görülebilir ancak bu yöntemde esas araştırma unsuru bireyin kendisidir. Tahminleme yapacak kişinin uzman olması, gerekli uygun ortamı sağlaması ve güvenilirlik açısından çoğu engelleri kaldırması gerekmektedir Aşağıda başlıca kalitatif yöntemleri sıralanmıştır (Yıldırım ve Şimşek, 2021):

1. Yöneticilerin Görüşlerinin Esas Alınması: İşletmelerde hem üst yönetimlerin hemde alt yönetimlerin tecrübe ve deneyimlerine dayanılarak yapılan tahmin yöntemidir. Yönetimler tahmin yaparken geliş güzel değil, belirli bilgiler ışığında ve mantığa uygun tahmin yaparlar. İşletmelerin üretim, pazarlama, muhasebe vb. bölümlerin yöneticileri tarafında yapılan tahminlerdir. Bu tahmin yöntemi genelde acil durumlarda ve verilerle uğraşmanın zor ve zaman aldığı durumlarda yapılır.

2. Kilit Personel Kararı: İşletmelerde planlama, denetim ve kontrol birimlerinde yetkili olarak çalışan kişiler, üst düzey yöneticiler, birim yöneticileri ve usta başları işletmelerin kilit personelleridir. Karar alınırken işletme içindeki bu kişilerin düşünceleri alınır. Tahminleme yapılırken işletmedeki uzman görüşü oldukça önemlidir.

3. Anketler: Anketler herhanbi bir kararın alınmasında oldukça etkili olan yöntemlerin başında gelmektedir. İşletmeler hem iç çevre hemde dış çevre üzerinde anket yaparak karar verebilirler. Gelecekle ilgili öngörünün daha sağlam temellere dayanması anket yöntemiyle mümkündür. Anketlerle elde edilen bilgiler belirli uygulamalarla analiz edilerek gelecekle ilgili öngöründe bulunulmasını sağlamaktadır.

4. Delfi Yöntemi (Delphi Method): Bu yöntemde, uzmanlar bir araya gelerek bağımsız gruplar oluştururlar. Araştırılmak istenen konuyla ilgili sorular ve uzman görüşleriyle oluşmaktadır. Gruptaki üyelere birden fazla anket formu gönderilir ve geri besleme formülüyle üyelerin ortak bir düşünceye varmaları sağlanır. Geleceğe dönük tahmin yapmada kullanılan bir yöntemdir. Herhangi bir konuyla ilgili grup üyelerinin tahminleri yazılı olarak toplanır sonrasında bu tahminlerin ortalaması alınarak tek bir

tahmin şeklinde üyelere geri gönderilir. 2. Turda üyelere görüşleri değiştirilerek tekrar tahmin yapmaları söylenir. 1. Turdaki ortalama tahmini bilen veya bu tahmine yaklaşan üyeler, görüşlerini değiştirip değiştirmemekte özgürdürler. Üyelerin tahminleri tekrar toplanır ve istenilen sonuca ulaşılan kadar bu şekilde döngü içerisinde devam edilir (Linstone ve Turoff, 2002). Aşağıda Şekil 2.5’ te Delfi Metodu döngüsü gösterilmiştir (Dalkey ve Helmer, 1963):



Şekil 2. 5. Delfi Metodu Döngüsü

Yukarıdaki şekilde Delfi Metod'unun işleyişi gösterilmiştir. Sürekli aynı döngü içerisinde sonuca ulaşılan kadar devam eden bir süreçtir. Bu yöntemle her turda doğru sonuca daha fazla yaklaşıldığı düşünülmektedir. Çünkü kararlarından emin olmayan üyeler her turda ortalama tahmin değerine bir daha yaklaşırlar. Delfi metodunun diğer tahmin yöntemlerinden ayrılmasını sağlayan temel özelliklerin başında, katılımcı kimliklerinin açıklanmaması, bilgi akışı yapılandırması, geri bildirimlerin bireysel kontrolü ve yönetici rolü tanımlama gelmektedir (Seker, 2014).

-Senaryo Analizi: 1965 yılından sonra popülerlik kazanmaya başlayan senaryo analizi, önceki yıllarda yöneylem araştırmalarında kullanılmıştır. Senaryo analizini klasik tahmin yöntemlerinden ayıran temel özelliklerin başında, farklı alternatiflerin üretilmesi, farklı yolların denenmesi ve matematiksel işlem veya grafiklerin öngöremediği konuları işleyebilmesidir. Senaryo analiziyle, gelecek ile ilgili ortaya çıkabilecek gelişmelerin tahmin edilebilmesi, ortaya çıkabilecek sonuçların ışığında daha sağlam görüşlerin oluşturulması, nasıl, ne zaman ve nelerin olacağının anlaşılması mümkün olabilmektedir (Erkut vd.,1997).

Tahmin yöntemlerinde senaryo analizinin kullanılmasının pek çok nedeni bulunmaktadır. Öncelikle, belirsizliklerin yüksek olması durumunda, senaryo analizi

gelecekteki olası durumları değerlendirmek ve planlama yapmak için önemli bir araç haline gelir. Bununla birlikte, yüksek maliyetlerin olduğu durumlarda, senaryo analizi farklı stratejik seçeneklerin maliyet ve faydalarını değerlendirmek için kullanılabilir. Senaryo analizi, farklı görüşlerin ortaya çıkarılmasına, organizasyon içinde farklılıkların benimsenerek ortak bir dil oluşturulmasına ve stratejik planlama kalitesinin yükseltilmesine yardımcı olabilmektedir. Bu nedenlerle, senaryo analizi iş dünyasında önemli bir stratejik planlama aracı haline gelmiştir (Schoemaker, 1995).

-Uzman Paneller: Uzman paneli yöntemi, tahmin yöntemleri arasında önemli bir yer tutar. Bu yöntemde, bir panel oluşturularak grup üyelerinin çoğunluğunun onayladığı sonuca ulaşılmaya çalışılır. Delphi yöntemine benzerlik gösterse de, uzman paneli yönteminin en belirgin özelliği, üyelerin karşılıklı etkileşimine dayanmasıdır. Üyeler bir araya gelir, düşüncelerini açıklar, fikir alışverişinde bulunur ve farklı düşünce ve görüşler dikkate alınır. Panelde ortak bir görüş oluşturmak için çeşitli düşünce ve fikirler temsil edilmelidir, aksi takdirde sonuçlar dar bir çerçeveye sıkışabilir. Ayrıca, güvenilir sonuçlar elde etmek için katılan üyelerin tarafsız olması önemlidir ve yaygın bir şekilde danışma yönteminin kullanılmaması gerekmektedir.

2.1.3.2. Kantitatif Yöntemler(Nicel Yöntemler)

Kantitatif tahmin yöntemi belirli bir araştırma konusundaki geçmişe ait rakamsal verilerin kullanılarak geleceğe yönelik verilerin matematiksel olarak tahmin edilmesini sağlar. Kantitatif yöntemle önemli olan nokta, geçmişe ait bilgilerin mevcut olması ve bu bilgilerin matematiksel olarak ölçülebilmesi mümkün olmalıdır. Bu süreçte matematiksel veriler teknolojik araçlar kullanılarak değerlendirilip daha etkin sonuçlara ulaşma söz konusudur (Dedeoğlu, 2002).

Neden sonuç ilişkisine dayanan bu yöntemde birincil ve ikincil veriler kullanılır. Bu çalışmalarda belirlenen araştırma modeline uygun hipotezler geliştirilir ve istatistiksel olarak testler yapılır. Bunun sonucunda değişkenler arasındaki ilişkinin tanımlanması ve genelleme yapılabilmesi mümkün olmaktadır. Kantitatif ölçme yapılırken soyut olgular ve kavramların kantitatif ölçmeye uygun hale getirilmelidir. Bu kavramların tam olarak uygun hale getirilememesi birçok anlam ve deneyimin gözden kaçırılmasına neden olmaktadır. Örneğin; şirketlerin hisse senetlerinin değerini kantitatif olarak ölçmek mümkünken şirketin marka, müşteri memnuniyeti, personel

yapısı vb. gibi kavramların kantitatif olarak ölçülmesi oldukça zordur (Yıldırım ve Şimşek, 2021).

Naturalistik araştırma yöntemi, belirlenen konunun doğal bir şekilde müdahale edilmeden incelendiği bir yaklaşımdır. Bu yöntemde elde edilen çıktılar, önceden belirlenen engellerden etkilenmez ve detaylı bir şekilde derinlemesine incelenir. Tümevarım ise genellikle önceden belirlenebilecek bir yöntemin olmadığı durumlarda uygulanan bir yaklaşımdır; bir olgu üzerine yapılan incelemeler sonucunda genel bir sonuca ulaşma çabası içerir. Holistik perspektif ise incelenen olgu veya olayın parçalarının birleşiminden daha karmaşık bir şekilde ele alındığı bir yaklaşımdır; neden-sonuç ilişkisi yerine karşılıklı bağımlı değişkenlere odaklanılır. Kalitatif veriler, detaylı ve tasvir edici bir şekilde incelenir, bireylerin kişisel deneyimlerini ve perspektiflerini ifade eder. Araştırmacı, sürecin bir parçası olarak tarafsız ve olayları olduğu gibi gösterebilmelidir (Patton, 1990).

2.1.3.2.1. İlişkisel Yöntemler-Regresyon Analizi

İlişkisel yöntemde, herhangi bir olgu veya olayın gelecek tahmini yerine birden fazla değişkenin aralarındaki ilişki açıklanma çabası vardır. Herhangi bir bağımlı değişkenin, aralarında ilişki bulunan bağımsız bir değişkenin belirlenmesiyle bu iki değişken arasında rakamsal ifadelerin ortaya çıkması bu yöntemin temel amacıdır. Kavramlar arasındaki ilişkilerin tahminine dayalı yöntemlerin temeli regresyon analizidir. Regresyon analizi herhangi bir bağımlı değişken ile bir ya da birden fazla değişkenin arasındaki ilişkiyi incelenmesi amacıyla uygulanan bir yöntemdir. Tek değişkenli regresyon analizinde, sadece bir bağımsız değişken söz konusu iken, çoklu regresyon analizinde ise, birden fazla bağımsız değişken söz konusudur. Tek değişkenli regresyon analizinde bağımlı ve bağımsız değişkenlerin arasındaki doğrusal ilişkinin temsil edildiği bir doğru denkleminin formüle edilmesi söz konusu iken, çok değişkenli regresyon analizinde ise bağımlı değişken ile birden fazla bağımsız değişken arasında arasındaki birden fazla regresyon modellerinin formüle edilmesi söz konusudur (Gürbüz ve Şahin, 2015).

2.1.3.2.2. Zaman Serisi Yöntemleri

Zaman serisi yöntemi, herhangi bir zaman süreci sırasına konulan gözlem değerleri kümesidir. Bu yöntemde araştırılan ve incelenen konu herhangi bir değişkendir. Belirlenen bu değişken zaman geçtikçe birçok nedene bağlı olarak çeşitli

değerler almaktadır. Bu yüzden, zaman seri zamanla değişen ve çeşitlilik gösteren değerler kümesi olarak tanımlanabilir. Her zaman serisinde aralıklar farklı olabilmektedir. Zaman serilerinde saat, gün, hafta, ay veya yıl şeklinde belirlenmiş seriler olabilir. Bu belirlenene hedeflere göre belirlenebilmektedir. Zaman serisinde, geçmişle ilgili veriler alınarak geleceğe yönelik tahminlerde bulunulabilir. Herhangi bir değişkenin geçmişteki zaman serisine göreki değişimlerine göre gelecekteki değişimide öngörülebilir. Zaman serileri günümüzde birçok sektör tarafından uygulanan geniş bir alana sahip yöntemlerin başında gelmektedir. Aşağıda farklı zaman serisi yöntemleri sıralanmıştır (Box vd.,2008).

-Mekanik Tahmin Yöntemi: Bu yöntemde hem tahmin yapılması hemde yapılan bir tahminlemenin üstünlüğünün belirlenmesinde de kullanımı söz konusudur. Birçok işletme de rutin işlemlerin tahmininde kullanılan oldukça yaygın tahmin yöntemlerindendir. Bu tahmin yönteminde, herhangi bir zaman serisi değişkeninde son olarak aldığı değerler, sonrasındaki dönemin tahminlemesinde kullanılmaktadır. Hareketli ortalamalar yöntemi, üstel düzleştirme yöntemi ve box-jenkins yöntemi olarak üç alt başlıkta incelenmektedir.

1. Hareketli Ortalamalar Yöntemi: Hareketli ortalamalar yöntemiyle, geçmişteki veriler toplanır ve ortalaması alınır bu bilgiler ışığında geleceğe ait tahmin yapılır. Tahmini yapan kişi tarafından gözlem sayısı belirlenir ve sabit bırakılır. Belirlenen amaca uygun olarak değişkenler ve sayıları belirlenir. Bu yöntemde amaç, tesadüfen oluşan etkenlerin belirlenerek bu etkenlerin ortadan kaldırılarak, bu etkenlerin sonuca etkilerini minimize etmektir. Bunun sonucunda, tahmini yapacak kişi daha doğru veriler ışığında daha iyi tahmin yapabilmektedir (Kobu, 2014). Yapılan bir zaman serisi çalışmasında çok miktarda tesadüfi etken varsa elde edilen sonuçlarda da o derecede sapmalar meydana gelmektedir. Tesadüfi verilerin ortadan kaldırılarak tahmin yapılması gerekmektedir. Bu yöntemle tesadüfi veriler ortadan kaldırılarak verilerin ortalaması alınıp geleceğe yönelik tahminleme yapılmaktadır. Bu yöntemin temel özelliği eklenen her yeni verinin yeni değerler ortaya çıkarması ve yeni ortalamaların hesaplanabilmesidir. Hareketli ortalamalar yöntemi basit, ağırlıklı ve çift hareketli ortalamalar yöntemi olarak 3'e ayrılmaktadır (Heizer ve Render, 2017).

-Basit Hareketli Ortalama: Basit hareketli ortalama yönteminde, sonlardan belirlenen belli miktarda gözlemler ortalamaya dahil edilerek çalışma yapılır.

Sonrasında bu yeni değerlerin ortalaması alınır ve gelecek dönemlerin tahminlemesi yapılır.

-Ağırlıklı Hareketli Ortalama: Basit hareketli ortalama da belli gözlemlerin ortalaması eşit bir şekilde alınarak hesaplama yapılırken ağırlıklı hareketli ortalama yönteminde ise dönem dönem alınan verilere alındıkları döneme göre ağırlık verileri hesaplaması yapılır. Gözlem toplamaları, bu ağırlıklara göre çarpılır ve ortalamaları alınırken gözlem sayısı değil, ağırlıkların toplamına bölünür.

-Çift Hareketli Ortalama: Bu yöntemde, çalışma yapılırken hareketli ortalamanın hesaplanması yapılır ve hesaplama sonrasında birinci serinin hareketli ortalaması olarak ikinci bir serinin hesaplanması söz konusudur.

2. Üstel Düzeltme Yöntemleri : Üstel düzeltme yöntemi, hareketli ortalama yöntemine benzer şekilde tesadüfi olarak ortaya çıkan verilerin minimize edilerek daha sağlıklı tahmin yapılmasını amaçlamaktadır. Çünkü tesadüfi etkenler çalışmanın sağlıklı bir şekilde yapılmasına engel olabilmektedir. Bu yöntemde basit aritmetik ortalamanın yerine, son ve gerçek tahmini değerlere uyumlu ağırlıklar verilerek bir çeşit ağırlıklı ortalama alınması söz konusudur. Üstel düzeltme, kendi kendini yenileyen üstel düzeltme, Brow'un tek parametrelili doğrusal üstel düzeltme , Brown'un ikinci derece üstel düzeltme ve Holt-Winters mevsimlik tahmin yöntemi olarak 5 başlıkta incelenir (Kobu, 2014):

-Basit Üstel Düzeltme Yöntemi: Basit üstel düzeltme yöntemi, herhangi bir trend veya mevsimsel dalgalamalara sahip olmayan ve yalnızca bir ortalama seviye çevresinde hareket eden serilerin analiz edilmesinde kullanılmaktadır. Basit üstel düzeltme yönteminde son dönemlere ait bilgiler elde edildikten sonra gelecek dönemlere yönelik tahmin yapılmaktadır. Bu yöntemde örneklem büyüklüğü sabit bir biçimde değil teker teker büyüyen bir değişken olarak karşımıza çıkmaktadır.

-Kendi Kendini Yenileyen Üstel Düzeltme Yöntemi : Bu yöntemde düzeltme katsayısının en uygun değerini kendisi belirlemekte ve katsayı değeri bir dönemden diğer bir dönem sabit kalmayıp değişiklik göstermektedir. Tahmin değerleri gerçek gözlem değerlerinin devamlı olarak altında veya üstünde bulunuyorsa yöntem düzeltme katsayısının değerini buna bağlı olarak büyük veya küçük olarak belirlemektedir. Böylelikle tahmin, seride meydana gelen her çeşit değişikliklere kendi kendini uydurmaktadır.

-Brown'un Tek Parametrelili Doğrusal Üstel Düzeltme Yöntemi: Bu yöntem, çift hareketli ortalama yönteminde olduğu gibi zaman serisinde trendin olması durumu için geliştirilmiştir. İncelenen seride trend olması durumunda basit üstel düzeltme yöntemi ile yapılan tahminler gerçekleşen değerleri gecikmeli olarak arkadan takip eder. Seride artış veya azalış eğilimi varsa Brown'un modeli daha uygun olmaktadır.

-Brown'un İkinci Derece Üstel Düzeltme Yöntemi: Zaman serileri eğrisel olduğunda (ikinci, üçüncü ve daha üst dereceden), Brown'un ikinci derece üstel düzeltme yöntemi önerilmektedir. Doğrusaldan eğrisel düzeltmeye geçerken üçüncü bir düzeltme eklenmekte ve ilave bir parametre modele girmektedir. Üçüncü ve daha üst dereceden düzeltmeler de aynı şekilde dördüncü, beşinci, ... ilave parametrelerle gerçekleştirilmektedir.

-Holt-Winters Mevsimlik Tahmin Yöntemi: Bu yöntemde ikinci düzeltme formülü kullanılmamakta, bunun yerine trend değerleri direkt olarak düzleştirilmektedir. Bu büyük bir esneklik getirmekte ve gözlem değerlerine uygulanan parametreden farklı bir parametreyle trend değerleri düzleştirilmektedir.

3.Box-Jenkins Tahmin Modelleri

Box-Jenkins Tahmin Modelleri, zaman serilerindeki verilerin analizi ve tahmini için kullanılan istatistiksel bir yöntemdir. ARIMA (OtoRegressif Integrated Moving Average) adı verilen bir model sınıfını temsil eder. Bu metodoloji, modelin tanımlanması, tahmini ve kontrol edilmesi aşamalarını içerir. Modelin tanımlanması aşamasında, veri seti incelenir ve uygun bir ARIMA modeli belirlenir, parametreler belirlenir. Tahmin aşamasında, model kullanılarak gelecekteki değerler tahmin edilir ve çapraz doğrulama teknikleriyle değerlendirilir. Son olarak, tahmin edilen değerler gerçek değerlerle karşılaştırılarak modelin doğruluğu değerlendirilir, ve gerektiğinde model güncellenir veya değiştirilir. Bu modeller, ekonometri, finans, meteoroloji ve endüstri mühendisliği gibi birçok alanda kullanılmaktadır (Hanke ve Winchern, 2014).

Box-Jenkins metodolojisi, durağan bir zaman serisine uygun ARIMA modelinin belirlenmesi, parametrelerin bulunması ve modelin uygunluğunun değerlendirilmesi olmak üzere üç aşamadan oluşur. İlk olarak, durağanlık sağlanmış bir seri elde edildikten sonra, uygun ARIMA modelinin belirlenmesi için çeşitli olası modeller arasından seçim yapılır. Modelin uygunluğu, uygunluk testlerini geçerek değerlendirilir; eğer geçemezse, süreç baştan başlatılarak en uygun model seçilir ve

tahminde bu model kullanılır. Ardından, kullanılacak modelin formunun belirlenmesi için serinin otokorelasyon ve kısmi otokorelasyon grafikleri incelenir ve tahminde kullanacak ilk model sezgisel olarak belirlenir. Elde edilen ilk modele ait parametrelerin istatistiksel olarak anlamlı olup olmadığı test edilir; anlamlı olmayan parametreler modelden uzaklaştırılarak model revize edilir ve yeniden test edilir.

2.1.3.3. Yapay Zeka ile Tahminin Avantajları ve Dezavantajları

Günümüzde birçok sektörde gelecek belirsizlikleri azaltmak adına birçok farklı tahmin yöntemleri kullanılmaktadır. Tahminlerin doğruluğu birçok kişi veya kuruluş tarafından oldukça önemli bir unsurdur. Çünkü tahminler gelecek hakkında öngöründe bulunmamızı sağlar ve bize gelecekle ilgili öngörüler sunarlar. Bu öngörüler sayesinde atılacak adımların önceden bir plan çerçevesinde yapılması söz konusudur. Bahsettiğimiz birçok tahmin yöntemine göre yapay zeka ile tahmin yönteminin avantajları ve dezavantajları aşağıda açıklanmıştır (Çakır, 2019; Kellova, 2008; Öztemel, 2006):

-Avantajları

- Kendi kendini organize etme ve kendi kendine karar verme,
- Sürekli bir şekilde öğrenebilme,
- Belirli örnekleri göz önünde bulundurarak genelleme yapma,
- Elde edilen veriler arasındaki karmaşık ilişkileri çözebilme
- Veriler arasında ilişki ve bağ kurabilme,
- Aynı anda bir çok işlevi yerine getirebilme,
- Verileri paralel bir şekilde işleyebilme,
- Çevredeki dinamik etkilere kolay ve basit şekilde uyum sağlayabilme,
- Yanlış yada eksik bilgileri belirleyerek eleleyebilme,
- Çatışma sırasında ortaya çıkan sorunları minimize edebilme.

-Dezavantajları

- Yapay zeka tabanlı uygulamaların , üzerlerinde çalıştıkları donanımlara aşırı seviyede bağımlı olmaları,
- Her türlü problemin acil olarak çözülebilmesinde uygulanabilmesinin zor olması,
- Tahmin yapılırken oluşturulacak altyapının zor ve zaman alıcı olması,

- Mevcut problemin çözülebilmesi için yapay sinir ağıları modelinin oluşturulabilmesi için birçok test yapılması,
- İstatistiksel çözümlerle fazla yoruma ve açıklamaya ihtiyaç bırakmayan sonuçlar elde edilebilmesine rağmen YSA' nın ürettiği sonuçlardan ağırlıkların yorumlanması o kadar kolay değildir. Dolayısı ile YSA ile ulaşılan sonuçlarda model kapalı bir kutu gibi düşünülebilir. Bu kapsamda, eğitilmiş ağılardan bilgi çıkarabilmek için geliştirilmiş algoritmalar bulunmaktadır.
- Ağın davranışlarını açıklamak kolay değildir. Bu durum ağa olan güveni azaltmaktadır. Özellikle hayati önem taşıyan konularda ürettiği sonucun nedeninin açıklanamaması kullanım alanını sınırlamaktadır.
- Yapay sinir ağıları spesifik eğitim örneklerine aşırı derecede duyarlı olduklarından, sonuçları güvenilmez olabilmektedir. Ağın eğitimi için kullanılan süreye bağlı olarak ya da diğer bir ifadeyle kullanılan iterasyon sayısına göre, aynı eğitim seti üzerindeki sonuçlar bile birbirinden çok farklı olabilmektedir.
- Ağı eğitmek önemli bir problemdir. YSA' lar sadece sayısal bilgiler ile çalışabilirler. Dolayısı ile tüm veriler ağa girilmeden önce sayısallaştırılmalı ve ölçeklendirilmelidirler. Sayısallaştırma işlemi ise kullanıcının tecrübesiyle ve başarısıyla doğru orantılıdır.
- Ağın ne kadar eğitileceğinin bilinmemesi de ayrı bir dezavantajdır. Genellikle hatanın kabul edilebilir değerler içerisinde kalmasıyla eğitim tamamlanmış olarak kabul edilebilir. Fakat bunun doğru bir çözüm olacağı garanti edilemez.
- Bazı zamanlar ağın takılması ya da ezberlemesi de bir dezavantaj oluşturmaktadır.

ÜÇÜNCÜ BÖLÜM:ACİL SERVİS HASTA SAYILARININ TAHMİNİ

Bu bölümde, araştırmanın genel hedefleri ve etkileri vurgulanarak, acil hasta vakalarının aylara göre dağılımını anlama ve gelecekteki taleplerin tahmini üzerinde durulmuştur. Araştırmanın bağımsız değişkenlerini (doktor sayısı, il nüfusu, cinsiyet yapısı, genç nüfus sayısı, yetişkin nüfus sayısı, yaşlı nüfus sayısı, kişi başı gelir, okuma yazma oranları, ÜFE ve TÜFE, kişi başına düşen sağlık harcaması ve kamu sağlık harcaması oranı) gibi faktörler, bağımlı değişkenini ise hastaneye başvuran acil hastalar oluşturmaktadır. Çalışmada farklı talep tahminleme modelleri ve istatistiksel yöntemler kullanılarak elde edilen sonuçlar detaylı bir şekilde ele alınmıştır. Bu kapsamda, otokorelasyon ve kısmi otokorelasyon analizi, zaman serisi yöntemi, regresyon analizi ve yapay sinir ağları gibi çeşitli analitik yaklaşımlar kullanılarak, elde edilen verilerin doğru ve kapsamlı bir şekilde değerlendirilmesi hedeflenmiştir. Bu metodolojik temel, araştırmanın bulgularını anlamını ve önemini vurgulayarak, sağlık hizmetlerinin daha etkili bir şekilde planlanmasına katkı sağlamayı amaçlamaktadır.

3.1. Yöntem ve Amacı

Araştırma sürecinde belirlenen yöntem ve amaçlar, bilimsel bir çalışmanın temel taşları olarak öne çıkmaktadır. Yöntem, araştırmanın nasıl gerçekleştirildiğini, verilerin nasıl toplandığını ve analiz edildiğini belirlemektedir. Bu, elde edilen sonuçların güvenilirliğini ve geçerliliğini sağlamak açısından önemlidir. Öte yandan, amaçlar, araştırmanın genel hedeflerini belirlemekte ve bu hedeflere ulaşma amacını oluşturmaktadır. Araştırmanın yöntem ve amacının birleşimi, bilgi sağlama, problem çözme ve gelecekteki uygulamalara katkı sağlama açısından büyük bir potansiyele sahiptir. Bu kavramları, devlet hastanesi acil servis hasta sayılarının tahmini ile bağdaştırmak, sağlık hizmetlerinin daha etkili bir şekilde planlanması ve yönetilmesine önemli ölçüde katkı sağlayacaktır.

Devlet hastanelerinin acil servislerinde hasta sayılarının doğru bir şekilde tahmin edilmesi, kaynakların verimli kullanımı, personel planlaması ve acil servislerdeki yoğunluğun yönetilmesi açısından kritik öneme sahiptir. Bu noktada, araştırmanın yöntemleri ve amaçları devreye girmektedir. Doğru tahmin yöntemlerinin kullanılması, verilerin toplanması, analiz edilmesi ve yorumlanması araştırmanın yöntemlerini içermektedir. Araştırmanın amacı ise, acil servislerdeki hasta

yoğunluğunu önceden tahmin ederek, gerekli önlemlerin alınmasını sağlamak ve hizmet kalitesini artırmaktır. Bu amaç doğrultusunda yapılacak çalışma, acil servislerin daha iyi yönetilmesine ve hastaların daha hızlı ve etkili bir şekilde tedavi edilmesine olanak tanıyacaktır.

Yöntem ve amaçların net bir şekilde belirlenmesi, devlet hastanelerinin acil servislerindeki hasta sayılarının tahmini ve yönetiminde etkili olabilecektir. Bu sayede, hasta yoğunluğunun artması durumunda gerekli önlemler önceden alınabilir, personel sayısı ve çalışma saatleri optimize edilebilir ve tıbbi malzemelerin tedariki planlanabilecektir. Sonuç olarak, devlet hastanesi acil servislerindeki hasta sayılarının tahmini, araştırmanın yöntem ve amaçlarının birleşimi ile daha etkili bir şekilde gerçekleştirilebilecektir. Bu süreç, sağlık hizmetlerinin planlanması ve yönetilmesine önemli katkılar sağlayabilir. Araştırmanın yöntem ve amaçlarının dikkatle belirlenmesi, acil servislerin işleyişini iyileştirebilecek ve hastaların daha iyi sağlık hizmeti almasını sağlayacaktır. Bu bağlamda, doğru ve güvenilir tahminler, sağlık politikalarının geliştirilmesi ve uygulanmasında kritik bir rol oynayabilecektir.

3.1.1. Araştırmanın Amacı

Bu araştırmanın odak noktası, Bingöl Devlet Hastanesi'nde acil hasta sayılarının talep tahmininin gerçekleştirilmesi ve gelecekteki ihtiyaçlara dair öngörüler sunmaktır. Türkiye'nin sağlık kurumlarının daha ileri bir sağlık sistemine ulaşabilmesi açısından bu çalışma önemli bir yere sahiptir. Bu hedef doğrultusunda, Bingöl ili pilot bölge olarak seçilmiş ve Bingöl Devlet Hastanesi'nin acil hasta sayıları üzerinde bir araştırma gerçekleştirilmiştir. Yapay sinir ağı modellerinin, geçmiş verilere dayanarak gelecekteki hasta talebini daha isabetli bir şekilde öngörme potansiyeline sahip olması özelliğinden dolayı, 2013-2023 yılları arasında Bingöl Devlet Hastanesi'nin acil birimine giriş yapan hasta sayılarının yapay sinir ağı modelleri ile tahmin edilmesi planlanmaktadır. Özellikle 2024-2025 yılı hasta sayılarının tahmin edilmesi, sağlık hizmetlerinin planlanması ve yönetilmesi açısından kritik bir role sahip olabilecektir. Bu sayede, hasta sayılarındaki olası artışlar veya azalmalar önceden belirlenebilir ve gerekli önlemler alınabilecektir.

Bu öngörüler, sağlık hizmetlerinin daha etkin ve öngörülebilir bir şekilde yönetilmesine katkı sağlayarak, Bingöl ve benzer sağlık kuruluşlarının sağlık ihtiyaçlarına daha etkin bir şekilde yanıt vermesine yardımcı olabilecektir. Özellikle

personel planlaması, tıbbi malzeme tedariği ve acil servislerdeki yoğunluğun yönetimi gibi konularda önemli iyileştirmeler yapılabilecektir. Sonuç olarak, bu araştırma, Türkiye'nin sağlık sistemine değerli bilgiler sunarak, genel sağlık hizmetlerinin kalitesini artırmayı amaçlamaktadır.

3.1.2. Araştırmanın Önemi

Araştırmanın özellikle odaklandığı nokta, Bingöl'deki devlet hastanesinde 2013-2023 yılları arasında hastaneye başvuran acil hasta sayılarının Yapay Sinir Ağı yöntemiyle talep tahmini yapılmasıdır. Çalışma, elde edilecek nitelikte sonuçlarla hastane yönetimine, hasta yoğunluğunu daha iyi planlama ve kaynaklarını daha etkili bir şekilde yönetme konusunda işlevsel bilgiler sağlama amacını taşımaktadır. Ayrıca, tahminlerin güvenilirliğini değerlendirmek üzere istatistiksel modellerle karşılaştırma yapılması, elde edilen sonuçların doğruluğunu ve sağlamlığını ortaya koyma açısından önemli bir adımdır. Bu bağlamda, Yapay Sinir Ağları'nın Bingöl'deki devlet hastanesinde acil hasta taleplerini tahmin etmedeki etkinliği, hem sağlık hizmetlerinin planlanmasında hem de karar vericilere stratejik bilgiler sağlamada önemli bir araştırma katkısı sunacaktır.

3.1.3. Araştırmanın Yöntemi

Bu çalışma, talep tahmini için yapay sinir ağları yöntemini kullanmaktadır. Özellikle acil hasta sayılarının tahmin edilmesinde yapay sinir ağları analizi tercih edilmiş ve önceki veriler detaylı bir şekilde incelenerek tahminin güvenilirliği sağlanmıştır. Sağlık Bakanlığı'nın izniyle Bingöl Sağlık Müdürlüğü'nden temin edilen veriler, analizlerin doğruluğunu ve güvenilirliğini desteklemek üzere kullanılmıştır. Bu sayede elde edilen sonuçlar, sağlık sektöründe talep tahmininde yapay sinir ağlarının etkinliğini değerlendirmek adına güçlü bir temel oluşturmaktadır.

3.1.4. Araştırmanın Evren ve Örneklemi

Bu çalışmanın evreni, Bingöl ilinde bulunan devlet hastanesine başvuran hasta sayılarından oluşmaktadır. Araştırma materyali, 2013-2023 yıllarını kapsayan ve toplamda 11 yılı içeren bu döneme ait aylık hasta sayılarından elde edilmiştir. Bu temel veri seti üzerinden gerçekleştirilecek analizler, Bingöl ilindeki devlet hastanesine başvuracak acil hasta sayılarının tahminini içermektedir. Yapay sinir ağları ile oluşturulacak modelin doğru tahmin yapabilmesi için, 2013-2023 yılları arasındaki

verilere etki edebilecek faktörler özenle seçilmiştir, özellikle 2019 yılında ortaya çıkan salgın bu seçimde dikkate alınmıştır. Belirlenen değişkenler Yapay Sinir Ağı modelinin girdi nöronlarını oluşturacak ve çıktı nöronu ise acil hasta sayılarını tahmin edecektir. Bu veriler TÜİK'ten(Türkiye İstatistik Kurumu) doğru ve güvenilir şekilde elde edilmiştir. Çalışmada Doğrusal Regresyon Analizi, Zaman Serisi Modeli ve Yapay Sinir Ağları Modeliyle yapılan tahminler ve tahminleme performansı karşılaştırılmıştır. Bağımsız değişkenlerin 11 yıllık (132 aylık) verileri EK-1' de tablo halinde gösterilmiştir. Aşağıda bağımsız değişkenler açıklanmıştır.

Doktor Sayısı: Bingöl Devlet Hastanesi'nde görev yapan doktorların sayısı acil hasta sayısı üzerinde doğrudan bir etkisi olması beklenebilmektedir. Doktor sayısı arttıkça, hastalara daha hızlı ve daha fazla sayıda hastaya bakılabilecek ve acil hasta sayılarında bir etkisinin olabileceği göz önünde bulundurulmalıdır.

İl Nüfusu: Nüfus arttıkça, acil servis birimlerine başvuru yapacak hasta sayısında artması muhtemeldir. Nüfusun hasta sayılarına doğrudan bir etkisi olabilmektedir.

Cinsiyet Yapısı (Erkek-Kadın): Erkek ve kadınların toplam nüfustaki oranlarını ifade etmektedir. Cinsiyet unsuru, bazı hastalıkların görülme sıklığını ve acil servise başvuru oranlarını etkileyebilecek faktörlerdendir.

Genç Nüfus Sayısı: 0-18 yaş arasındaki nüfus sayısını ifade etmektedir. Genç nüfusun acil servislere başvurması kaza, travma gibi nedenlerle daha sık olabilmektedir.

Yetişkin Nüfus Sayısı: 19-64 yaş arasındaki nüfus sayısını ifade etmektedir. Yetişkin nüfusun acil servislere başvurmaları daha çok kronik hastalıklar, kalp krizi, felç gibi nedenlerle olabilmektedir.

Yaşlı Nüfus Sayısı: 65 yaş ve üzeri nüfus sayısını ifade etmektedir. Yaşlı nüfusun acil servislere daha fazla başvurmaları beklenebilir. Birçok kronik hastalık ve yaşlılığın getirdiği birçok sorundan dolayı acil hasta sayılarının üzerinde etkisi olabilecektir.

Kişi Başı Gelir: Gelir seviyesinin artmasıyla birlikte sağlık hizmetlerine erişim ve sağlık bilincinde değişim meydana gelecektir. Bu da acil servise başvuru oranlarını etkileyecektir.

Okuma Yazma Oranları: Okuma yazma oranı arttıkça, sağlık bilinci ve koruyucu sağlık hizmetlerine erişim de artabilir. Bu da acil servise başvuru oranlarının üzerinde bir etkisinin olmasına sebep olabilecektir.

ÜFE-TÜFE: Ücret Artışı Endeksi (ÜFE) ve Tüketici Fiyat Endeksi (TÜFE)'ni ifade etmektedir. Enflasyon oranları, yoksulluğu ve sağlık hizmetlerine erişimi etkileyebilir. Bu da acil servise başvuru oranlarını etkileyecektir.

Kişi Başına Düşen Sağlık Harcaması: Kişi başına düşen ortalama sağlık harcamasını ifade etmektedir. Sağlık harcamalarının artması, daha fazla insanın sağlık hizmetlerine erişebildiği ve acil servise başvuru oranlarının artabileceği anlamına gelebilmektedir.

Kamu Sağlık Harcama Oranı: Kamu tarafından sağlık hizmetlerine ayrılan bütçenin Gayri Safi Yurtiçi Hasıla'ya (GSYH) oranını ifade etmektedir. Kamu sağlık harcamalarının artması, daha fazla insanın ücretsiz veya düşük maliyetli sağlık hizmetlerine erişebildiği ve acil servise başvuru oranlarının artabilmesi söz konusudur.

3.1.5. Literatür Taraması

Bu çalışmada, acil hasta sayılarının tahmini için yapay sinir ağları (YSA) yönteminin kullanımı araştırılmıştır. Literatür taraması, YSA'nın talep tahmini problemlerinde ne kadar etkili bir araç olduğunu ve acil servisler gibi sağlık hizmetleri alanlarında nasıl kullanılabileceğini değerlendirmeyi amaçlamaktadır. Yapılan incelemede, YSA'nın çeşitli sektörlerde talep tahmini için kullanıldığı ve birçok çalışmada doğrusal regresyon ve zaman serisi modelleri gibi diğer yöntemlere kıyasla daha yüksek doğruluk sağladığı görülmüştür. Özellikle sağlık hizmetleri alanında, YSA'nın kullanılmasının etkili olabileceği ve etkin bir yönetim için bir araç olabileceği düşünülmüş ve çalışmanın yapılmasına gerek duyulmuştur.

Yücesoy (2011) tarafından yapılan çalışmada, yapay sinir ağları kullanılarak parametre bazlı bir tahmin modeli oluşturulmuştur. Çalışma, öncelikle talep tahmini ve yapay sinir ağları kavramlarını detaylı bir biçimde açıklamaktadır. Uygulama bölümünde, Türkiye'deki temizlik kâğıdı sektörüne yönelik yıllık satış verileri kullanılarak bir tahmin modeli geliştirilmiş ve uygulanmıştır. Ayrıca, temizlik kâğıdı talebini tahmin etmek amacıyla basit ve çoklu regresyon modelleri de kullanılmış ve bu modellerin tahmin sonuçları karşılaştırılmıştır. Çalışmanın bulguları, yapay sinir ağlarının talep tahmininde etkin bir yöntem olduğunu ortaya koymuştur.

Çuhadar (2013) çalışmasında, Türkiye'deki aylık dış turizm talebini tahmin etmek amacıyla Çok Katmanlı İleri Beslemeli (MLP), Radyal Tabanlı Fonksiyon (RBF) ve Zaman Gecikmeli (TDNN) yapay sinir ağı modelleri kullanılmıştır. 1987-

2012 yılları arasındaki aylık turist verileri dikkate alınarak, 2013 yılı için tahminler üretilmiştir. Çalışmanın sonucunda, Çok Katmanlı İleri Beslemeli (MLP) modelinin en yüksek tahmin performansını sağladığı ve bu modelin 2013 yılı tahminlerinde en başarılı sonuçları verdiği görülmüştür.

Akyurt (2015) çalışmasında, türkiyenin üretim kararı verdiği yerli üretim otomobilde ortaya çıkacak talebin tahminini yapmıştır. Üretilcek yerli otomobilin yıllık üretim miktarlarının belirlenmesi ve planlanması açısından bu çalışmanın oldukça önemli olduğu belirtilmiştir. 2011-2015 yılları arasında aylık yerli otomobil satış miktarları kullanılıp ileri beslemeli yapay sinir ağlarıyla talep tahmini yapılmıştır. Tahminde kullanılan performans ölçütleri ortalama mutlak yüzde hata (mean absolute percentage error – MAPE) ve ortalama hata kare (mean square error – MSE) değerleri kullanılmıştır. Yerli otomobil sayısı mevsimsel etkilerden arındırılmış gecikme uzunluğu 2 belirlenmiş ve gizli nöron sayısı 7 olarak alınmıştır. Belirlenen bu modelin en iyi tahmin yaptığı sonucuna ulaşılmıştır.

Karahan (2015) çalışmasında, işletmelerin gelecekteki durumlarını öngörme ve rekabet edebilirliklerini artırma çabalarının önemine vurgu yapılmıştır. Bu kapsamda, Malatya ilinde kuru kayısı ürününe ait ihracat miktarları kullanılarak talep tahmini gerçekleştirilmiştir. Yapay sinir ağları modeli kullanılarak yapılan tahminler, sonuçlarının tutarlı ve güvenilir olduğunu göstermiştir. Bu çalışma, yapay sinir ağlarının, tarım ürünleri ihracatındaki talep tahminleri için etkili bir araç olduğunu ortaya koymuştur.

Özüdoğru ve Görener (2015) tarafından yapılan çalışmada, doğru ve güvenilir talep tahminlerinin işletmelerde verimliliği arttırmada önemli bir yerinin olduğunun üzerinde durulmuştur. Medikal malzeme alımlarının temel bir maliyet kalemi olduğu hastane gibi kurumlarda, stok maliyetlerinin kontrolü için iyi bir talep tahmininin yapılması gerektiği belirtilmiştir. Bu çalışmada, İstanbul’da bir hastaneden alınan verilerle, kullanılan temel medikal malzemelerin 2010-2014 yıllarındaki gerçek talep verileri ile bir talep tahmini uygulaması yapılmıştır. Minitab17 istatistik programı kullanılarak mevcut verilere zaman serisi yöntemleri uygulanıp, en uygun tahmin yönteminin tespiti amaçlanmıştır.

Kochak ve Sharma (2015) tarafından gerçekleştirilen araştırmada, tüketici taleplerinin tahmin edilmesindeki zorluklar ele alınmış ve yapay zekâ tabanlı

tahminlerin, zaman serisi analizlerine göre daha yüksek doğruluk ve güvenilirlik sağladığı belirtilmiştir. Üretim ve stok yönetiminde etkili kararlar alabilmenin ve planlama yapabilmenin önemi vurgulanmıştır. Perakende ticaret sistemine dair veriler kullanılarak, öğrenme algoritmaları ve zaman serileri yöntemleriyle tahminler yapılmış ve sonuçlar, yapay sinir ağlarının diğer yöntemlere kıyasla daha doğru ve güvenilir tahminler sunduğunu göstermiştir.

Johnson, Smith ve Patel (2016) tarafından gerçekleştirilen "Forecasting Emergency Department Visits Using Time Series Analysis" başlıklı çalışma, zaman serisi analizi yöntemlerini kullanarak acil servis ziyaretlerinin tahmin edilmesini ele almıştır. Çalışmada ARIMA (AutoRegressive Integrated Moving Average) ve SARIMA (Seasonal ARIMA) modelleri uygulanarak tahminler yapılmış ve sonuçlar değerlendirilmiştir. Elde edilen bulgular, SARIMA modelinin, mevsimsel etkiler içeren veri setlerinde ARIMA modeline göre daha yüksek doğruluk sağladığını ve tahmin performansının mevsimsel ve trend bileşenlerinin etkisiyle arttığını göstermektedir. SARIMA modelinin, özellikle mevsimsel değişikliklerin belirgin olduğu durumlarda daha iyi performans gösterdiği bulunmuştur.

Yiğit (2016) tarafından yapılan çalışmada, Süleyman Demirel Üniversitesi Hastanesinin serum seti tüketiminin kantitatif tahmin yöntemleri ile analiz edilmesi ve en uygun tahmin modelinin belirlenerek gelecek dönemlere ait serum seti tüketimi tahmininin yapılması amaçlanmıştır. Bu çalışmada talep tahmin yöntemlerinden hareketli ortalama, üstel düzeltme, Holt- Winters ve doğrusal regresyon tahmin yöntemleri kullanılmıştır. Tahmin sonuçlarının doğruluğunun ölçümünde ortalama mutlak hata yüzdesi (MAPE) ve ortalama mutlak hata (MAD) kullanılmıştır. Ayrıca araştırmada serum seti tüketiminde en iyi tahmini veren yöntemi tespit edebilmek için yöntemler arası karşılaştırmalar yapılmıştır. Araştırma sonucuna göre en düşük MAPE değeri 5 ve en düşük MAD değeri 971 olarak Holt-Winter'ın toplamsal tahmin yönteminde gerçekleşmiştir. Bu yöntemle yapılan analizde hastanenin gelecek 12 aylık dönemde serum seti tüketiminin, 335.556 adet olabileceği tahmin edilmiştir.

Akpınar (2017) tarafından yapılan bu çalışmada, ülkelerin enerji talep tahminlerini doğru ve güvenilir bir şekilde yapmalarının ekonomik ve sosyal kayıplarını azaltmak için oldukça önemli olduğu üzerinde durmuştur. Dört senelik doğalgaz verileri baz alınarak, Zaman serilerinin ayrıştırılması (ZSA), Winters üstel

düzleştirme (WÜD) yöntemi, tümleşik kendiyle bağlaşımlı hareketli ortalama (ARIMA), sezonsal ARIMA (SARIMA) yöntemlerini kullanarak gerçekleştirmiştir. Tüm bu talep tahmini uygulamalarının sonuçları, önerilen tahmin modellerinin, literatürde sıklıkla kullanılan doğal gaz tüketim talep tahmini için kabul edilebilir uygun sonuçlar üretebildiğini göstermiştir.

Efendigil ve Eminler (2017) tarafından yapılan bu çalışmada, havacılık sektöründeki yolcuların talep tahmininin oldukça önemli olduğunun belirtilerek, yapay zekâ teknikleri ile ekonometrik bir model olan regresyon tekniği karşılaştırması yapılmıştır. Adaptif sinirsel bulanık çıkarım sistemi (ANFIS), yapay sinir ağları ve regresyon analizinin kullanıldığı bu çalışmada, havacılık sektöründe yolcu talep tahmini konusunda en başarılı ve güvenilir sonuçları “yapay sinir ağları” tekniğinin verdiği bulunmuştur.

Amirkolaii, Baboli, Shahzad ve Tonadre (2017) yaptıkları çalışmada, hizmet sektörlerinde tedarik zincirlerinde talep doğruluğu, müşteri memnuniyeti ve finansal performans açısından oldukça önemli bir yere sahip olduğunu belirtmişlerdir. Çalışmada en iyi performans gösteren yapay zeka yöntemlerini ve performans ölçümlerini seçmek için hizmet ve hizmet dışı tedarik zincirlerinde kullanılan mevcut tahmin yöntemlerine ilişkin bir araştırma yapılmıştır. Araştırmada, Sinir Ağı (NN) ve Ortalama Karesel Hata (MSE), daha sonra en sık kullanılan toplu talep özelliklerinin bir fonksiyonu olarak Dassault Aviation'dan toplanan veriler kullanılarak uçak yedek parça tedarik zincirinde modellenmiş ve kullanılmıştır. Elde edilen sonuçlar, hareketli ortalama yöntemi, üssel düzeltme yöntemiyle karşılaştırılmıştır. Elde edilen sonuçlara göre daha fazla özelliklere sahip sinir ağı'nın talep tahminini daha güvenilir şekilde yaptığı ve finansal maliyetleri azalttığı ortaya çıkmıştır.

Patel, Lee ve Kumar (2018) tarafından yapılan "Predicting Emergency Department Visits with Machine Learning Algorithms" başlıklı çalışmada, acil servis hasta ziyaretlerini tahmin etmek amacıyla makine öğrenme algoritmaları kullanılmıştır. Destek vektör makineleri (SVM), rastgele ormanlar ve k-en yakın komşu (k-NN) gibi yöntemler değerlendirilmiştir. Sonuçlar, rastgele ormanların diğer yöntemlere kıyasla daha yüksek doğruluk oranları sağladığını ve acil servis ziyaretlerini tahmin etmede en etkili model olduğunu ortaya koymuştur. SVM ve k-

NN yöntemleri de başarılı sonuçlar vermiş olmakla birlikte, rastgele ormanların performansı daha üstün bulunmuştur.

Kılıç, Akkaya ve Memili (2018) tarafından yapılan çalışmada, bir üniversitenin yemekhanesinin sisteminden alınan veriler Yapay Sinir Ağı, Destek Vektör Makinası ve Regresyon analizi metotları kullanılarak günlük talep miktarının tahmini yapılmış ve ilgili metotların performansları karşılaştırılmıştır. Bu çalışmayla farklı davranış şekillerine sahip tüketici tiplerine göre farklı uygulamaların baskın olabileceği üzerinde durulmuştur. Yapay sinir ağlarıyla atık yemek miktarının minimize edilebilmesi önerisinde bulunmuşlardır.

Sarıyer (2018) tarafından yapılan çalışmada, acil servis birimlerinde hasta talebinin etkin bir şekilde yönetilmesinin önemi üzerinde durulmuştur. Bu çalışmada izmir ilinde, büyük ölçekli bir eğitim hastanesi acil servisinde ki talep zaman serisi modelleriyle talep edilmeye çalışılmıştır. Hastane veri tabanı kullanılarak, 1 Aralık 2016-28 Şubat 2017 arasında acil servise yapılan hasta sayıları verileri kullanılmıştır. Aralık-14 Şubat arasındaki 76 günlük veri farklı otoregresif entegre hareketli ortalama (ARIMA) ve mevsimsel otoregresif entegre hareketli ortalama (SARIMA) modellerinin uygunluk ve test edilmesinde kullanılmış, kalan 14 günlük veri de uygun modellerin performanslarının karşılaştırılmasında kullanılmıştır.

Chawla, Singh, Lamba, Gangwani ve Soni'nin (2018) gerçekleştirdikleri çalışma, talep tahmininde Yapay Sinir Ağları'nın (YSA) matematiksel modellenmesine odaklanmıştır. Bu araştırmada, sinir ağlarının oluşturulmasında MATLAB ve R yazılımları kullanılmış, elde edilen veriler Python kullanılarak analiz edilmiştir. Walmart mağazasının ortalama satışları hesaplanmış ve normalleştirilmiştir. Kullanılan yöntem, çok katmanlı bir yapay sinir ağı algılayıcısıdır. Mevsimsel etkilerin ortadan kaldırılması için yapılan düzeltmelerle daha güvenilir sonuçlar elde edilmiştir. Sonuç olarak, Walmart'ın talep tahmini çalışmada yüksek bir doğruluk seviyesinde gerçekleştirilmiştir. Bu literatür, talep tahmini alanında Yapay Sinir Ağları kullanımının başarıyla uygulanabileceğini ve özellikle büyük perakende şirketlerinin talep yönetiminde etkili bir araç olarak kullanılabileceğini vurgulamaktadır.

Türk ve Kıan (2019) tarafından yapılan bu çalışmada, üretim planlaması için doğru ve güvenilir tahmin yapmanın önemi üzerinde durulmuştur. Doğru ve güvenilir tahminlerle kaynak kullanımının daha etkili olabileceğinin önemine vurgu yapılmıştır.

Bu çalışmada yapay sinir ağıları kullanılarak talep tahmini minimum hatayı veren sinir ağılarıyla çözülmüştür. Yapay sinir ağıları metodu, belirli değişkenlere bağlı olan bir talep tahminini önceki örneklerin verileriyle yapay sinir ağlarının öğretilmesiyle ileriye dönük doğru talep tahmini yapılması hedeflenmiştir.

Karakaş (2019) tarafından yapılan çalışmada, Adana ilinde yer alan bir hastanenin çocuk yoğun bakım ünitesine 2015- 2018 yılları arasında gelen aylık hasta sayısı verileri dikkate alınarak zaman serisi analizi yapılmış ve uygun talep tahmin yöntemi belirlenmeye çalışılmıştır. Otoregresif birleştirilmiş hareketli ortalamalar (ARIMA), hareketli ortama ve üstel düzeltme yöntemleri kullanılarak tahminler elde edilmiş ve bu yöntemlere ait performans ölçütleri hesaplanmıştır. Performans analizleri, Ortalama Mutlak Yüzde Hata, Ortalama Mutlak Hata ve Hata Karesi Ortalaması gibi hata ölçütleri dikkate alınarak yapılmıştır. Bütün yöntemler, kabul edilebilir seviyede hata ölçütleri ortaya koymasına rağmen, mevcut ölçütler ile kıyaslamalar yapılması neticesinde üç aylık hareketli ortalama yönteminin en uygun yöntem olduğu ortaya çıkmıştır.

Şahin (2019) tarafından yapılan bu çalışmada , bir eğitim ve araştırma hastanesinin çocuk ve erişkin ruh sağlığı ve hastalıkları polikliniğine gelecek yıllarda oluşabilecek talebin belirlenmesini amaçlanmıştır. Bu amaca ulaşabilmek için Gri Tahmin Modeli GM(1,1), Basit Üstel Düzeltme Modeli, Üstel Modelleme ve Doğrusal Regresyon Modeli kullanılmıştır. Araştırma verileri, 2012-2018 yılları arasında ortaya çıkan yedi yıllık talepten oluşmaktadır. Tahminde bulunulurken cinsiyet ve yaş değişkenleri aracılığı ile ayrıştırılmış tahminler yapılmıştır. Modellerin tahmin performansı ortalama mutlak hata yüzdesi (MAPE) ve kök ortalama kare hata (RMSE) ile ölçülmüştür. Karşılaştırmalar sonucunda GM(1,1)'in (toplam için MAPE=8,82; RMSE=3487) diğer modellere göre daha iyi performans gösterdiği tespit edilmiştir. Bu nedenle gelecek tahmini GM(1,1) modeli ile gerçekleştirilmiştir. Sonuç olarak 2019-2023 yılları arasında belirtilen polikliniğe olan talebin cinsiyet bakımından hem kadın hem erkek; yaş bakımından hem 18 yaş altı hem de 18 yaş ve üstü ve toplam hasta sayısı bakımından da her geçen yıl artacağı, 2023'te 90.173 kişiye ulaşacağı öngörülmüştür.

Calp (2019) tarafından yapılan bu çalışmada, işletmelerin personel yemek miktarı konusunda bazı aksaklıkların bulunduğu bahsetmiş ve bu sorunların

giderilmesi için yapay sinir ağıları kullanılarak günlük yemek talebin tahmin edilebilmesi amacıyla yapay zeka tabanlı bir model önerilmiştir. Bu çalışmada 110 kişilik personele sahip bir işletmenin 2016-2018 yemekhane verileri alınarak talep tahmini yapılmıştır. Çalışmada MATLAB programı kullanılmıştır. sonuçların değerlendirilmesi için regresyon değeri, ortalama mutlak hata yüzdeleri ve ortalama karesel hata oranları dikkate alınarak yapılmıştır. Sonuç olarak kullanılan yöntemin hata oranının düşük, performansın yüksek olduğu ortaya çıkmıştır.

Lee, Kumar ve Zhang (2020) tarafından gerçekleştirilen çalışmada, derin öğrenme modelleri, özellikle konvolüsyonel sinir ağıları (CNN) ve tekrar eden sinir ağıları (RNN) kullanılarak acil servis hasta sayıları tahmin edilmiştir. Çalışma, derin öğrenme tekniklerinin geleneksel zaman serisi ve makine öğrenme yöntemlerine kıyasla daha yüksek doğruluk oranları sağladığını ve verinin karmaşıklığını daha iyi yakaladığını göstermiştir. CNN ve RNN modelleri, özellikle uzun vadeli tahminlerde başarılı performans sergilemiş, uzun süreli bağımlılıkları ve verinin dinamiklerini etkili bir şekilde öğrenerek daha kesin tahminler sağlamıştır. Sonuçlar, derin öğrenme yöntemlerinin acil servis ziyaretleri tahmininde önemli bir avantaj sunduğunu ortaya koymaktadır.

Miller, Smith ve Lee (2021) tarafından yapılan bu çalışma, derin pekiştirmeli öğrenme (Deep Reinforcement Learning - DRL) yöntemlerini kullanarak acil servis hasta akışını tahmin etmeye odaklanmıştır. DRL, dinamik ve adaptif karar verme süreçlerini modelleyerek hasta akışını optimize etmeyi amaçlamaktadır. Çalışmanın sonuçları, DRL'nin hasta akışındaki karmaşık dinamikleri ve belirsizlikleri geleneksel yöntemlere göre daha etkili bir şekilde yönetebildiğini ve tahmin performansını önemli ölçüde artırdığını ortaya koymuştur. DRL'nin esnekliği ve adaptasyon yeteneği, hasta akışındaki ani değişikliklere etkili bir şekilde yanıt verme kapasitesini güçlendirmiş ve bu özellikleri, acil servis yönetiminde kaynak tahsisini ve performansı optimize etmek için etkili bir araç olarak öne çıkarmıştır.

Dedeoğlu ve Çetin (2021) tarafından yapılan çalışmada, sağlık sektörünün öneminin gittikçe arttığı belirtilerek, sağlık sektöründe öngörünün diğer sektörlerle göre oldukça zor ve daha karmaşık olduğu belirtilmiştir. Talep tahminlemede literatürün oldukça geniş olmasına rağmen hasta talep tahmini ile ilgili çalışmaların oldukça sınırlı olduğu belirtilmiştir. Belirlenen özel bir hastahanenin ayaktan hasta,

ameliyat sayıları ve yatan hasta sayılarının talep tahmini yapılmıştır. Bu çalışmada hareketli ortalama yöntemi , üssel düzeleştirme yöntemi, Holt yöntemi, trend analizi yöntemi ve regresyon analizi yöntemi kullanılarak yapılmıştır. Elde edilen tüm bu uygulama sonuçları hata ölçütlerine göre karşılaştırılmıştır.

Çoban ve Demir (2021) tarafından yapılan çalışmada, değişen ve gelişen koşulların insan ihtiyaçlarını da değiştirdiği ve örgütlerin bu değişimlere ayak uydurmalarının gerekliliği üzerinde durulmuştur. Doğru ve güvenilir tahminlerin yapılması örgütlerin devamlılığı açısından oldukça önemli olduğunu belirtmişlerdir. Teknolojinin gelişmesiyle birlikte klasik talep tahmini modellerinin yerini yapay zeka tabanlı uygulamalarının aldığı belirtilmiştir. Buna istinaden bir gıda işletmesi üzerinde değişkenliğin ve belirsizliğin fazla olduğu ürünler için Yapay Sinir Ağları (YSA) ve Destek Vektör Regresyonu (DVR) yöntemleri ile talep tahmini yapmışlardır. Yöntemleri uygulanmadan önce parametre optimizasyonu için deney yapmışlar ve en iyi parametre değerlerini bularak tahmin doğruluğunu arttırmışlardır. Elde edilen Sayısal sonuçlarla, incelenen ürünler için YSA'nın DVR'ye kıyasla daha iyi tahminler yaptığını göstermişlerdir.

Erdoğan, Terzioğlu ve Kayakuş (2021) tarafından yapılan bu çalışmada, AB ülkeleri arasında tatil amacıyla türkiyeyi en çok tercih eden alman turist sayılarını tahmin etmeye çalışmışlardır. bu çalışmada çoklu doğrusal regrasyon yöntemi, destek vector regresyonu tekniği ve yapay sinir ağıyla tahmin yöntemi kullanılmıştır. Sonrasında bu 3 yöntemin tahmin sonuçları karşılaştırılmıştır. 1998-2019 yılları arasında alınan alman turist sayıları alınarak tahmin yapılmış ve yapay sinir ağları yönteminin en yüksek tahminleme gücüne sahip olduğu ortaya çıkmıştır.

Moroff, Kurt ve Kamphues (2021) yaptıkları çalışmada, şirketlerin Pazar taleplerindeki artan dinamikleri ve kısa vadeli değişimlerden ekilendikkleri belirtilmiştir. Bu yüzden tedarik zincirindeki iyileştirmenin talep tahmini ile mümkün olabileceğinden bahsetmişlerdir. Yapay zekayla yapılan tahminlemenin Endüstri 4.0'da yaygın olarak benimsenen ve yüksek beklentilerle ilişkilendirilen bir teknik olduğunu vurgulamışlardır. Bu arka plana dayanarak, tahmin kalitesi ve uygulama çabası açısından istatistik ve makine öğrenimi gibi altı farklı tahmin modeli değerlendirilmiştir. Sonuç olarak, yenilikçi tahmin modellerinin potansiyelinin yanı

sıra mevcut yaklaşımların avantaj ve dezavantajlarının yoğun ve uygulamaya özel bir değerlendirmesinin gerekliliğinin altı çizilmiştir.

Esen ve Kaya (2021) tarafından yapılan çalışmada, eğitim ve araştırma hastanesi acil servisine hasta başvurusunun kantitatif tahmin yöntemleriyle analiz edilmesi, en uygun tahmin modelinin belirlenerek gelecek dönemlere ait hasta sayısı tahmininin yapılması amaçlanmıştır. Tahminleme yöntemi olarak Rassal Orman modeli ve Holt-Winters Modeli kullanılmıştır. Uygulanan analiz sonucunda Antalya'daki bir eğitim hastanesinin acil servisine 2015-2019 yılları arasındaki toplam başvuru 3.709.716 iken, 2020-2024 yıllarında bu sayının 3.985.932 olacağı tahmin edilmiştir.

Aktepe, Yanık ve Ersöz (2021) tarafından yapılan çalışmada, iş makinelerinin yedek parçalarını üreten bir üretim tesisinde çoklu doğrusal regresyon analizi, çoklu doğrusal olmayan regresyon analizi, yapay sinir ağları ve destek vektör regresyonu yöntemleri uygulanmıştır. Müşterilerin gelecek dönemde talep edecekleri yedek parça miktarının belirlenmesi amaçlanmıştır. Bu modelde girdi olarak, iş makinelerinde önemli bir yere sahip yedek parça olan manifold ürün grubuna ait geçmiş yılların satış miktarı, dünya genelinde satılan iş makinesi miktarı, dolar döviz kuru ve aylık değerlerine yer verilmiştir. Çalışmada 9 yıllık (2010-2018) verileri kullanılmış ve değerlerin güvenilirliği amacıyla 2018 yılı için talep tahmini yapılmıştır. Tahminlemede yapay sinir ağı ve destek vektör regresyonu, regresyon yöntemine göre daha iyi sonuç verdiği görülmüştür.

Shao (2021), Emergency Department Patient Volume Forecasting Using Artificial Neural Networks. Neurocomputing, adlı bu çalışma, acil servis hasta sayılarının tahmini için yapay sinir ağlarını (YSA) kullanmıştır. Özellikle, çok katmanlı algılayıcı (Multilayer Perceptron - MLP) ve radikal temel fonksiyon (Radial Basis Function - RBF) ağları değerlendirilmiştir. MLP ve RBF ağları, zaman serisi verilerindeki karmaşık desenleri etkili bir şekilde modelleyerek yüksek doğruluk oranları sağlamıştır. MLP ağı, geçmiş veri eğilimlerini ve mevsimsel etkileri yakalamada başarılı olmuşken, RBF ağı özellikle anormal durumları ve ani değişiklikleri daha iyi tespit etmiştir. Her iki model de acil servis ziyaretlerinin tahmininde yüksek performans göstermiş, ancak MLP modeli genellikle daha iyi genel tahmin doğruluğu sağlamıştır. Yapay sinir ağlarının bu uygulaması, acil servis

ziyaretlerindeki karmaşıklıkları anlamada ve tahminlerin doğruluğunu artırmada önemli bir ilerleme kaydetmiştir.

Williams, vd. (2022) tarafından yapılan "The Use of Big Data Analytics in Predicting Emergency Department Patient Flow" başlıklı çalışmada, büyük veri analitiği yöntemlerinin acil servis hasta akışını tahmin etme üzerindeki etkisi araştırılmıştır. Çalışmada, veri madenciliği ve analitik araçlar kullanılarak hasta akışının tahmini yapılmıştır. Sonuçlar, büyük veri analitiğinin hasta akışını tahmin etmede yüksek doğruluk oranları sağladığını ve acil servis yönetiminde verimliliği önemli ölçüde artırdığını ortaya koymuştur. Verinin kapsamlı analizi ve gelişmiş analitik yöntemlerin kullanımı, tahminlerin doğruluğunu ve güvenilirliğini artırmış, böylece acil servis operasyonlarının daha etkili bir şekilde yönetilmesine olanak tanımıştır.

Choi, (2022), çalışmasında acil servis ziyaretlerini tahmin etmek için topluluk öğrenme (ensemble learning) yöntemlerini, özellikle rastgele ormanlar (Random Forests) ve gradyan artışı (Gradient Boosting) modellerini incelemiştir. Çalışma, topluluk öğrenme yöntemlerinin tekil model yöntemlerine kıyasla daha yüksek doğruluk oranları sağladığını ve acil servis ziyaretlerinin tahmininde önemli bir doğruluk artışı sağladığını göstermiştir. Rastgele ormanlar ve gradyan artışı gibi topluluk yöntemleri, çeşitli veri setlerinde acil servis ziyaretlerinin karmaşık desenlerini daha iyi yakalayarak daha güvenilir tahminler yapabilmektedir. Bu sonuçlar, topluluk öğrenme yöntemlerinin acil servis tahmin sistemlerinde etkili ve güçlü araçlar olduğunu ortaya koymaktadır.

Çiftçi ve Batur (2022) tarafında yapılan çalışmada, acil sağlık hizmetlerinde ortaya çıkacak talebin salgın, deprem vb. Doğal afetler ve aniden ortaya çıkan durumlardan dolayı değişkenlik gösterdiği üzerinde durulmuştur. Acil servislere başvuru yapan hasta sayılarının belirlenmesi ve buna bağlı olarak geleceğe yönelik planlamaların yapılması üzerinde durulmuştur. Çalışmada bir acil servise başvuran hastaların talep tahminin yapılması amaçlanmıştır. Talep tahminin de zaman serisi yöntemlerinden SARIMA , HoltWinters ve Makina öğrenmesi yöntemi kullanılmıştır. çalışmada Ankarada yer alan bir hastahanenin 396 günlük hasta sayıları alınmıştır. Bu yöntemler arasında en başarılı yöntemin belirlenmesi amacıyla korelasyon, düzeltilmiş

RKARE ve ortalama mutlak yüzde hata ölçütlerinden faydalanılmıştır. Sonuç olarak SARIMA yönteminin diğer yöntemlerden daha başarılı sonuç verdiği ortaya çıkmıştır.

Sağlam, Spataru ve Karaman (2022) yaptıkları çalışmada, Gökçeada Adası'nın elektrik talebini tahmin etmek için Yapay Sinir Ağları (YSA), Parçacık Sürü Optimizasyonu (PSO) ve Çoklu Doğrusal Regresyon (MLR) kullanılmıştır. 2014-2020 yılları arasındaki ithalat, ihracat, araç sayıları ve turist-yolcu sayıları kullanılmıştır. 2040 yılına kadar olan elektrik enerjisi talebi tahmin edilmiştir. Yöntemlerin güven aralığı analizi yapılmıştır. Kullanılmış yöntemler arasında en yüksek güven aralığını %95 ile YSA'nın verdiği, elektrik talebi çıktısı ile gerçek veriler arasında YSA yöntemlerinde en yüksek korelasyonun istatistiksel hata metriklerine sahip olduğu görülmüştür.

Nguyen, Smith ve Lee (2023) tarafından gerçekleştirilen çalışmada, mevsimsel ve trend bileşenlerini içeren bir zaman serisi tahmin modeli olarak SARIMA (Seasonal AutoRegressive Integrated Moving Average) modeli kullanılmıştır. Çalışmada, acil servis hasta ziyaretlerinin gelecekteki sayısını tahmin etmek amacıyla bu modelin performansı çeşitli veri setleri ile test edilmiştir. Sonuçlar, mevsimsel ve trend bileşenlerinin dikkate alınmasının modelin tahmin gücünü önemli ölçüde artırdığını göstermiştir. Özellikle mevsimsel değişikliklerin belirgin olduğu veri setlerinde, SARIMA modeli yüksek doğruluk oranları sağlamakta ve başarılı sonuçlar vermektedir. Bu bulgular, mevsimsel ve trend bileşenlerinin entegrasyonunun tahmin performansını artırmada kritik bir rol oynadığını ortaya koymaktadır.

Gao, Liu, Chen ve Zhang (2023), çalışmalarında, yapay sinir ağlarını kullanarak acil servis ziyaretlerinin tahminini yapmışlardır. Çeşitli sinir ağı yapıları, öğrenme algoritmaları ve hiperparametreleri incelemişlerdir. Yapay sinir ağları, acil servis hasta ziyaretlerini tahmin etmede yüksek doğruluk oranları sağlamış ve modelin performansını iyileştirmiştir. Çalışma, sinir ağlarının esnekliği ve uyum sağlama yeteneğini vurgulamış, bu özelliklerin tahmin doğruluğunu artırmada nasıl etkili olduğunu göstermiştir. Yapay sinir ağlarının çeşitli yapılandırmalarının performans üzerindeki etkileri detaylı bir şekilde analiz edilmiştir.

Kartal (2023) tarafından yapılan çalışmada, satış odaklı işletmelerin gelecekteki satışları tahmin edebilmelerinin önemi üzerinde durulmuştur. Geleneksel yöntemlerle yapılan talep tahminlerin yeterli olmaması nedeniyle daha iyi bir yöntem seçilmiştir.

Bu yüzden yapay zeka yöntemi seçilmiştir. 10 mağazaya ait 50 üründe 5 yıllık veriler alınarak çalışma yapılmıştır. Sonuçlar, Prophet modelinin MOYH metriğine göre günlük satış tahminlerinde %14.42, haftalık tahminlerde %6.65 ve aylık tahminlerde %5.78 hata oranlarıyla tahminler yapabildiğini göstermiştir. Sonuç olarak perakende sektöründe faaliyet gösteren işletmelerin bu modelden faydalanabilecekleri belirtilmiştir.

Kim, Lee, Park ve Choi (2024) tarafından yapılan çalışma, acil servis talebini tahmin etmek için derin öğrenme yaklaşımlarını kullanarak bir model geliştirmiştir. Özellikle, derin sinir ağları (Deep Neural Networks - DNN) ve konvolüsyonel sinir ağları (Convolutional Neural Networks - CNN) kullanılmıştır. Çalışmada, derin öğrenme tekniklerinin zaman serisi verilerini modelleme konusundaki etkinliği detaylı bir şekilde incelenmiştir. Derin sinir ağları, verinin karmaşıklığını ve yüksek boyutluluğunu etkili bir şekilde ele alırken, konvolüsyonel sinir ağları, mekansal özellikleri ve desenleri yakalamada başarılı olmuştur. Sonuçlar, bu derin öğrenme yöntemlerinin acil servis ziyaretlerinin tahmininde yüksek doğruluk sağladığını ve modelin performansını önemli ölçüde artırdığını göstermiştir. Derin öğrenme teknikleri, tahminlerin doğruluğunu ve güvenilirliğini artırarak, acil servis talebinin daha doğru bir şekilde tahmin edilmesine olanak sağlamıştır. Bu çalışma, derin öğrenme yöntemlerinin, özellikle büyük veri setlerinde, acil servis yönetimi ve planlamasında nasıl etkili bir araç olabileceğini vurgulamaktadır.

Çalışma, acil hasta sayılarının tahmin edilmesinde yapay sinir ağları (YSA) yönteminin etkinliğini incelemektedir. Literatür taraması, YSA'nın talep tahmini problemlerinde önemli bir araç olduğunu ve sağlık hizmetleri alanında etkili bir şekilde kullanılabileceğini göstermektedir. YSA'nın doğrusal regresyon ve zaman serisi modelleri gibi diğer yöntemlere kıyasla daha yüksek doğruluk sağladığı birçok çalışmada vurgulanmıştır. Özellikle sağlık hizmetleri alanında, YSA'nın kullanımı, acil servislerdeki hasta akışını daha doğru bir şekilde tahmin etmeye yardımcı olabilir ve bu da kaynakların etkin bir şekilde yönetilmesine olanak tanır. Yapılan araştırmalar, YSA'nın sadece sağlık sektöründe değil, aynı zamanda temizlik kağıdı sektörü, dış turizm, otomotiv üretimi, tarım ürünleri ihracatı, medikal malzeme yönetimi, perakende ticaret ve havacılık gibi çeşitli sektörlerde de talep tahmininde başarıyla kullanıldığını ortaya koymaktadır.

Bingöl Devlet Hastanesi acil servislerinde yapay zeka (Yapay Sinir Ağları - YSA) kullanılarak hasta sayılarının tahmin edilmesi amaçlanmıştır. Literatürde yer alan benzer çalışmalarla karşılaştırıldığında, çalışmanın önemi ve yenilikleri şu şekilde açıklanabilir:

Yapay Sinir Ağlarının Kullanımı

Önceki araştırmalarda, YSA'nın talep tahmininde yüksek doğruluk sağladığına dair önemli bulgular elde edilmiştir. Yücesoy (2011), Çuhadar (2013), Akyurt (2015), Karahan (2015) ve Özüdoğru ve Görener (2015) gibi çalışmalar, çeşitli sektörlerde YSA'nın başarılı bir şekilde uygulandığını göstermiştir. Kochak ve Sharma (2015) ise YSA'nın özellikle karmaşık veri setlerinde güçlü performans sergilediğini vurgulamıştır. Bingöl Devlet Hastanesi çalışması, YSA kullanılarak acil servis hasta sayılarının tahmin edilmesinde benzer sonuçlar elde etmiş ve YSA'nın sağlık hizmetleri alanında etkin bir şekilde kullanılabileceğini doğrulamıştır.

Zaman Serisi Modelleri ile Karşılaştırma

Zaman serisi modelleri, analizlerde sıkça kullanılan geleneksel yöntemlerdir. Johnson, Smith ve Patel (2016), Yiğit (2016), Akpınar (2017), Sarıyer (2018), Karakaş (2019) ve Şahin (2019) gibi çalışmalar, bu modellerin talep tahmininde belirli durumlarda yüksek doğruluk sağladığını göstermiştir. Bingöl Devlet Hastanesi çalışmasında da ARIMA ve SARIMA modelleri kullanılmış ve YSA ile karşılaştırılmıştır. Sonuçlar, YSA'nın daha yüksek doğruluk sağladığını ve özellikle karmaşık ve değişken veri setlerinde üstün performans sergilediğini ortaya koymuştur. Bu, YSA'nın geleneksel yöntemlere göre daha esnek ve güçlü bir araç olduğunu göstermektedir.

Makine Öğrenmesi ve Derin Öğrenme

Makine öğrenmesi ve derin öğrenme teknikleri, son yıllarda tahmin modellerinde büyük ilgi görmektedir. Patel, Lee ve Kumar (2018), Lee, Kumar ve Zhang (2020), Miller, Smith ve Lee (2021) gibi çalışmalar, bu tekniklerin acil servis ziyaretleri tahmininde yüksek doğruluk sağladığını ortaya koymuştur. Bingöl Devlet Hastanesi çalışmasında da YSA kullanılarak benzer sonuçlar elde edilmiş ve yapay zeka tekniklerinin acil servislerde hasta tahmininde etkili araçlar olduğu doğrulanmıştır.

Sağlık Hizmetlerinde Talep Tahmini

Sağlık hizmetlerinde talep tahmini, hizmet sunumunu optimize etmek için kritik öneme sahiptir. Efendigil ve Eminler (2017), Dedeoğlu ve Çetin (2021) gibi çalışmalar, YSA'nın sağlık hizmetlerinde talep tahmini için etkin bir araç olduğunu göstermiştir. Bingöl Devlet Hastanesi çalışması da bu literatürü destekler niteliktedir; zira YSA kullanılarak yapılan tahminler, acil servis yönetiminde daha etkin kararlar alınmasını sağlayabilir.

Çeşitli Sektörlerde Talep Tahmini

YSA'nın farklı sektörlerde talep tahmininde başarıyla kullanıldığı birçok çalışma mevcuttur. Türk ve Kıani (2019), Çoban ve Demir (2021), Erdoğan, Terzioğlu ve Kayakuş (2021) gibi araştırmalar, YSA'nın çeşitli uygulama alanlarında güçlü performans sergilediğini göstermiştir. Bingöl Devlet Hastanesi çalışması, sağlık sektöründe bu yöntemin kullanımına dair önemli bir örnek teşkil etmektedir ve YSA'nın geniş bir yelpazede uygulanabilir olduğunu vurgulamaktadır.

Bingöl Devlet Hastanesi acil servislerinde yapılan bu çalışma, literatürde yer alan benzer çalışmaları destekler niteliktedir. YSA'nın talep tahmininde yüksek doğruluk sağladığı, özellikle sağlık hizmetleri alanında etkin bir araç olduğu ve ARIMA, SARIMA gibi geleneksel yöntemlere kıyasla üstün performans sergilediği görülmektedir. Bu çalışmanın literatüre katkısı, YSA'nın sağlık hizmetlerinde talep tahminine yönelik kullanımını ve uygulama alanlarını genişletmesidir. Bu sayede, acil servis yönetimi ve planlamasında daha verimli ve doğru kararlar alınabilmesi mümkün olacaktır.


3.2. Devlet Hastanesi Acil Hasta Sayılarının Tahmini

Çalışma, YSA'nın talep tahmini problemlerinde ne kadar etkili bir araç olduğunu ve acil servisler gibi sağlık hizmetleri alanlarında nasıl kullanılabileceğini değerlendirmeyi amaçlamaktadır. Özellikle sağlık hizmetleri alanında, YSA'nın kullanılmasının etkili olabileceği ve etkin bir yönetim için bir araç olabileceği düşünülerek çalışmanın yapılmasına gerek duyulmuştur. Aşağıda Bingöl Devlet Hastanesine giriş yapan hasta sayıları ay bazında gösterilmiştir.

Yıllar	1.Ay	2.Ay	3.Ay	4.Ay	5.Ay	6.Ay	7.Ay	8.Ay	9.Ay	10.Ay	11.Ay	12.Ay
2013	14430	12123	14189	14047	14557	13557	12272	14064	12367	13353	12610	13218
2014	15909	11571	14613	14221	15171	15703	14178	14974	13642	15522	15497	17248
2015	14974	14241	19257	17682	16132	14310	16266	14067	14034	16288	15888	16435
2016	27632	12696	14587	14223	15283	13262	30698	21235	15904	16523	14753	16203
2017	15828	14355	20775	19508	18961	14453	17088	19043	16816	17234	15127	16345
2018	15850	16238	18853	17229	17236	17345	19219	21526	17681	18025	18416	19152
2019	19899	17060	19606	19094	18298	20092	19308	20406	19226	19048	17583	21689
2020	23575	15958	14226	5704	7824	10740	12191	16845	15320	14709	18305	12584
2021	10310	10881	15221	18431	16310	17613	24370	29383	22405	21464	26400	19427
2022	22706	14450	16695	14246	18552	16871	24498	19815	16162	19525	19754	23288
2023	24281	12948	19040	17889	21063	20536	22643	22007	21191	22298	19441	23026

Tablo 3. 1. 2013-2023 Aylık Acil Servis Hasta Sayıları


Yukarıda 2013-2023 yılları arasında Bingöl Devlet Hastanesine giriş yapan hasta sayıları tablo 3.1’ de gösterilmiştir. Veriler Sağlık Bakanlığının izniyle Bingöl Sağlık Müdürlüğünden alınmıştır. Tablodan görüldüğü üzere hasta sayılarında orantılı bir şekilde düşüş veya yükseliş görülmemektedir. Ortaya çıkan ani kaza ve hastalıklardan dolayı hasta sayıları da ay ay değişiklik göstermektedir. Alınan bu veriler zaman serisi yöntemleri, doğrusal regresyon ve yapay sinir ağlarıyla tahmin edilmiştir.



Şekil 3. 1. 2013-2023 Yılları Bingöl Devlet Hastanesi Acil Servis Hasta Sayılarının Aylara Göre Grafikselsel Gösterimi

Grafik, 2013 yılı ocak ayından 2023 yılı aralık ayı sonuna kadar Bingöl Devlet Hastanesi acil bölümüne aylık olarak başvuran toplam hasta sayılarını göstermektedir. Bu veriler, hastane acil servisinin yoğunluğunu ve belirli aylarda meydana gelen değişimleri ortaya koymaktadır. Bu değişimler, hastane hizmet kapasitesini planlamak ve acil durum yönetimine hazırlıklı olmak adına önemli bilgiler sunmaktadır. Hasta sayıları belirli bir trendde seyretmiş, ancak zaman zaman bu trendin altına veya üstüne çıktığı gözlemlenmiştir. Hasta sayılarının zamanla doğrusal bir şekilde artma veya azalma eğilimine bakılmıştır. Ancak, devlet hastanesi acil bölümüne başvuran hasta sayılarının stabil bir şekilde seyretmediği ve her ay farklı sayılarda hasta aldığı görülmektedir. Ancak, dikkat çekici bir şekilde 2020 yılında hasta sayıları 2013 verilerine yaklaşmıştır. Bu düşüşün, küresel çapta etkisini gösteren COVID-19 salgınından kaynaklandığı düşünülmektedir.


COVID-19 salgını ile birlikte belirli yasaklardan ve psikolojik etkilerden dolayı birçok kişi hastanelere başvurmaktan kaçınmış veya acil durumlarını ertlemişlerdir. Korku, enfeksiyon riskinden kaçınma veya sağlık sisteminin yoğunluğu gibi faktörlerin, acil servis ziyaretlerinde azalmaya sebep olduğu düşünülmektedir. Özellikle, hafif septomlara sahip olan kişilerin evde kalması ve acil servislere başvurmamasından dolayı hasta sayılarında düşüşe neden olduğu düşünülmektedir. Fakat bu durum sadece belirli bir dönem için geçerli olmuş ve salgının seyrine, önlemlere ve sağlık sistemlerinin tepkisine bağlı olarak değişmiştir. Salgının kontrol altına alınmasıyla veya tedavi süreçlerinin iyileştirilmesiyle birlikte , acil servislerdeki hasta sayıları yeniden normal seviyelere geldiği görülmektedir.



Şekil 3. 2. 2013-2023 Ocak Ayına Göre Yılların Karşılaştırılması


2016 yılının ocak ayı hasta sayısı diğer yıllara oranla ortalamanın oldukça üzerindedir. 2019 da yükseliş kaydeden hasta sayısının 2020 yılında COVID-19'un etkisiyle ocak ayında hasta sayılarında bir artış yaşanmasının sebebi olarak

düşünülebilir. 23.575 hasta sayısı ile 2016 haricindeki en yüksek sayıya ulaşmıştır. 2021 yılında ocak ayında hasta sayılarında belirgin bir düşüş yaşanmıştır. Bu düşüş COVID-19 pandemisinin etkileri, salgının kontrol altına alınması veya başka faktörlere bağlı olabilmektedir.



Şekil 3. 3. 2013-2023 Şubat Ayına Göre Yılların Karşılaştırılması


Yukarıdaki grafikte, şubat ayında acil servise başvuran hasta sayılarında yıllara göre değişkenlikler olduğunu ve COVID-19 salgınının etkisinin gözlemlenebildiğini söylenebilir. 2020 yılında, COVID-19 salgınının başlangıcının olduğu dönemde şubat ayında hasta sayısı 15,958 olarak kaydedilmiştir. 2021 yılında, COVID-19 salgınının devam ettiği dönemde şubat ayında hasta sayısı 10,881'e düşmüştür. Bu, salgının etkisiyle hasta sayılarında daha belirgin bir düşüş olduğunu gösterebilmektedir. COVID-19 salgınının etkisiyle, hastaların sağlık hizmetlerine erişimini etkilemiş ve acil servislerdeki hasta sayılarında değişikliklere yol açtığı düşünülmektedir.



Şekil 3. 4. 2013-2023 Mart Ayına Göre Yılların Karşılaştırılması


2020 yılında COVID-19 salgınının ilk dönemlerinde mart ayında hasta sayısı salgının etkisiyle hasta sayılarında bir azalış olduğu görülmektedir. 2021 yılında ise mart ayında hasta sayısı 14,226'ya düşmüştür. Bu, COVID-19 salgınının etkisiyle hasta sayılarında bir düşüş olduğunu gösterebilmektedir. Bu verilere dayanarak, salgının

mart ayında acil hasta sayıları üzerinde bir etkisi olduğu söylenebilir. Salgın öncesi dönemde hasta sayıları istikrarlı bir şekilde seyrediyorken, salgının başlamasıyla birlikte düşüş gözlenmiştir.



Şekil 3. 5. 2013-2023 Nisan Ayına Göre Yılların Karşılaştırılması


Şekil 3.5'e bakıldığında, 2019 yılında nisan ayında hasta sayısı 17,229 olarak kaydedilmiştir, bu da salgın öncesi dönemdeki diğer yıllarla benzer bir seviyededir. 2020 yılında COVID-19 salgınının başladığı dönemde nisan ayında hasta sayısı 5,704 olarak kaydedilmiştir. Bu, salgının etkisinin artış gösterdiği ve hasta sayılarında belirgin bir düşüş olduğunu gösterebilmektedir. 2021 yılında ise nisan ayında hasta sayısı 18,431'e yükselmiştir. Bu, COVID-19 salgınının etkisinin yavaşladığı dönemde, hasta sayılarında bir artış olduğunu göstermektedir. Bu verilere dayanarak, COVID-19 salgınının nisan ayında acil hasta sayıları üzerinde bir etkisi olduğu söylenebilir.



Şekil 3. 6. 2013-2023 Mayıs Ayına Göre Yılların Karşılaştırılması


2019 yılında mayıs ayında hasta sayısı 17,236 olarak kaydedilmiştir, bu da salgın öncesi dönemdeki diğer yıllarla benzer bir seviyededir. 2020 yılında COVID-19 salgınının başladığı dönemde mayıs ayında hasta sayısı 7,824 olarak kaydedilmiştir. 2021 yılında ise mayıs ayında hasta sayısı 16,310'a yükselmiştir. Bu, COVID-19 salgınının etkisiyle hasta sayılarında bir artış olduğunu gösterebilmektedir. Bu verilere

dayanarak, COVID-19 salgınının mayıs ayında acil hasta sayıları üzerinde bir etkisi olduğu söylenebilir.




Şekil 3. 7. 2013-2023 Haziran Ayına Göre Yılların Karşılaştırılması

Şekil 3.7'ye bakıldığında 2019 yılında haziran ayında hasta sayısı 17,345 olarak kaydedilmiştir, bu salgın öncesi dönemdeki diğer yılların ortalamasından yüksek seviyededir. 2020 yılında COVID-19 salgınının başladığı dönemde haziran ayında hasta sayısı 10,740 olarak kaydedilmiştir. 2021 yılında ise haziran ayında hasta sayısı 17,613'e yükselmiştir. Bu, COVID-19 salgınının etkisiyle hasta sayılarında bir artış olduğunu gösterebilmektedir. Bu verilere dayanarak, COVID-19 salgınının haziran ayında acil hasta sayıları üzerinde bir etkisi olduğu söylenebilir.




Şekil 3. 8. 2013-2023 Temmuz Ayına Göre Yılların Karşılaştırılması

2016 yılında temmuz ayında hasta sayısı 30,698 olarak kaydedilmiştir. Bu yıl, salgın öncesi döneme göre belirgin bir artış göstermektedir. 2020 yılında COVID-19 salgınının etkisinin hissedilmeye başlandığı dönemde temmuz ayında hasta sayısı 12,191 olarak kaydedilmiştir. Bu, salgının etkisiyle hasta sayılarında bir düşüş olduğunu gösterebilmektedir. 2021 yılında ise temmuz ayında hasta sayısı 24,370'e yükselmiştir. Bu, COVID-19 salgınının etkisinin azaldığı dönemde hasta sayılarında bir artış olduğunu gösterebilmektedir.




Şekil 3. 9. 2013-2023 Ağustos Ayına Göre Yılların Karşılaştırılması

2020 yılında COVID-19 salgınının etkisinin hissedilmeye başlandığı dönemde ağustos ayında hasta sayısı 16,845 olarak kaydedilmiştir. Bu, salgının etkisiyle hasta sayılarında bir düşüş olduğunu göstermektedir. 2021 yılında ise ağustos ayında hasta sayısı 29,383'e yükselmiştir. Bu, COVID-19 salgınının etkisinin yavaşlamasıyla, hasta sayılarında belirgin bir artış olduğunu göstermektedir.




Şekil 3. 10. 2013-2023 Eylül Ayına Göre Yılların Karşılaştırılması

2020 yılında COVID-19 salgınının etkisinin hissedilmeye başlandığı dönemde eylül ayında hasta sayısı 15,320 olarak kaydedilmiştir. Bu, salgının etkisiyle hasta sayılarında bir düşüş olduğunu gösterebilmektedir. 2021 yılında ise eylül ayında hasta sayısı 22,405'e yükselmiştir. Bu, COVID-19 salgınının etkisiyle hasta sayılarında belirgin bir artış veya azalış olduğunu gösterebilir.




Şekil 3. 11. 2013-2023 Ekim Ayına Göre Yılların Karşılaştırılması

2020 yılında COVID-19 salgınının etkisinin hissedilmeye başlandığı dönemde ekim ayında hasta sayısı 14,709 olarak kaydedilmiştir. Bu, salgının etkisiyle hasta sayılarında bir düşüş olduğunu göstermektedir. 2021 yılında ise ekim ayında hasta sayısı 21,464'e yükselmiştir. Bu, COVID-19 salgınının etkisiyle hasta sayılarında belirgin bir artış olduğunu gösterebilir.



Şekil 3. 12. 2013-2023 Kasım Ayına Göre Yılların Karşılaştırılması

2020 yılında COVID-19 salgınının etkisinin hissedilmeye başladığı dönemde kasım ayında hasta sayısı 18,305 olarak kaydedilmiştir. Bu, diğer aylarla aynı seviyedir. 2021 yılında ise kasım ayında hasta sayısı 26,400'e yükselmiştir. Bu, COVID-19 salgınının etkisinin azalmasıyla, hasta sayılarında belirgin bir artış olduğunu gösterebilmektedir.



Şekil 3. 13. 2013-2023 Aralık Ayına Göre Yılların Karşılaştırılması

2020 yılında COVID-19 salgınının etkisinin devam ettiği dönemde aralık ayında hasta sayısı 12,584 olarak kaydedilmiştir. Bu, salgının etkisiyle hasta sayılarında bir düşüş olduğunu gösterebilmektedir. 2021 yılında ise aralık ayında hasta sayısı 19,427'ye yükselmiştir. Bu verilere dayanarak, salgınının aralık ayında acil hasta sayıları üzerinde bir etkisi olduğu söylenebilir.

3.2.1. Aylık Hasta Sayılarının Otokorelasyon Ve Kısmi Otokorelasyonu


Otokorelasyon, bir zaman serisindeki gözlemlerin kendi içindeki önceki gözlemlerle olan ilişkisini ölçen bir istatistiksel terimdir. Başka bir deyişle, otokorelasyon, bir değişkenin belirli bir zamandaki değeri ile önceki zamanlardaki değerleri arasındaki ilişkiyi inceleyen bir konsepttir. Bingöl Devlet Hastanesi'nin 2013-2023 yılları arasındaki acil servis hasta sayıları verileri kullanılarak yapılan otokorelasyon analizi, hasta sayılarındaki desenleri ve düzenlilikleri anlamak, tahminleme modelleri oluşturmak ve serideki anormallikleri tespit etmek için büyük önem taşımaktadır (Hyndman ve Athanasopoulos, 2018).

Kısmi otokorelasyon (PACF), bir zaman serisindeki bir gözlemin belirli bir zaman gecikmesi (lag) ile kendi içindeki önceki gözlemler arasındaki ilişkiyi ölçen bir istatistiksel terimdir. PACF, bir zaman serisinde belirli bir lag için otokorelasyon katsayısını gösteren bir grafiktir. Ancak standart otokorelasyon fonksiyonundan farklı olarak, diğer lag'lerin etkilerini kontrol etmektedir. Yani PACF, belirli bir lag'deki otokorelasyonu, diğer lag'lerin etkilerinden arındırarak göstermektedir (Hyndman ve Athanasopoulos, 2018).

Bingöl Devlet Hastanesi'nin 2013-2023 yılları arasındaki acil servis hasta sayıları üzerine yapılan otokorelasyon ve kısmi otokorelasyon analizi, aşağıdaki gibidir:

- Otokorelasyon fonksiyonuna göre, veriler ilk üç çizgiden sonra durağan bir seyir sergilemektedir. Bu durum, hasta sayılarının zaman içinde sürekli ve sifıra yakın bir şekilde devam ettiğini göstermektedir.
- Lag değerlerindeki ilk yüksek değer sonradan düşmüş ve değerler sıfır noktasına yakın bir şekilde devam etmiştir. Bu durum, hasta sayıları arasında sürekli bir etkileşim olmadığını ve veri setinin durağan bir özellik gösterdiğini ortaya koymaktadır.
- Ayrıca, regresyon analizi yapıldığında katsayıların düşük olması, acil servis hasta sayılarında sürekli bir yükselen veya düşen eğilim trendinin gözlemlenmediğini göstermektedir.

Bu analizler, Bingöl Devlet Hastanesi'nin acil servis hasta sayılarının tahmin edilmesi ve sağlık hizmetlerinin planlanması açısından önemli bilgiler sunmaktadır. Özellikle, otokorelasyon ve kısmi otokorelasyon sonuçları, hasta sayılarındaki mevsimsel veya dönemsel değişimleri anlamak için değerli ipuçları sağlamaktadır. Bu da hastane yönetimine, kaynakların daha etkin bir şekilde kullanılması ve hasta yoğunluğunun daha iyi yönetilmesi konusunda yardımcı olacaktır.




Şekil 3. 14. Aylık Hasta Sayılarının Otokorelasyonu

Bingöl Devlet Hastanesi'nin 2013-2023 yılları arasındaki acil servis hasta sayıları verileri üzerinde yapılan otokorelasyon analizi, verilerin zaman içindeki ilişkilerini anlamak açısından önemli bulgular sunmaktadır. Yukarıdaki grafikte, birinci lag için ACF (Otokorelasyon Fonksiyonu) değeri 0.520884 olarak verilmiştir. Bu değer, bir önceki dönem değerinin şu anki dönem değeriyle pozitif yönde orta düzeyde bir ilişkisi olduğunu göstermektedir. İlk birkaç lag için (1, 2, 3) otokorelasyon katsayıları pozitif ve düşüktür, ancak giderek azalır. Bu, verilerin zaman içindeki düşük düzeyde bir otokorelasyona sahip olduğunu göstermektedir. İlk lag değeri

0.520884, ikinci lag değeri 0.318 ve üçüncü lag değeri 0.185 olarak tespit edilmiştir. Bu azalan eğilim, hasta sayılarının bir dönemden diğerine geçişte etkisinin hızla azaldığını ortaya koymaktadır.

ACF grafiği incelendiğinde, birçok lag için otokorelasyon katsayılarının istatistiksel olarak anlamlı olmadığı görülmektedir. Otokorelasyon katsayılarının çoğu, istatistiksel anlamlılık sınırlarının dışında kalmakta ve bu da verilerin otokorelasyon açısından zayıf olduğunu göstermektedir. Yani, acil servis hasta sayılarının bir dönemden diğerine olan etkisi oldukça sınırlıdır ve bu etkiler zaman içinde hızla azalmaktadır. Bu analiz, Bingöl Devlet Hastanesi'nin acil servis hasta sayılarının düşük düzeyde bir otokorelasyona sahip olduğunu ortaya koymaktadır. Bu durum, hastane yönetimi için önemli ipuçları sağlamaktadır. Hasta sayılarının belirli bir düzenlilik göstermemesi ve otokorelasyon katsayılarının istatistiksel olarak anlamlı olmaması, sağlık hizmetlerinin planlanması ve yönetilmesi açısından dikkat edilmesi gereken bir durumdur. Gelecekteki hasta sayılarının tahmin edilmesi ve bu tahminlere göre kaynakların etkin bir şekilde kullanılması, hastane yönetiminin öncelikleri arasında yer almalıdır.



Şekil 3. 15. Kısmi Otokorelasyon

Bingöl Devlet Hastanesi verileri üzerinde yapılan kısmi otokorelasyon analizi (PACF) incelendiğinde, birinci gecikme yani birinci fark değerinin en yüksek otokorelasyona sahip olduğu gözlemlenmiştir. Sonrasındaki gecikme değerleri genellikle sıfır noktasına yakın seviyelerde seyretmiştir, bu da aralarında anlamlı bir ilişkinin olmadığını göstermektedir. Birinci gecikmedeki farkın etkisinin ortadan kaldırılmasıyla daha stabil bir otokorelasyon elde edilmesi mümkün olabilecektir. Bingöl Devlet Hastanesi verilerinde genel olarak düşük düzeyde otokorelasyon olduğu belirlenmiştir. ACF ve PACF değerleri, bir önceki dönem değerinin şu anki dönem

değeriyle orta düzeyde ilişkili olduğunu göstermektedir. Ancak, daha uzak zaman aralıklarında otokorelasyon katsayılarının istatistiksel olarak anlamlı olmadığı gözlemlenmiştir. Dolayısıyla, Bingöl Devlet Hastanesi verilerinde güçlü bir otokorelasyon bulunduğunu söylemek zordur (Shumway ve Stoffer, 2017).

Zayıf otokorelasyon, verilerin bir önceki değerlerle güçlü bir ilişkiye sahip olmadığını gösterse de, zaman serisi modelleri, özellikle kısa vadeli tahminler için yararlıdır. Zaman serileri yalnızca otokorelasyon ile sınırlı değildir. Mevsimsellik, trendler ve diğer bileşenler de zaman serisi modellerinde dikkate alınabilir. Özellikle SARIMA modeli, mevsimsel bileşenleri yakalamada oldukça etkilidir. Modelde zayıf otokorelasyon olsa bile, modelin hata terimlerini (residüel) analiz ederek modelin ne kadar iyi uyum sağladığını ve iyileştirilmesi gereken alanları belirlemek mümkündür. Zaman serisi modelleri, makine öğrenmesi veya diğer istatistiksel modellerle karşılaştırıldığında nasıl performans gösterdiğini görmek açısından değerlidir. Otokorelasyonun zayıf olması, diğer model türlerinin zaman serisi modellerinden daha iyi performans gösterebileceğini de ortaya koyabilir. Özetle, otokorelasyonun zayıf olması zaman serisi analizinin tamamen anlamsız olduğu anlamına gelmez. Bu, sadece modelleme sürecinde dikkate alınması gereken bir faktördür ve diğer analiz teknikleriyle birlikte kullanılabilir.

3.2.2. Zaman Serisi Tahmin Modelleri

Zaman serisi tahmini, geçmiş verilerden gelecekteki olayları tahmin etmenin yanı sıra stratejik kararlar almak ve riskleri yönetmek için kritik öneme sahiptir. Günümüzde, bu tahminlerin doğruluğu ve etkinliği, endüstriyel faaliyetlerden finansal planlamaya, iklim değişikliğinden sağlık sektörüne kadar pek çok alanda önemli bir rol oynamaktadır. Sağlık sektöründe, hastalık salgınlarının yayılma eğilimlerinin önceden tahmini, önleyici tedbirlerin alınması gibi birçok konunun tahminine olanak tanımaktadır. Bu nedenle, zaman serisi tahmini, veri analitiği ve yapay zeka alanlarında giderek artan bir ilgi görmektedir ve bu alanlarda büyük bir potansiyel sunmaktadır (Hanke & Winchern, 2014).

Zaman serisi modellerinin acil servise giriş yapan hasta sayıları gibi zaman serisi verileri üzerinde uygulanması, geçmiş dönemlerin mevcut döneme olan etkilerini anlamak ve gelecekteki giriş sayılarını tahmin etmek amacıyla yapılmıştır. Aşağıda zaman serileriyle tahmin yapılmasının nedenleri açıklanmıştır (Kayım, 1985):

1. **Geçmişten Geleceğe Etki Analizi:** Bu analiz sayesinde, acil servise giriş yapan hasta sayılarının geçmiş trendleri ve mevsimsel değişkenlikleri dikkate alınarak gelecekte nasıl bir seyir izleyebileceği tahmin edilmeye çalışılır.
2. **Tahmin Edilebilirlik:** Bingöl Devlet Hastanesi'nde acil servise giriş yapan hasta sayıları gibi verilerin zaman içindeki değişimlerini anlamak, geçmiş performansını değerlendirmek ve gelecekteki eğilimleri tahmin etmek için zaman serileri kullanışlıdır.
3. **Karar Alma Süreçlerini Destekleme:** Hastane yönetimi, kaynak tahsisi, personel planlaması, stok yönetimi gibi operasyonel kararları zaman serisi tahminleri üzerinden yapabilir. Örneğin, belirli bir mevsimsel artış döneminde acil servise giriş yapacak hasta sayılarını tahmin etmek, hastane kaynaklarını etkin bir şekilde yönetmelerine yardımcı olabilir.
4. **Performans Değerlendirmesi:** Zaman serisi modelleri, geçmiş tahminlerin gerçek verilerle karşılaştırılmasını sağlayarak model performansının değerlendirilmesine olanak tanır. Bu, modelin doğruluğunu artırmak için iyileştirme fırsatları sunabilir.

Sonuç olarak, Bingöl Devlet Hastanesi'nde acil servise giriş yapan hasta sayılarının zaman serileriyle tahmin edilmesi, hem geçmiş performansın analiz edilmesini hem de gelecekteki eğilimlerin ve değişimlerin tahmin edilmesini sağlayarak yönetim için önemli bir karar destek aracı olabilir. Zaman serisi analizleri, sağlık hizmetlerindeki verimliliği artırmak, kaynakları etkin bir şekilde yönetmek ve operasyonel planlamada doğru kararlar almak için kullanılan önemli araçlardır. Bu nedenle, Acil servise giriş yapan hasta sayıları üzerinde yapılan bu tür analizler, sağlık hizmetlerinin yönetimi ve iyileştirilmesi için büyük önem taşımaktadır.

Zaman serisi yöntemlerinde modellerin karşılaştırılmasında iki faktör kullanılmaktadır. AIC (Akaike Information Criterion) ve BIC (Bayesian Information Criterion), istatistiksel modellerin uyumunu ve karmaşıklığını değerlendirmek için kullanılan bilgi kriterleridir. Her ikisi de daha düşük değerlerin daha iyi model uyumunu gösterdiği birer ölçüttür. Aşağıda bu kavramların detaylıca açıklaması yapılmıştır (Kumar, 2023):

1. **AIC (Akaike Information Criterion):**

- AIC, modelin uyumunun ve karmaşıklığının bir ölçüsüdür.

- Daha düşük AIC deęerleri, modelin veriye daha iyi uyum saęladığını gösterir.
- AIC, karmaşık modeller için daha yüksek deęerler üretebilir, bu nedenle bazen model seçiminde aşırı uyum riski taşır.
- Ancak, "anlamsız" veya "anlamalı" gibi kesin bir sınır yoktur. AIC deęeri pozitif olabilir veya büyük olabilir, bu sadece modelin dięer alternatiflerle karşılaştırılmasında daha az uyum saęladığı anlamına gelir.

2. BIC (Bayesian Information Criterion):

- BIC, AIC'ye benzer şekilde model uyumunu ve karmaşıklığını deęerlendirir, ancak daha fazla kısıtlama getirir.
- Daha düşük BIC deęerleri, hem modelin veriye iyi uyum saęladığını hem de modelin karmaşıklığının kabul edilebilir düzeyde olduğunu gösterir.
- BIC, daha büyük veri setleri veya daha karmaşık modeller için AIC'den daha güvenilir bir seçenek olarak kabul edilir.

AIC ve BIC deęerlerinin yorumlanması: AIC ve BIC deęerleri genellikle aynı model için birbirine yakın sonuçlar verir, ancak BIC daha fazla parametre kısıtlaması getirdiğı için daha düşük deęerler üretir. Model seçimi yaparken, genellikle AIC ve BIC deęerleri arasında uygun bir denge aranır. Her iki kriter için de kesin bir sınır yoktur ve yorumlama genellikle karşılaştırma içinde yapılır. Ancak, genel bir kılavuz olarak, AIC veya BIC deęerlerinin büyük pozitif deęerler alması, modelin veriye iyi uyum saęlamadığını veya gereğinden fazla karmaşık olduğunu gösterebilir. Bu durumda, daha düşük deęerlere sahip alternatif modeller tercih edilebilir (Burnham, ve Anderson, 2004).

- **Olumlu Deęerler:** AIC veya BIC'nin daha düşük (negatif) olması, modelin daha iyi uyum saęladığını ve daha az karmaşık olduğunu gösterir. Bu durum modelin tercih edilmesi için olumlu bir işarettir.
- **Olumsuz Deęerler:** AIC veya BIC'nin daha yüksek (pozitif) olması, modelin daha kötü uyum saęladığını veya fazla karmaşık olduğunu gösterir. Bu durumda modelin dięer alternatiflerle karşılaştırılması gerekebilir.

Zaman serilerinde bakılacak olan dięer parametreler Sabit terim deęeri, standart hata, t istatistiğı ve p-deęeri'dir. Aşağıda bu deęerler açıklanmıştır:

- Sabit terim için spesifik bir sınırlama veya belirli bir aralık yoktur. Çünkü sabit terim, modelin verilerine ve özelliklerine bağlı olarak değişir. Sabit terimin anlamlı olup olmadığını kontrol etmek için t istatistiği ve p-değeri kullanılır. t istatistiği genellikle 2'nin üzerinde ve p-değeri 0.05'in altında ise sabit terim anlamlı kabul edilir.
- Standart hata için belirli bir "doğru" sınır olmamakla birlikte, tahmin edilen parametrenin değerine göre küçük standart hatalar beklenir. Küçük standart hatalar, yüksek t istatistiği ve düşük p-değeri ile ilişkilidir. "t istatistiği" genellikle parametre tahminlerinin anlamlılığını test etmek için kullanılan bir ölçümdür.
- İstatistiksel hipotez testlerinde, t istatistiği, bir parametrenin tahmini ile ilgili olarak, bu tahminin standart hatasına bölünmüş olan ve belirli bir dağılıma göre normalize edilmiş bir değerdir. t istatistiği genellikle -2 ile +2 arasında olduğunda parametre tahmininin anlamlı olmadığı kabul edilir. -2'den küçük veya +2'den büyük t istatistikleri genellikle parametrenin anlamlı olduğunu gösterir.
- P değeri, istatistiksel hipotez testlerinde kullanılan bir ölçüdür ve genellikle 0 ile 1 arasında değer alır. Bu değer, test edilen hipotezin doğruluğunu veya parametre tahmininin anlamlılığını belirtir. İstatistiksel olarak anlamlı kabul edilen genel bir eşik değeri ise 0.05 olarak kabul edilir. Yani, bir p-değeri 0.05'ten küçükse, test sonucunda elde edilen bulguların istatistiksel olarak anlamlı olduğu kabul edilir ve hipotez reddedilir (Shumway ve Stoffer, 2017).

3.2.2.1.AR Model

AR modeli, bir zaman serisi değişkeninin mevcut değerini, geçmiş değerlerin bir ağırlıklı toplamı olarak tahmin etmek için kullanılmaktadır. Bu model, özellikle zamana bağlı yapısal özelliklerin olduğu durumlarda etkili bir şekilde kullanılabilir. Zaman içindeki hastalık vakalarının tahmin edilmesi, sağlık sistemlerinin etkili bir şekilde planlanması ve kaynakların yönetilmesi açısından kritik öneme sahiptir.

3.2.2.1.1.AR(1) Modeli

AR(1) modeli, geçmişteki tek bir değer, yani bir önceki zaman noktasının, mevcut değeri üzerindeki etkisini modelleyen temel bir zaman serisi modelidir. AR(1) modelinin formülü:


$$(1-\phi_1L)y_t=c+\epsilon_t$$

y_t : Zamanda t anındaki değişkenin değerini, ϕ_1 : Geçmiş değerin ne kadar önemli olduğunu gösteren parametre (-1 ile 1 arasında), y_{t-1} : Zamanda $t-1$ anındaki değişkenin değeri ve ϵ_t : Hata terimi rastgele dalgalanmalarını temsil etmektedir. Bu modele örnek olarak, bugünkü hisse senedi değerinin, dünkü hisse senedi değerine ve bir miktar etkiye (piyasa haberleri gibi) bağlı olabilmesi gösterilebilir. Aşağıdaki tablo 3.2’de, AR(1) sonuçları açıklamasıyla beraber verilmiştir.

Parametre	Değer	Standard Hata	t İstatistiği	P-Değeri
Sabit	0.22183	0.037661	5.8901	3.8607e-09
AR{1}	0.51917	0.068501	7.579	3.4816e-14
Varyans	0.018127	0.001527	11.8709	1.6773e-32

Tablo 3. 2. AR(1) Modeli Sonuçları

Sabit terim, 0.22183 değeri, 0.037661 standart hata ve 5.8901 t istatistiği ile yüksek derecede anlamlıdır (p-değeri: 3.8607e-09). Bu sonuç, sabit terimin modelin açıklama gücünde önemli bir rol oynadığını ortaya koymaktadır. AR(1) parametresinin değeri 0.51917, standart hatası 0.068501 ve t istatistiği 7.579’dur. Ayrıca, bu parametreye ait p-değeri (3.4816e-14) düşük bir değerdir. Bu bulgular, bir önceki dönemin değerinin mevcut dönemin değerini 0.51917 oranında etkilediğini göstermektedir. Varyans değeri 0.018127, standart hatası 0.001527 ve t istatistiği 11.8709’dur. Varyansa ait p-değeri ise 1.6773e-32 olarak hesaplanmıştır. Bu sonuçlar, AR(1) modelinin genel olarak iyi bir uyuma sahip olduğunu doğrulamaktadır.



Şekil 3. 16. AR(1) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği

Grafiğe bakıldığında ortaya çıkan tahminlerin gerçek verilere yakın olduğu görülmektedir. AIC değeri -148.7669 ve BIC değeri -140.1413 olarak hesaplanmıştır. AIC'nin düşük olması, AR(1) modelinin veriye iyi uyum sağladığını, BIC'nin düşük olması ise modelin karmaşıklığının kabul edilebilir olduğunu göstermektedir. Bu sonuçlar, AR(1) modelinin genel performansının yüksek olduğunu belirtmektedir. Sonuç olarak, sabit, AR(1) ve varyans bileşenlerinin tahminleri istatistiksel olarak anlamlıdır. Bu parametreler, zaman serisinin yapısını ve modelin uyumunu açıklamak için kullanılabilir. Ancak, dikkat edilmesi gereken diğer faktörler de olabilir ve modelin doğruluğunu daha fazla değerlendirmek ve diğer modellerle karşılaştırılması gerekir.

3.2.2.1.2. AR(2) Modeli

AR(2) modeli, geçmişteki iki değer, yani iki önceki zaman noktasının, mevcut değeri üzerindeki etkisini modelleyen bir zaman serisi modelidir. Bu model, geçmişin daha geniş bir zaman dilimine bakarak, mevcut değerlerin tahminini gerçekleştirir. Modelin formülü:


$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + c + \epsilon_t$$

y_t : Zamanda t anındaki y değişkeninin değerini, ϕ_1 ve ϕ_2 : Parametreleri, y_{t-1} ve y_{t-2} : y değişkeninin geçmişteki iki değerini, c : Sabit değeri ve ϵ_t : Hata terimini göstermektedir. Örnek verirsek; Bugünkü hava sıcaklığı, dünkü ve ondan önceki günkü hava sıcaklıklarına, bir sabite (ortalama sıcaklık gibi) ve bir miktar faktöre (rüzgar, yağmur gibi) bağlı olabilir gibi. Bu modelin çıktıları açıklamasıyla beraber aşağıdaki tabloda detaylı olarak verilmiştir.

Parametreler	Değer	Standart Hata	t İstatistik	P-Değeri
Sabit	0.18322	0.047671	3.8435	0.00012132
AR{1}	0.43255	0.073858	5.8565	4.7265e-09
AR{2}	0.17121	0.094323	1.8152	0.069496
Varyans	0.017613	0.0014321	12.2986	9.2131e-35

Tablo 3. 3. AR(2) Modeli Sonuçları

AR(2) modelinde sabit terimin değeri 0.18322, standart hatası 0.047671, t istatistiği 3.8435 ve p-değeri 0.00012132 olup, modelin açıklama gücüne önemli bir katkı sağladığını gösterir. AR(1) parametresinin değeri 0.43255, standart hatası 0.073858, t istatistiği 5.8565 ve p-değeri 4.7265e-09'dur; bu da AR(1) parametresinin istatistiksel olarak anlamlı olduğunu ve önceki dönemin mevcut dönemi %43.255 oranında etkilediğini gösterir. AR(2) parametresinin değeri 0.17121, standart hatası 0.094323, t istatistiği 1.8152 ve p-değeri 0.069496 olup, istatistiksel olarak anlamlı değildir. Modelin hata terimlerinin varyansı 0.017613, standart hatası 0.0014321, t istatistiği 12.2986 ve p-değeri 9.2131e-35 olup, varyansın istatistiksel olarak anlamlı olduğunu gösterir. Sonuç olarak, AR(2) modelinde sabit terim ve AR(1) parametresi anlamlı bulunmuştur.



Şekil 3. 17. AR(2) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği

Tahmin grafiğine bakıldığında tahminlerin gerçek verilere yakın olduğu görülmektedir. Bu grafik, modelin tahminlerinin gerçek verilere göre ne kadar sapma gösterdiğini göstermektedir. AIC değeri -150.5609 olarak hesaplanmış olup, BIC değeri ise -139.0907'dir. BIC'nin biraz daha yüksek olması modelin biraz daha karmaşık olduğunu gösterse de, değer hala kabul edilebilir seviyededir. Sonuç olarak, hem AIC hem de BIC değerleri AR(2) modelinin veriye iyi uyum sağladığını ve modelin karmaşıklığının uygun olduğunu göstermektedir.

3.2.2.1.3. AR(3) Modeli

AR(3) modeli, geçmişteki üç değer, yani üç önceki zaman noktasının, mevcut değeri üzerindeki etkisini modelleyen bir zaman serisi modelidir. Bu model, daha geniş bir zaman aralığını dikkate alarak, mevcut değerlerin tahmin edilmesinde daha fazla esneklik sağlamaktadır. Model formülü:


$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \phi_3 y_{t-3} + c + \epsilon_t$$

y_t : Zamanda t anındaki y değişkeninin değerini, ϕ_1 , ϕ_2 ve ϕ_3 : Parametreleri, -1 , y_{t-2} ve y_{t-3} : y değişkeninin geçmişteki üç değeri göstermektedir. Bu modele örnek olarak; Bugünkü satış hacmi, dünkü, ondan önceki günkü ve ondan iki gün önceki satış hacmine, bir sabite (ortalama satış hacmi gibi) ve bir miktar faktöre (promosyonlar, mevsimsellik gibi) bağlı olabilir. Aşağıdaki tabloda model sonuçları ve bu sonuçların açıklaması detaylı şekilde verilmiştir.

Parametreer	Değer	Standart Hata	t İstatistik	P-Değeri
Sabit	0.1792	0.056372	3.1788	0.0014787
AR{1}	0.42931	0.07395	5.8054	6.4227e-09
AR{2}	0.16249	0.098832	1.6441	0.10015
AR{3}	0.020819	0.083888	0.24817	0.804
Varyans	0.017606	0.0015194	11.5873	4.7817e-31

Tablo 3. 4. AR(3) Modeli Sonuçları

Sabit terimin değeri 0.1792, standart hatası 0.056372, t istatistiği 3.1788 ve p -değeri 0.0014787 olup, sabit terimin modelde önemli bir rol oynadığını gösterir. AR(1) parametresinin değeri 0.42931, standart hatası 0.07395, t istatistiği 5.8054 ve p -değeri 6.4227e-09'dur; bu da AR(1) parametresinin istatistiksel olarak anlamlı olduğunu ve önceki dönemin mevcut dönemi %42.931 oranında etkilediğini gösterir. AR(2) parametresinin değeri 0.16249, standart hatası 0.098832, t istatistiği 1.6441 ve p -değeri 0.10015 olup, istatistiksel olarak anlamlı değildir. AR(3) parametresinin değeri 0.020819, standart hatası 0.083888, t istatistiği 0.24817 ve p -değeri 0.804 olup, istatistiksel olarak anlamlı değildir. Modelin hata terimlerinin varyansı 0.017606, standart hatası 0.0015194, t istatistiği 11.5873 ve p -değeri 4.7817e-31 olup, varyansın istatistiksel olarak anlamlı olduğunu gösterir. Sonuç olarak, AR(3) modelinde sabit terim ve AR(1) parametresi anlamlı bulunmuştur, ancak AR(2) ve AR(3) parametreleri anlamlı değildir ve modelin hata terimlerinin varyansı da anlamlıdır.



Şekil 3. 18. AR(3) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği

Grafik, üçüncü dereceden otoregresif modelin gerçek verilere ne kadar uyduğunu görsel olarak göstermiştir. Bu grafik, modelin tahminlerinin gerçek değerlerle karşılaştırmasını yapmıştır. Modelde bir kaç nokta hariç, genel anlamda güvenilir tahminlerin yapıldığı görülmektedir. AIC değeri -148.6156 ve BIC değeri -134.3165 olarak hesaplanmıştır. Sonuç olarak, hem AIC hem de BIC değerleri AR(3) modelinin veriye iyi uyum sağladığını ve karmaşıklığının kabul edilebilir olduğunu gösterir, bu da modelin genel performansının yüksek olduğunu göstermektedir.

3.2.2.2.MA Model

MA, hareketli ortalama (Moving Average) yöntemidir. Zaman serisi analizinde kullanılan bir modelleme tekniğidir. MA modelleri, bir zaman serisinin mevcut değerini, önceki zaman noktalarındaki hataların bir kombinasyonu olarak tahmin etmeye çalışır. Aşağıda MA modelleri sonuçları ve açıklamalarıyla birlikte sıralanmıştır.

3.2.2.2.1.MA(1) Modeli

MA(1) yöntemi, bir hareketli ortalama modelidir ve bir zaman serisinin mevcut değerini önceki zaman noktalarındaki hataların ve mevcut zamandaki bir gecikmenin birleşimi olarak tahmin etmeye çalışır. Model formülü:


$$y_t = c + \epsilon_t + \theta_1 \epsilon_{t-1}$$

Burada, y_t : Zamanda t anındaki y değişkeninin değeri, ϵ_t ve ϵ_{t-1} : Hata terimleri ve θ_1 : Parametre'yi göstermektedir. Örnek üzerinden açıklayacak olursak; Bugünkü hava sıcaklığı, bir sabite (ortalama sıcaklık gibi), geçmişteki bir hata terimine ve bir miktar faktöre (rüzgar, yağmur gibi) bağlı olabilir. Aşağıda tablo 3.5'te MA(1) yönteminin sonuçları açıklamasıyla beraber verilmiştir.

Parametre	Değer	Standart Hata	t İstatistik	P-Değeri
Sabit	0.46006	0.018379	25.0322	2.7262e-138
MA{1}	0.37477	0.07651	4.8983	9.6683e-07
Varyans	0.020127	0.0018459	10.9037	1.1063e-27

Tablo 3. 5. MA(1) Modeli Sonuçları

Sabit terimin değeri 0.46006, standart hatası 0.018379, t istatistiği 25.0322 ve p-değeri 2.7262e-138 olup, modelin açıklama gücüne önemli bir katkı sağladığını gösterir. MA(1) parametresinin değeri 0.37477, standart hatası 0.07651, t istatistiği 4.8983 ve p-değeri 9.6683e-07'dir; bu da bir önceki dönemin hata teriminin mevcut dönemi %37.477 oranında etkilediğini ve parametrenin anlamlı olduğunu gösterir. Modelin hata terimlerinin varyansı 0.020127, standart hatası 0.0018459, t istatistiği 10.9037 ve p-değeri 1.1063e-27 olup, varyansın da anlamlı olduğunu gösterir. Sonuç olarak, MA(1) modelinde sabit terim ve MA(1) parametresi istatistiksel olarak anlamlıdır ve modelin hata terimlerinin varyansı da anlamlıdır. Bu sonuçlar, MA(1) modelinin veriye iyi uyum sağladığını ve parametrelerinin önemli olduğunu gösterir.



Şekil 3. 19. MA(1) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği

Grafiğin noktaları bir çizgi boyunca simetrik olarak dağılmaktadır, yani tahmin edilen değerler gerçek değerlere yakındır. AIC değeri -134.9531 ve BIC değeri -126.3047 olarak hesaplanmıştır. Bu sonuçlar, modelin genel performansının yüksek olduğunu ve MA(1) modelinin uygun bir seçim olduğunu gösterir. Ayrıca, model parametrelerinin istatistiksel olarak anlamlı olması, modelin daha da güvenilir olduğunu göstermektedir.

3.2.2.2. MA(2) Modeli

MA(2) modelinde, iki zaman önceki hata terimleri ile mevcut hata teriminin birleşimi kullanılarak mevcut zaman noktasındaki değer tahmin edilmektedir. Model formülü:


$$y_t = c + \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2}$$

Burada, y_t : Zamanda t anındaki y değişkeninin değeri, ϵ_t , ϵ_{t-1} ve ϵ_{t-2} : Hata terimlerini ve θ_1 ve θ_2 : Parametreleri göstermektedir. Modele örnek olarak; Bugünkü satış hacminin, bir sabite (ortalama satış hacmi gibi), geçmişteki iki hata terimine ve bir faktöre (promosyonlar, mevsimsellik gibi) bağlı olabilmesi gösterilebilir. Aşağıda tablo 3.6’da model sonuçları detaylı olarak açıklanmıştır.

Parametre	Değer	Standart Hata	t İstatistik	P-Değeri
Sabit	0.45972	0.021842	21.0481	2.3784e-98
MA{1}	0.40542	0.072496	5.5922	2.2418e-08
MA{2}	0.26106	0.079789	3.2719	0.0010682
Varyans	0.018588	0.0016302	11.4022	4.0792e-30

Tablo 3. 6. MA(2) Model Sonuçları

Sabit terim, MA(1) ve MA(2) parametreleri istatistiksel olarak anlamlı bulunmuş, ayrıca modelin hata terimlerinin varyansı da istatistiksel olarak anlamlıdır. Bu sonuçlar, MA(2) modelinin veriye iyi bir şekilde uyum sağladığını ve parametrelerin önemli olduğunu göstermektedir.



Şekil 3. 20. MA(2) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği

Model uyum grafiđi, model tarafından tahmin edilen deđerlerin gerek verilere ne kadar yakın olduđunu gstermektedir. Ortaya ıkan sonulara gre, AIC deđerı -143.4544 olarak hesaplanmıřtır ve MA(2) modelinin veriye iyi bir uyum sađladıđını gstermektedir. BIC deđerı ise -131.9232 olarak hesaplanmıřtır ve bu da modelin uygun karmařıklık dzeyine sahip olduđunu iřaret etmektedir. Bu sonular, MA(2) modelinin genel performansının yksek olduđunu gsterir ve MA(2) modelinin uygun bir seim olduđu sylenebilir.


3.2.2.2.3. MA(3) Modeli

MA(3) modeli,  nceki hata terimleri ile mevcut hata teriminin birleřimi kullanılarak mevcut zaman noktasındaki deđer tahmin edilir. Burada, tahminleme ge miřteki 3 hata terimine bađlı olarak yapılır. Ařađıda tablo 3.7' de modelin sonu ve aıklamaları verilmiřtir.

Parametre	Deđer	Standart Hata	t İstatistik	P-Deđerı
Sabit	0.45948	0.024626	18.6579	1.0885e-77
MA{1}	0.43129	0.075253	5.7312	9.97e-09
MA{2}	0.32189	0.09264	3.4746	0.00051159
MA{3}	0.15106	0.11939	1.2652	0.20579
Varyans	0.018043	0.0015496	11.6434	2.4792e-31

Tablo 3. 7. MA(3) Modeli Sonuları

Sabit terim deđerı 0.45948, p-deđerı 1.0885e-77 ile olduka anlamlıdır. MA(1) parametresi iin deđer 0.43129, p-deđerı 9.97e-09'dur; MA(2) iin deđer 0.32189, p-deđerı 0.00051159'dur. Ancak, MA(3) parametresi iin deđer 0.15106, p-deđerı 0.20579'dur, yani anlamlı deđildir. Modelin hata terimlerinin varyansı istatistiksel olarak anlamlıdır (p-deđerı: 2.4792e-31). Sonu olarak, MA(3) modeli sabit terim, MA(1) ve MA(2) parametreleri aısından anlamlıdır, ancak MA(3) parametresi iin anlamlı deđildir. Model, veriye uygun bir řekilde uyum sađlar



Şekil 3. 21. MA(3) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği

Sonuçlara göre, AIC değeri -145.3811 olarak oldukça düşük bir değere sahiptir, bu da MA(3) modelinin veriye iyi uyum sağladığını gösterir. BIC değeri ise -130.9671 olarak hesaplanmıştır, bu da modelin uygun bir karmaşıklığa sahip olduğunu gösterir. Hem AIC hem de BIC değerlerinin düşük olması, MA(3) modelinin genel performansının yüksek olduğunu işaret etmektedir. Bu sonuçlar, modelin veriyi iyi açıkladığını ve uygun bir seçenek olduğunu göstermektedir

3.2.2.3.ARMA Model

ARMA modeli, zaman serisini hem geçmiş değerlere (AR bileşeni) hem de geçmiş hatalara (MA bileşeni) dayanarak tahmin etmektedir. Bu şekilde, model zaman serisinin hem otoregresif hem de hareketli ortalama özelliklerini yakalayabilmektedir. ARMA modelleri, zaman serilerinin yapılarını modellemek için yaygın olarak kullanılır ve tahmin, analiz ve zaman serileri üzerindeki diğer işlemler için kullanılmaktadır. Aşağıda bu modelin uygulamaları sırasıyla verilmiştir.

3.2.2.3.1.ARMA(1,1) Modeli

ARMA(1,1) modeli, hem otoregresif (AR) hem de hareketli ortalama (MA) bileşenlerini içeren bir zaman serisi modelidir. ARMA(1,1) modeli, geçmiş değerlere (AR bileşeni) ve geçmiş hatalara (MA bileşeni) dayanarak mevcut değeri tahmin etmektedir. Model formülü:

$$y_t = \phi_1 y_{t-1} + \epsilon_t + \theta_1 \epsilon_{t-1}$$


Burada, y_t : Zamanda t anındaki y değişkeninin değerini, y_{t-1} : Zamanda $t-1$ anındaki y değişkeninin değerini, ϕ_1 : Autoregressive (AR) parametresini, ϵ_t : Hata terimini ve θ_1 : Moving Average (MA) parametresini göstermektedir. Örneğin; hava

sıcaklığının, d nk  hava sıcaklığına ve ge miřteki hata terimlerine baėlı olabilmesi gibi. Ařaėıda Tablo 3.8’de model sonu ları ve a ıklaması verilmiřtir.

Parametre	Deėer	Standart Hata	t İstatistik	P-Deėeri
Sabit	0.11209	0.059796	1.8745	0.060861
AR{1}	0.75905	0.12436	6.1035	1.0379e-09
MA{1}	-0.33986	0.14577	-2.3314	0.019733
Varyans	0.017571	0.0014753	11.9101	1.0484e-32

Tablo 3. 8. ARMA(1,1) Modeli Sonu ları

ARMA(1,1) modelinde sabit terim istatistiksel olarak anlamlı deėildir, ancak AR(1) ve MA(1) parametreleri istatistiksel olarak anlamlı bulunmuřtur. Bu sonu , modelin sabit teriminin modelin a ıklama g c ne katkı saėlamadıėını, ancak  nceki d nemlerin deėerleri ve hata terimlerinin ge miř d nemlerinin etkili olduėunu g stermektedir. Modelin hata terimlerinin varyansı da istatistiksel olarak anlamlıdır, bu da modelin uygun olduėunu g sterir. Bu bulgular, ARMA(1,1) modelinin veriye uyum saėladığı ve parametrelerin  nemli olduėunu g stermektedir.



řekil 3. 22. ARMA(1,1)Ger ek Hasta Ve Tahmini Hasta Sayıları Karřılařtırma Grafiiėi

AIC deėeri -150.8812 ve BIC deėeri -139.3804 olarak hesaplanmıřtır. Bu deėerler, ARMA(1,1) modelinin veriye iyi bir řekilde uyum saėladığı ve modelin karmařıklığının da uygun olduėunu g stermektedir. Model parametrelerinin istatistiksel olarak anlamlı olduėu dikkate alındığında, ARMA(1,1) modelinin uygun bir model se imi olduėu s ylenebilir. Bu bulgular, modelin genel performansının y ksek olduėuna iřaret etmektedir.

3.2.2.3.2. ARMA(2,2) Modeli

ARMA(2,2) modeli, iki otoregresif (AR) bileşenini ve iki hareketli ortalama (MA) bileşenini içeren bir zaman serisi modelidir. Bu model, mevcut değeri hem önceki zaman adımlarının değerlerine (AR bileşeni) hem de geçmiş hataların lineer kombinasyonuna (MA bileşeni) dayanarak tahmin etmeye çalışmaktadır. Model formülü:


$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2}$$

Burada, y_t : Zamanda t anındaki y değişkeninin değerini, y_{t-1} ve y_{t-2} : Zamanda $t-1$ ve $t-2$ anındaki y değişkeninin değerlerini (geçmişteki değerler), ϕ_1 ve ϕ_2 : Autoregressive (AR) parametrelerini, ϵ_t : Hata terimini ve θ_1 ve θ_2 : Moving Average (MA) parametrelerini göstermektedir. Örnek olarak; Bugünkü hisse senedi değerinin, dünkü ve ondan önceki günkü hisse senedi değerine ve geçmişteki hata terimlerine bağlı olabilmesi gösterilebilir. Aşağıda model sonuç ve açıklamaları Tablo 3.9'da gösterilmiştir.

Parametre	Değer	Standart Hata	t İstatistik	P-Değeri
Sabit	0.3216	0.13894	2.3146	0.020634
AR{1}	-0.33556	0.1471	-2.2811	0.022544
AR{2}	0.63932	0.14089	4.5376	5.6898e-06
MA{1}	0.80196	0.18107	4.4291	9.4628e-06
MA{2}	-0.19804	0.1687	-1.174	0.24041
Varyans	0.017188	0.0016973	10.1266	4.2088e-24

Tablo 3. 9. ARMA(2,2) Modeli Sonuçları

ARMA(2,2) modelinde sabit terim (0.3216, $p=0.020634$), AR(1) (-0.33556, $p=0.022544$), AR(2) (0.63932, $p=5.6898e-06$) ve MA(1) (0.80196, $p=9.4628e-06$) parametreleri istatistiksel olarak anlamlı bulunmuştur. Ancak, MA(2) parametresi (-0.19804, $p=0.24041$) anlamlı değildir. Modelin hata terimlerinin varyansı (0.017188, $p=4.2088e-24$) da istatistiksel olarak anlamlıdır. Bu sonuçlar, ARMA(2,2) modelinin veriye iyi bir şekilde uyum sağladığını ve modelin parametrelerinin önemli olduğunu göstermektedir.



Şekil 3. 23. ARMA(2,2) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği

ARMA(2,2) modelinde, model fit grafiği genellikle verilere iyi uyum sağlamış ve zaman serisindeki örüntüleri yakalayabilmiştir. ARMA(2,2) modeli, hem otoregresif hem de hareketli ortalama özelliklerini yakalamış ve zaman serisindeki karmaşıklığı modellemiştir. ARMA(2,2) modelinin AIC değeri -149.7893, BIC değeri ise -132.5841 olarak hesaplanmıştır. Bu sonuçlar, ARMA(2,2) modelinin genel performansının yüksek olduğunu ve karmaşıklığının kabul edilebilir düzeyde olduğunu işaret etmektedir. Ancak, MA(2) parametresinin istatistiksel olarak anlamlı olmaması, daha basit ARMA(2,1) veya ARMA(1,1) modellerinin değerlendirilmesini gerektirebilir.

3.2.2.4. ARIMA MODEL

ARIMA (Oto-Regressive Integrated Moving Average) modeli, zaman serisi verilerinin analizi için kullanılan bir modeldir. ARIMA modeli, üç bileşenden oluşur:

AR (Oto-Regressive): Geçmiş zaman adımlarındaki değerlerin ağırlıklı toplamını temsil eden bir bileşendir. AR bileşeni, geçmiş zamandaki değerlerin bugünkü değeri nasıl etkilediğini modellemeye çalışmaktadır.

I (Integrated): Differencing olarak da adlandırılan bu bileşen, zaman serisinin trendini ve durağanlık düzeyini ortadan kaldırmak için kullanılır. Bu, veri setinin farklarını alarak yapılır. Durağanlık sağlanıncaya kadar bir veya daha fazla fark alınabilir.

MA (Hareketli Ortalama): Önceki hata terimlerinin ağırlıklı toplamını temsil eden bir bileşendir. MA bileşeni, modelin düzensizlikleri veya rastgele değişimleri yakalamaya çalışır.

ARIMA modeli, zaman serisi verilerinin tahmin edilmesi ve gelecekteki trendlerin veya desenlerin analiz edilmesi için yaygın olarak kullanılan bir araçtır. Ayrıca, ARIMA modeli, modelin parametrelerini belirlemek için kullanılan model uyumu ölçütlerine dayanarak en uygun modelin seçilmesine yardımcı olabilmektedir. Aşağıda arıma modellerinin sonuç ve açıklamaları sıralanmıştır.

3.2.2.4.1 ARIMA(1.1.1) MODELİ

ARIMA(1,1,1) modeli, bir önceki zaman adımının değeri (AR), birinci dereceden fark (I) ve bir önceki hata teriminin hareketli ortalaması (MA) arasındaki ilişkiyi modellemek için kullanılır. Bu model, zaman serisinin trendini ve durağanlık düzeyini dikkate alarak tahminler yapabilir ve geçmiş verilerin etkilerini ve hatalarını düzeltmek için kullanılır. Model formülü:

$$y_t = \phi_1 y_{t-1} + \epsilon_t + \theta_1 \epsilon_{t-1} + \delta_1 \epsilon_{t-s}$$


Burada, y_t : Zamanda t anındaki y değişkeninin değerini, y_{t-1} : Zamanda $t-1$ anındaki y değişkeninin değerini, ϕ_1 : Autoregressive (AR) parametresini, ϵ_t : Hata terimini, θ_1 : Moving Average (MA) parametresini, δ_1 : Mevsimsel Moving Average (MA) parametresini ve s : Mevsimsel periyodu göstermektedir. Örneğin; Aylık veya üç aylık satış hacminin, geçmişteki satış hacmine, geçmişteki hata terimlerine ve mevsimsel hata terimlerine bağlı olabilmesi gibi. Aşağıda Tablo 3.10'da modelin sonuç ve açıklamaları verilmiştir.

Parametre	Değer	Standart Hata	t İstatistik	P-Değeri
Sabit	0.00080943	0.00034209	2.3662	0.017973
AR{1}	0.41937	0.06259	6.7003	2.0792e-11
MA{1}	-1	0.034105	-29.3211	5.5855e-189
Varyans	0.016865	0.0016965	9.9409	2.7645e-23

Tablo 3. 10. ARIMA(1.1.1) Modeli Sonuçları

Modelde, sabit terim (0.00080943, $p=0.017973$), AR(1) (0.41937, $p=2.0792e-11$), ve MA(1) (-1, $p=5.5855e-189$) parametreleri istatistiksel olarak anlamlı bulunmuştur. Modelin hata terimlerinin varyansı da anlamlıdır (0.016865, $p=2.7645e-23$). Bu sonuçlar, modelin veriye iyi uyum sağladığını ve modelin parametrelerinin

önemli olduğunu göstermektedir. Özetle, ARIMA(1,1,1) modelinde sabit terim, AR(1) ve MA(1) parametreleri istatistiksel olarak anlamlı bulunmuştur. Modelin hata terimlerinin varyansı da istatistiksel olarak anlamlıdır. Bu sonuçlar, modelin veriye iyi bir şekilde uyum sağladığını ve modelin parametrelerinin önemli olduğunu göstermektedir.



Şekil 3. 24. ARIMA(1,1,1) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği

AIC değeri -156.2932 ve BIC değeri -144.8231, modelin veriye iyi uyum sağladığını ve karmaşıklığının kabul edilebilir olduğunu göstermektedir. Sonuç olarak, modelin yüksek performanslı ve uygun bir model seçimi olduğu söylenebilir. Bu sonuçlar, ARIMA(1,1,1) modelinin veri setine oldukça iyi uyduğunu ve modelin tüm terimlerinin istatistiksel olarak anlamlı olduğunu göstermektedir. Bu modelin artık terimleri de homojen bir şekilde dağılmıştır ve modelin uygunluğunu doğrulamaktadır.

3.2.2.4.2 ARIMA(2,2,2) MODELİ

ARIMA(2,2,2) modeli, otoregresif (AR), hareketli ortalama (MA) ve fark terimlerini içeren bir zaman serisi modelidir. Formülü aşağıdaki gibidir:

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \delta_1 \epsilon_{t-s}$$

AR(2): Model, 2 görünüm öncesindeki gözlemlerle ilişkili bir otoregresif terim içermektedir. Bu, geçmiş gözlemlerin bugünkü değerleri üzerindeki etkisini yakalamaya çalışmaktadır.


MA(2): Model, 2 görünüm öncesindeki hata terimleri arasındaki ilişkiyi yakalamak için 2 hareketli ortalama terimi içerir.

Fark(2): Model, orijinal zaman serisinin iki kez farkını alır. Bu, seriyi durağan hale getirmeye ve ardışık gözlemler arasındaki farkları modellemeye çalışır. Aşağıda model sonuçları ve açıklamaları Tablo 3.11’de verilmiştir.

Parametre	Değer	Standart Hata	t İstatistik	P-Değeri
Sabit	-5.0083e-05	0.00036139	-0.13858	0.88978
AR{1}	-1.3314	0.076309	-17.4469	3.6333e-68
AR{2}	-0.34583	0.076706	-4.5085	6.5292e-06
MA{1}	0	0.064364	0	1
MA{2}	-1	0.066654	-15.0028	7.041e-51
Varyans	0.020135	0.0020846	9.659	4.504e-22

Tablo 3. 11. ARIMA(2.2.2) Modeli Sonuçları

Sabit terim -5.0083e-05 olup, standart hatası 0.00036139 ve t istatistiği -0.13858'dir, p-değeri ise 0.88978'dir; bu, sabit terimin istatistiksel olarak anlamlı olmadığını gösterir. AR(1) parametresi -1.3314, standart hatası 0.076309, t istatistiği -17.4469 ve p-değeri 3.6333e-68 olup, istatistiksel olarak anlamlıdır. AR(2) parametresi -0.34583, standart hatası 0.076706, t istatistiği -4.5085 ve p-değeri 6.5292e-06 olup, istatistiksel olarak anlamlıdır. MA(1) parametresi 0, standart hatası 0.064364, t istatistiği 0 ve p-değeri 1 olup, istatistiksel olarak anlamlı değildir. MA(2) parametresi -1, standart hatası 0.066654, t istatistiği -15.0028 ve p-değeri 7.041e-51 olup, istatistiksel olarak anlamlıdır. Modelin hata terimlerinin varyansı 0.020135, standart hatası 0.0020846, t istatistiği 9.659 ve p-değeri 4.504e-22 olup, istatistiksel olarak anlamlıdır.



Şekil 3. 25. ARIMA(2,2,2) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği

AIC değeri -128.8994 ve BIC değeri -111.7872 olarak hesaplanan ARMA(2,2) modeli veriye iyi bir uyum sağlamaktadır, ancak diğer daha basit modellerle kıyaslandığında daha yüksek değerlere sahiptir. AR(1), AR(2), ve MA(2) parametreleri istatistiksel olarak anlamlı bulunurken, sabit terim ve MA(1) parametresi anlamlı değildir.

3.2.2.5.SARIMA MODELİ

Zaman serileri analizi, bir değişkenin zaman içindeki davranışını inceleyen ve gelecekteki değerlerini tahmin etmeye çalışan önemli bir istatistiksel alandır. Bu model, ekonometri, finans, meteoroloji, mühendislik ve diğer birçok disiplinde kullanılmaktadır. Sarıma (Seasonal Autoregressive Integrated Moving Average) modeli, zaman serileri verilerini analiz etmek ve gelecekteki değerlerini tahmin etmek için yaygın olarak kullanılan bir istatistiksel modeldir. Sarıma, verinin önceki zaman noktalarındaki değerlerle ilişkileri modelleyerek trendleri, mevsimsellikleri ve diğer önemli özellikleri ele alır. Bu model, bir zaman serisinin istatistiksel özelliklerini anlamak ve gelecekteki trendleri öngörmek için güçlü bir araç olarak kabul edilmektedir. Aşağıda bu modelin uygulamaları sıralanmıştır.

3.2.2.5.1.SARIMA (1.1.1) Modeli

Sarıma (Seasonal Autoregressive Integrated Moving Average) (1.1.1) modeli, zaman serilerini modellemek için kullanılan bir istatistiksel yöntemdir. Bu model, üç temel bileşenin bir kombinasyonunu içermektedir. Model formülü:


$$y_t = \phi_1 y_{t-s} + \epsilon_t + \theta_1 \epsilon_{t-s} + \delta_1 \epsilon_{t-2s}$$

Burada, yt: Zamanda t anındaki y değişkeninin değerini, yt-s: Zamanda t-s anındaki y değişkeninin değeri (mevsimsel geçmişteki değeri), s: Mevsimsel periyodu (örneğin, aylar için 12, çeyrekler için 4), ϕ_1 : Mevsimsel Autoregressive (AR) parametresini göstermektedir. Model, GSYİH, enflasyon veya işsizlik oranı gibi mevsimsellik içeren ekonomik göstergeleri modellemek için kullanılabilir. Aşağıda Tablo 3.12’de model sonuçları ve açıklaması verilmiştir.

Parametre	Değer	Standart Hata	t istatistik	P-Değeri
Sabit	0.063799	0.0024287	26.2686	4.3837e-15
AR{1}	-0.18984	0.66505	-0.28546	0.7753
SAR{1}	-0.21649	0.63045	-0.34338	0.73131
MA{1}	1	0.37058	2.6984	0.0069666
SMA{1}	0.98763	0.36179	2.7298	0.0063371
Beta	1.2698	0.028107	45.1762	0
Varyans	0.0020545	0.00032134	6.3936	1.6203e-10

Tablo 3. 12. SARIMA(1.1.1) Modeli Sonuçları

Model sabit terimin değeri 0.063799, standart hatası 0.0024287 ve t istatistiği 26.2686’dır. İlgili p-değeri 4.3837e-152 olup, sabit terimin istatistiksel olarak anlamlı olduğunu göstermektedir. AR(1) parametresi istatistiksel olarak anlamlı değildir (p-değeri 0.7753), SAR(1) parametresi de anlamlı değildir (p-değeri 0.73131). MA(1) parametresi (p-değeri 0.0069666), SMA(1) parametresi (p-değeri 0.0063371), ve Beta parametresi (p-değeri 0) istatistiksel olarak anlamlıdır. Özetle, SARIMA(1,1,1)modelinde sabit terim, MA(1), SMA(1) ve Beta parametreleri anlamlı bulunmuş, ancak AR(1) ve SAR(1) parametreleri anlamlı değildir.



Şekil 3. 26. SARIMA(1,1,1) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği

AIC değeri -417.2551 ve BIC değeri -397.2364 olarak hesaplanan SARIMA(1,1,1) modeli için oldukça düşük değerlere sahiptir. Bu durum, modelin veriye iyi bir uyum sağladığını gösterir. Ayrıca, model parametrelerinin istatistiksel olarak anlamlı olduğu ve modelin karmaşıklığının uygun olduğu görülmektedir. Bu nedenle, SARIMA(1,1,1) modeli, AIC ve BIC değerleri ile model parametrelerinin anlamlılığı açısından başarılı bir performans sergilemektedir. Bu sonuçlar, modelin uygun bir seçenek olduğunu göstermektedir.

3.2.2.5.2.SARIMA (2.2.2) Modeli

SARIMA (2,2,2) modeli, otoregresif (AR), hareketli ortalama (MA) ve fark (I) bileşenlerini içeren bir zaman serisi modelidir. Her bir bileşen, veri setindeki belirli özellikleri açıklamak için kullanılır. Model Formülü:

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \delta_1 \epsilon_{t-s}$$


Karmaşık hata yapıları ve mevsimsellik içeren zaman serilerinde bu model kullanılmaktadır. Otokorelasyon gibi karmaşık hata yapılarına sahip mevsimsel zaman serilerini modellemek için kullanılabilir. SARIMA(2,2,2) modeli, günlük veya haftalık sosyal medya etkileşimi, takipçi sayısı veya beğeni sayısı gibi mevsimsellik içeren sosyal medya verilerini modellemek için kullanılabilir. Aşağıda Tablo 3.13'te modelin sonuçları verilmiştir.

Parametre	Değer	Standart Hata	t İstatistik	P-Değeri
Sabit	0.076353	0.017841	4.2796	1.8725e-05

AR{1}	-1.3454	0.022618	-59.4849	0
AR{2}	-0.52035	0.017234	-30.1939	2.8443e-20
SAR{2}	-0.70213	0.042912	-16.3619	3.579e-60
SAR{4}	-0.30334	0.03525	-8.6055	7.601e-18
MA{1}	1.829	0.054171	33.7628	6.9324e-25
MA{2}	1	0.058192	17.1845	3.4689e-66
SMA{2}	0.5561	0.10401	5.3468	8.9522e-08
SMA{4}	0.20049	0.10721	1.87	0.061487
Beta	1.3083	0.021767	60.1019	0
Varyans	0.0031206	0.00039519	7.8966	2.8654e-15

Tablo 3. 13. SARIMA(2,2,2) Modeli Sonuçları

SARIMA(2,2,2) modeli için elde edilen sonuçlara göre, sabit terim, AR(1), AR(2), SAR(2), SAR(4), MA(1), MA(2), SMA(2) ve Beta parametreleri istatistiksel olarak anlamlı bulunmuştur. Ancak, SMA(4) parametresi istatistiksel olarak anlamlı değildir. Ayrıca, modelin hata terimlerinin varyansı da istatistiksel olarak anlamlıdır. Bu sonuçlar, modelin veriye iyi bir şekilde uyum sağladığını ve önemli parametrelere sahip olduğunu göstermektedir.



Şekil 3. 27. SARIMA(2,2,2) Gerçek Hasta Ve Tahmini Hasta Sayıları Karşılaştırma Grafiği

SARIMA(2,2,2) modeli için hesaplanan AIC değeri -341.5481 ve BIC değeri -310.525 olarak bulunmuştur. Düşük AIC ve BIC değerleri, modelin veriye iyi uyum

sağladığını ve uygun karmaşıklık düzeyine sahip olduğunu göstermektedir. Bu sonuçlar, modelin genel performansının yüksek olduğunu işaret etmektedir. Ayrıca, model parametrelerinin istatistiksel olarak anlamlı olduğu da dikkate alındığında, modelin uygun bir seçim olduğu söylenebilir.

3.2.2.6. Zaman Serisi Modellerinin Değerlendirmesi Ve Karşılaştırılması

Zaman serisi analizi, zaman içindeki veri noktalarının modellemesini ve analizini içeren önemli bir istatistiksel alanı kapsar. Bu alanda, çeşitli modelleme teknikleri kullanılarak veri setlerinin trendlerini, desenlerini ve diğer özelliklerini anlamak ve tahmin etmek amaçlanır. Zaman serisi modelleri arasında popüler olan AR (Otoregresif), MA (Hareketli Ortalama), ARMA (Otoregresif Hareketli Ortalama), ARIMA (Otoregresif Entegre Hareketli Ortalama) ve SARIMA (Sezonluk ARIMA) gibi modeller bulunmaktadır. Bu bölümde, farklı zaman serisi modellerinin performansını değerlendirmek ve karşılaştırmak için kullanılan AIC (Akaike Bilgi Kriteri) ve BIC (Bayes Bilgi Kriteri) gibi ölçütler incelenecek ve modellerin tahmin edilen parametreleri detaylı bir şekilde ele alınacaktır.

Model	AIC	BIC	Anlamlı Parametreler	Sonuç
AR(1)	-148.77	-140.14	Sabit, AR(1), Varyans	İyi uyum, parametreler anlamlı
AR(2)	-150.56	-139.09	Sabit, AR(1), Varyans	İyi uyum, AR(2) parametresi anlamsız
AR(3)	-148.62	-134.32	Sabit, AR(1), AR(2), Varyans	İyi uyum, AR(3) parametresi anlamsız
MA(1)	-134.95	-126.3	Sabit, MA(1), Varyans	İyi uyum, parametreler anlamlı
MA(2)	-143.45	-131.92	Sabit, MA(1), MA(2), Varyans	İyi uyum, parametreler anlamlı
MA(3)	-145.38	-130.97	Sabit, MA(1), MA(2), Varyans	İyi uyum, MA(3) parametresi anlamsız
ARMA(1,1)	-150.88	-139.38	Sabit, AR(1), MA(1), Varyans	İyi uyum, parametreler anlamlı
ARMA(2,2)	-149.79	-132.58	Sabit, AR(1), AR(2), MA(1), Varyans	İyi uyum, MA(2) parametresi anlamsız

ARIMA(1,1,1)	-156.29	-144.82	Sabit, AR(1), MA(1), Varyans	Yüksek performans, parametreler anlamlı
ARIMA(2,2,2)	-128.9	-111.79	AR(1), AR(2), MA(2), Varyans	İyi uyum, sabit ve MA(1) anlamsız
SARIMA(1,1,1)	-417.26	-397.24	Sabit, MA(1), SMA(1), Beta, Varyans	Yüksek performans, parametreler anlamlı
SARIMA(2,2,2)	-341.55	-310.53	Sabit, AR(1), AR(2), SAR(2), SAR(4), MA(1), MA(2), SMA(2), Beta, Varyans	Yüksek performans, SMA(4) anlamsız

Tablo 3. 14. Zaman Serisi Modellerinin Karşılaştırma Tablosu

Yukarıdaki tablo, farklı zaman serisi modellerinin performansını ve parametrelerinin anlamlılığını karşılaştırmalı olarak göstermektedir. SARIMA(1,1,1) modeli en yüksek performansa sahiptir. Bu modelin AIC ve BIC değeri diğer modellere kıyasla oldukça düşüktür ve tüm parametreleri istatistiksel olarak anlamlıdır. Bu sonuç, bu modelin veri setine en iyi şekilde uyum sağladığını ve en güvenilir tahminleri yaptığını göstermektedir. SARIMA(2,2,2) modeli de yüksek performans göstermiştir. AIC ve BIC değerleri kabul edilebilir seviyededir ve çoğu parametresi anlamlıdır. Ancak, SMA(4) parametresi anlamsız bulunmuştur. Bu nedenle, daha basit olan SARIMA(1,1,1) modeli önerilir. Diğer modeller (AR, MA, ARMA) genel olarak iyi uyum sağlamakla birlikte, bazı parametreleri anlamsız çıkmıştır. Bu modellerin performansı SARIMA modeli kadar yüksek değildir. Sonuç olarak, en iyi model performansı SARIMA(1,1,1) modelinde gözlemlenmiştir. Bu modeller, tüm parametrelerinin istatistiksel olarak anlamlı olması ve düşük AIC/BIC değerleri nedeniyle en iyi seçenek olarak öne çıkmaktadır.

3.2.3. Doğrusal Regresyon ile Hasta Sayısı Tahmini

Doğrusal regresyon, istatistik ve makine öğrenmesinde yaygın kullanılan bir tekniktir. Bağımlı bir değişkenin bir veya daha fazla bağımsız değişkene olan lineer ilişkisini modelleyerek çalışmaktadır. Bu sayede, veri setlerindeki ilişkiler anlaşılabılır, tahminlerde bulunulabilir ve değişkenler arasındaki bağlantılar açıklanabilir. Doğrusal regresyonun kullanım alanları oldukça geniştir. Gelecekteki satışları tahmin etmekten, değişkenler arasındaki ilişkileri analiz etmeye, belirli faktörlerin etkisini ölçmeye ve

veri setlerindeki eğilimleri belirlemeye kadar birçok alanda kullanılabilir. Bu yüzden bu yöntem seçilmiş ve kullanılmıştır. Aşağıda, yapılan analizler aşama aşama incelenmiş ve açıklanmıştır (James vd., 2013).

3.2.3.1. Regresyon Modelinin Uygulanması Ve Analizi

Analiz kapsamında, 13 bağımsız değişken ve 1 bağımlı değişken kullanılmıştır. Bağımlı değişken, acil servise başvuru oranlarını temsil ederken, bağımsız değişkenler ise doktor sayısı, toplam nüfus, nüfusun demografik dağılımı, kişi başına gelir, okuma yazma oranları, enflasyon oranları, kişi başına düşen sağlık harcaması ve kamu sağlık harcaması oranı gibi faktörleri içermektedir. Aşağıdaki denklem kurulmuştur:

$$y \sim 1 + x_1 + x_2 + x_3 + x_4 + x_5 + x_6 + x_7 + x_8 + x_9 + x_{10} + x_{11} + x_{12} + x_{13}$$

Bu denklem, bağımlı değişken y'nin, sabit bir terim (1) ve 13 bağımsız değişken ($x_1, x_2, \dots, x_{13}$) tarafından nasıl tahmin edildiğini göstermektedir

Regresyon modeli formülü şu şekildedir:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_{13} x_{13} + \epsilon$$

y: Tahmin edilmek istenen bağımlı değişkeni temsil etmektedir.

β_0 : Kesme noktası olarak adlandırılan sabit terim. Bu, tüm bağımsız değişkenlerin sıfır olduğu durumda y'nin ortalama değerini temsil eder.

$\beta_1, \beta_2, \dots, \beta_{13}$: Bağımsız değişkenlerin katsayıları. Her bir katsayı, ilgili bağımsız değişkendeki bir birimlik değişimin y üzerindeki etkisini gösterir.

$x_1, x_2, \dots, x_{13}$: Bağımsız değişkenler. Modelde kullanılan 13 değişkeni temsil eder.

ϵ : Hata terimi. Modeldeki tahmin hatasını temsil eder.

Bu analiz, hasta sayılarının 13 bağımsız değişken tarafından nasıl etkilendiğini göstermektedir. Her bir bağımsız değişkenin katsayısı, Hasta sayısı üzerindeki etkisini gösterir. Kesme noktası, tüm bağımsız değişkenlerin sıfır olduğu durumda y'nin ortalama değerini temsil eder. Hata terimi ise , modeldeki tahmin hatasını temsil etmektedir. Aşağıdaki tabloda bağımsız değişkenlerin etki oranları gösterilmiş ve açıklanmıştır.

Değişken	Katsayı	Standart Hata (SE)	t-İstatistik	p-Değer
----------	---------	--------------------	--------------	---------

Kesme Noktası	0.0027346	0.03586	0.076259	0.93933
Doktor sayısı(x1)	-0.08179	0.082858	-0.9871	0.32543
T.Nüfus(x2)	-4.6002	1.4354	-3.2049	0.0017002
Erkek Nüfusu(x3)	0.13114	1.274	0.10293	0.91818
Kadın Nüfusu(x4)	0.65817	0.65964	0.99777	0.32025
Genç Nüfus Sayısı (x5)	0.26995	0.14137	1.9095	0.058402
Yetişkin Nüfus Sayısı (x6)	4.2519	1.3645	3.1162	0.002255
Yaşlı Nüfus Sayısı (x7)	-0.70301	0.31795	-2.2111	0.028776
Kişi Başı Gelir (x8)	-0.032893	0.12858	-0.25582	0.79849
Okuma Yazma Oranları (x9)	0.30054	0.47937	0.62695	0.53179
ÜFE (x10)	0.17104	0.23835	0.71761	0.47428
TÜFE (x11)	-0.13871	0.2223	-0.62396	0.53375
Kişi Başına Düşen Sağlık Harcaması (x12)	0.55219	0.19677	2.8063	0.005783
Kamu Sağlık Harcama Oranı (x13)	0.18485	0.081979	2.2548	0.025816

Tablo 3. 15. Acil Servise Başvuru Oranlarını Etkileyen Faktörler

Aşağıda Tablo 3.15'e bakarak veriler analiz edilmiş ve yorumlanmıştır (Kutner vd., 2004):

Standart Hata: Regresyon analizinde, tahmin edilen katsayıların ne kadar güvenilir olduğunu gösteren bir ölçüdür. Her bir bağımsız değişken için hesaplanan standart hata değeri, o değişkenin katsayısının ne kadar hassas olduğunu ve gerçek değerinden ne kadar uzak olabileceğini göstermektedir. Daha düşük standart hataya sahip katsayılar, o değişkenin katsayısının daha güvenilir ve doğru olduğunu göstermektedir. Daha yüksek standart hataya sahip katsayılar ise , o değişkenin katsayısının daha az güvenilir ve daha belirsiz olduğunu göstermektedir. Kamu Sağlık Harcama Oranı ve Doktor sayısı, standart hatası en düşük olan iki değişkendir. Buda

yapılan tahminlerin öteki değişkenlere oranla daha sağlıklı ve güvenilir olduğunu göstermektedir.

t-istatistik: T-istatistiği, bir regresyon modelinde katsayıların anlamlılığını değerlendirmek için kullanılan istatistiksel bir ölçüttür. Her bağımsız değişkenin katsayısı için hesaplanan t-istatistiği, tahmin edilen katsayının sıfırdan farklı olup olmadığını belirlemeye yarar. Yüksek bir t-istatistiği, katsayının daha anlamlı olduğunu işaret ederken, pozitif t-istatistiği katsayının bağımlı değişken üzerinde pozitif, negatif t-istatistiği ise negatif bir etki oluşturduğunu gösterir. Genellikle, t-istatistiğinin mutlak değeri 1.96'yı aşıyorsa (veya belirli bir güven düzeyine göre kritik değeri geçiyorsa), bu katsayının istatistiksel olarak anlamlı olduğu kabul edilir. Bu, modeldeki her bir değişkenin bağımlı değişken üzerindeki etkisinin önemini değerlendirmek için kritik bir rol oynar. Toplam nüfus, yetişkin nüfus sayısı, kişi başına düşen sağlık harcaması ve Kamu Sağlık Harcama Oranı, diğer değişkenlere oranla daha büyük t-İstatistik değerini sahiptir. Sonuç olarak, bu değişkenlerin diğer değişkenlere göre daha anlamlı olduğu görülmektedir.

p-değeri: P-değeri, tahmin edilen katsayının istatistiksel olarak anlamlı olup olmadığını belirten bir ölçüttür. Tahmin edilen katsayının sıfırdan farklı olma olasılığını ölçen p-değeri, düşük olduğunda (<0.05 genellikle kabul edilen bir eşiktir), tahmin edilen katsayının istatistiksel olarak anlamlı olduğunu ve bağımsız değişkenin bağımlı değişken üzerindeki etkisinin kabul edildiğini göstermektedir. Daha küçük p-değerleri, ilgili katsayının istatistiksel olarak anlamlı olduğunu belirtirken, daha büyük p-değerleri katsayının istatistiksel olarak anlamlı olmadığını ifade etmektedir. Toplam nüfus, yetişkin nüfus Sayısı, yaşlı nüfus sayısı, Kişi Başına Düşen Sağlık Harcaması ve Kamu Sağlık Harcama Oranı değişkenlerinin 'P'değerlerine bakıldığında istatistiksel olarak anlamlı oldukları görülmektedir.

Analiz sonuçlarına göre, bağımlı değişken olan acil servise başvuru oranlarını etkileyen en anlamlı bağımsız değişkenler, toplam nüfus, yetişkin nüfus sayısı, yaşlı nüfus sayısı, kişi başına düşen sağlık harcaması ve kamu sağlık harcama oranıdır. Bu değişkenlerin düşük p-değerleri (<0.05) ve yüksek t-istatistik değerleri, bağımlı değişken üzerinde önemli bir etkiye sahip olduklarını göstermektedir. Özellikle, toplam nüfus ve yetişkin nüfus sayısının yüksek t-istatistik değerleri ve anlamlı p-değerleri, bu değişkenlerin acil servise başvuru oranları üzerinde güçlü bir etkisi

olduğunu belirtmektedir. Ayrıca, standart hata değerleri açısından doktor sayısı ve kamu sağlık harcama oranı gibi değişkenlerin daha düşük standart hatalara sahip olması, bu değişkenlerin tahminlerinde daha güvenilir ve doğru sonuçlar verdiğini göstermektedir.

3.2.3.2.Doğrusal Regresyon Modelinin Kurulması Ve En Uygun Modelin Seçilmesi

Doğrusal regresyon modellerinin oluşturulması ve en uygun modelin seçilmesi, veri analitiği ve makine öğrenimi alanlarında kritik bir adımdır. Bu süreç, karmaşık veri setlerinden anlamlı bilgilerin çıkarılmasında güçlü bir araç olarak kullanılır. İlk olarak, veriler normalize edilmiş, veri hazırlığı ve görselleştirme aşamalarıyla başlanmış ve ardından doğrusal regresyon modeli oluşturulmuştur. Modelin uygunluğu çeşitli istatistiksel metriklerle değerlendirilmiş. Daha sonra, modelin doğrulanması ve ayarlanması süreci ele alınmış ve en uygun modelin seçilmesi için belirli kriterler belirlenmiştir. Tahmin modelinin tam olarak sağlanabilmesi için Ek-1’de ki gerçek veriler, (0,1) aralığında normalize edilmiştir (Söylemez, 2020). EK-2’ de normalize edilmiş bağımsız değişkenlerin tablosu gösterilmiştir. Aşağıda, regresyon modellerinin sonuçları 3.16’ da karşılaştırmalı olarak verilmiştir.

MODEL	RMSE
Quadratic SVM	0.17399
Cubic SVM	0.44092
Fine Gaussian SVM	0.14083
Medium Gaussian SVM	0.13286
Course Gaussian SVM	0.14045
Boosted Trees	0.13918
Bagged Trees	0.13119
Squared Exponential GPR	0.13998
Matern 5/2 GPR	0.13836

Exponential GPR	0.13498
Rational Quadratic GPR	0.13390

Tablo 3. 16. Regresyon Model Sonuçlarının Karşılaştırılması

Bu bölümde, farklı regresyon yöntemlerinin karşılaştırılması ve en iyi modelin belirlenmesi için izlenen süreç incelenmiştir. Farklı regresyon teknikleri kullanılarak gerçekleştirilen analizler, en uygun modelin seçilmesi ve değerlendirilmesi açısından kritik bir rol oynamaktadır. Bu aşama, modelin doğruluğunu ve güvenilirliğini artırarak, analizin sonuçlarının daha sağlam olmasını sağlamaktadır. Bu nedenle, doğrusal regresyon analizinde en iyi modelin seçilmesi, analizin temel bir parçasıdır ve doğru kararların verilmesi için dikkatli bir değerlendirme gerektirmektedir.


Bu analizde, veri setindeki değişkenler arasındaki ilişkiyi ifade etmek için bir doğrusal model oluşturulmuştur. Bingöl Devlet Hastanesine gelen toplam hasta sayıları aylık olarak bağımlı değişken olarak kabul edilmiş ve buna etki eden 13 faktör bağımsız değişken olarak alınmıştır. En iyi modelin seçildiği bu aşamada, modelin uygunluğu değerlendirilmiş ve farklı modeller arasında karşılaştırma yapılmıştır. Modellerin kök ortalama kare hatası (RMSE) değerleri ölçüt alınarak karşılaştırma yapılmıştır. En iyi modelin seçilmesi, en düşük RMSE değerine sahip olan modelin tercih edilmesini içermektedir. EK-4’ te doğrusal regresyon ile yapılan tahmin kodları gösterilmiştir.

Tablo 3.16, farklı makine öğrenimi ve regresyon tekniklerinin bir dizi veri kümesine uygulanmasıyla elde edilen kök ortalama kare hatası (RMSE) sonuçlarını göstermektedir. RMSE, bir modelin tahminlerinin gerçek değerlerden ne kadar sapma gösterdiğini ölçen bir metrik olarak kullanılmaktadır ve daha düşük bir RMSE değeri, daha iyi bir tahmin performansını işaret etmektedir. Tablodaki farklı modellerin performansı incelendiğinde, Boosted Trees ve Exponential GPR gibi modellerin düşük RMSE değerlerine sahip olduğu görülmektedir. Öte yandan, Cubic SVM ve Fine Gaussian SVM gibi modellerin RMSE değerleri biraz daha yüksektir, bu da bu modellerin daha az doğrulukla tahminlerde bulunduğunu göstermektedir. Sonuç olarak, Bagged Trees modelinin en düşük RMSE değerine sahip olduğu görülmektedir. Model sonuçları aşağıda tablo 3.17’de gösterilmiştir.

RMSE (Karekök Ortalama Kare Hata)	0.13119
R-Kare	0.31
MSE (Ortalama Kare Hata)	0.017211
MAE (Ortalama Mutlak Hata)	0.089906
Tahmin hızı	1900 gözlem/sn
Eğitim süresi	3.71 sn

Tablo 3. 17. Doğrusal Regresyon(Bagged Trees) Sonuçları


Tablo 3.17, doğrusal regresyon modelinin tahmin performansını ve yapılandırmasını detaylı bir şekilde özetleyen makine öğrenimi yazılım sonuçlarını içermektedir. Bu sonuçlar, eğitilmiş bir makine öğrenme modelinin performansını değerlendirirken kullanılan önemli metrikler üzerinde yoğunlaşmaktadır. Modelin RMSE, R-Kare, MSE ve MAE gibi temel performans ölçütleri incelenmiş ve modelin tahmin hızı ile eğitim süresi hakkında bilgi verilmiştir. Belirtilen RMSE değeri 0.13119, modelin tahminlerinin gerçek değerlerden ortalama olarak 0.131 birim sapma gösterdiğini ifade ederken, R-Kare değeri 0.31 olarak belirtilmiştir; bu da modelin bağımsız değişkenlerin %31'inin bağımlı değişkendeki varyansını açıkladığını göstermektedir. MSE değeri 0.017211 olarak belirlenmiş ve MAE değeri ise 0.089906 olarak kaydedilmiştir. Modelin tahmin hızı yaklaşık olarak 1900 gözlem/saniye olarak tahmin edilirken, eğitim süresi 3.71 saniye olarak hesaplanmıştır. Bu metrikler, modelin tahmin performansı, doğruluğu ve hesaplama hızı hakkında kapsamlı bir değerlendirme sunmakta ve modelin pratik uygulanabilirliği ve güvenilirliği hakkında önemli bir fikir vermektedir (Hastie vd., 2009).



Şekil 3. 28. Model Tahminleri Grafiği


Grafik, 2013-2023 yıllarını kapsayan geniş bir zaman diliminde gerçek hasta sayıları ile doğrusal regresyon modeli tarafından yapılan tahminler arasındaki karşılaştırmayı görsel olarak sunmaktadır. Grafikte, zamana bağlı olarak hastane acil servisine giriş yapan hasta sayıları, mavi noktalarla vurgulanmış ve her bir noktanın etrafında yer alan turuncu hata çubukları, verilerin belirsizlik aralığını yansıtmaktadır. Ayrıca, doğrusal regresyon modeli tarafından yapılan tahminlerin temsil edildiği turuncu noktalar, veri noktalarının genel eğilimini ve gelecekteki eğilimleri öngörme kabiliyetini göstermektedir. Bingöl Devlet Hastanesi'nin acil servisine ilişkin bu analiz, doğrusal regresyon modeli tarafından yapılan tahminlerin gerçek verilerle karşılaştırılması, modelin gelecekteki hasta sayılarını tahmin etme doğruluğunu değerlendirmek adına önemli bir referans noktası sunmaktadır.

Grafikteki mavi noktalar gerçek verileri veya hedef değerleri temsil ederken, sarı noktalar tahmin edilen veya model tarafından öngörülen değerleri temsil etmektedir. Bu grafikte, gerçek ve tahmin edilen değerlerin ne kadar yakın olduğunu görmek için mavi ve sarı noktalar arasındaki ilişkiye bakmak gerekir. Sarı noktaların mavi noktalara oldukça yakın olduğu görülmektedir, bu modelin gerçek verileri iyi tahmin ettiğini göstermektedir.



Şekil 3. 29. Dağılım Grafiği

Bu grafik, bir "gerçek değer" ve buna karşılık gelen "tahmin edilen değerler" arasındaki ilişkiyi göstermektedir. Bu grafikteki noktaların çoğu, yani tahmin edilen cevapların gerçek cevaplara yakın olduğu görülmektedir, bu modelin doğru tahminler yaptığı ve gerçek verilere iyi bir şekilde uyduğunu göstermektedir. Bu grafik, modelin tahmin performansını daha detaylı bir şekilde değerlendirmemize ve modelin ne kadar iyi çalıştığını anlamamıza yardımcı olabilmektedir. X eksenini, gerçek değerleri temsil ederken, y eksenini tahmin edilen değerleri göstermektedir. Bu durumda, düzenli olarak yükselen siyah çizgi, modelin gerçek verilere oldukça iyi uyduğunu ve tahminlerinin genel olarak doğru olduğunu göstermektedir. Bu, modelin tahmin gücünün yüksek olduğunu ve güvenilir tahminler sağladığını göstermektedir.



Şekil 3. 30. Değişim Oranları Grafiği

Şekil 3.30’da, çoğunlukla -0.2 ile 0.2 arasında y ekseninde dağılmış birçok turuncu noktadan oluşmaktadır, bu durum çoğu tahminin artıklarının bu aralıkta olduğunu göstermektedir. Ayrıca, $y=0$ noktasında mükemmel bir eşleşme sağlayacak olan yatay siyah bir çizgi bulunmaktadır, bu da tahmin edilen değerlerin gerçek değerlerle tam olarak eşleştiği noktayı temsil etmektedir ve artık hata olmadığını göstermektedir. Veri noktaları, grafiğin merkezi etrafında daha yoğun bir şekilde yer almaktadır, bu da gerçek yanıtın aralığın ortasında olduğunda kalıntıların daha küçük olduğunu göstermektedir. Sonuç olarak, modelin tahminlerinin oldukça doğru olduğunu gösteren bir desen vardır ve desende sistemli bir sapma gözlenmemektedir. Bu durum, modelin tahminlerinin genellikle doğru olduğunu ve hata dağılımının rastgele olduğunu göstermektedir. Aşağıdaki tabloda gerçek veriler ile tahmini verilerin detaylı karşılaştırması ve yorumlanması yapılmıştır.

Aylar	Veri	Tahmin	Aylar	Veri	Tahmin	Aylar	Veri	Tahmin
1	14460	13750	45	15904	16697	89	7824	8002
2	12123	14247	46	16523	16063	90	10740	12123
3	14189	12627	47	14753	15404	91	12191	13480
4	14047	15986	48	16203	16595	92	16845	14799
5	14557	12446	49	15828	16143	93	15320	14057
6	13557	13458	50	14355	15472	94	14709	15164
7	12272	13052	51	20775	18786	95	18305	14054
8	14064	13750	52	19508	19328	96	12584	14982
9	12367	12567	53	18961	18194	97	10310	10946
10	13353	13661	54	14453	15757	98	10881	11751
11	12610	13170	55	17088	17699	99	15221	16270
12	13218	13815	56	19043	17879	100	18431	16341
13	15909	15632	57	16816	17042	101	16310	17893
14	12171	13493	58	17234	16766	102	17613	17815
15	14613	14402	59	15127	15820	103	24370	22339
16	14221	13784	60	16345	16730	104	29383	24157

17	15171	15150	61	15850	17193	105	22405	21850
18	15703	15732	62	16238	16684	106	21464	21468
19	14178	14641	63	18853	17059	107	26400	22653
20	14974	14791	64	17229	17266	108	19427	20308
21	13642	14402	65	17236	17347	109	22706	19833
22	15522	15612	66	17345	17393	110	14450	16207
23	15497	15642	67	19219	21934	111	16695	16220
24	17248	16856	68	21526	17527	112	14246	15510
25	14974	15640	69	17681	18080	113	18552	17825
26	14241	15750	70	18025	18186	114	16871	17815
27	19257	17019	71	18416	18228	115	24498	21446
28	17682	16814	72	19152	18965	116	19815	19958
29	16132	15768	73	19899	18616	117	16162	17228
30	14310	15106	74	17060	18501	118	19525	19265
31	16266	15223	75	19606	19636	119	19754	20518
32	14067	17366	76	19094	18523	120	23288	20738
33	14034	15044	77	18298	19010	121	24281	20932
34	16288	12760	78	20092	19665	122	12948	15007
35	15888	16443	79	19308	19147	123	19040	18239
36	16435	16237	80	20406	19663	124	17889	18746
37	27632	21510	81	19226	19249	125	21063	20217
38	12696	13865	82	19048	18266	126	20536	20641
39	14587	15945	83	17683	18030	127	22643	21478
40	14223	15021	84	21689	20206	128	22007	21433
41	15283	16225	85	23875	18332	129	21191	20966
42	13262	14053	86	15958	17216	130	22298	20807
43	30698	19262	87	14226	15452	131	19441	21255

44	21235	22403	88	5704	6949	132	23026	20822
----	-------	-------	----	------	------	-----	-------	-------

Tablo 3. 18. Gerçek Veri Ve Tahmini Verilerin Karşılaştırılması

Tablo 3.18’de, 2013 yılından 1. aydan başlayarak 2023 yılı aralık ayına kadar toplamda 132 aylık dönemde Bingöl Devlet Hastanesine giriş yapan acil hasta sayılarının gerçek verileri ile makine öğrenmesi tabanlı doğrusal regresyonla tahmin edilen sonuçlar yer almaktadır. Ayrıca EK-3’te doğrusal regresyon oranları tablo halinde vermiştir. Veriler incelendiğinde, genel olarak gerçek ve tahmini değerler arasında bir uyum gözlemlenmektedir. Regresyon modeli, genellikle gerçek verilere oldukça yakın tahminler yapmıştır. Ancak bazı aylarda gerçek ve tahmini değerler arasında belirgin farklılıklar da gözlemlenmektedir. Bu durum, regresyon modelinin belirli dönemlerde daha az doğru tahminler yapabildiğini göstermektedir. Özellikle pandemi dönemi olarak kabul edilen ayları detaylı olarak incelediğimizde, 84. aydan sonra pandemi etkisiyle acil hasta sayılarında belirgin değişiklikler yaşandığı görülmektedir. Ancak genel olarak, modelin hastane acil servisine olan talebi doğru bir şekilde öngörebildiği ve gerçek verilere oldukça yakın tahminler yaptığı söylenebilmektedir. Bu verilerin analizi, hastane yöneticilerine gelecekteki hasta yükünü daha iyi planlama ve kaynakları etkin bir şekilde yönetme konusunda önemli bir rehberlik sağlayabilecektir. Regresyon modelinin başarısı ve doğruluğu, hastane acil servisinin verimliliğini artırmak için stratejik kararlar alınmasına yardımcı olabilecektir.

3.2.3.3. Tahmin Ölçeği Oranlarının Analizi

Tahmin ölçeği değerleri, bağımsız değişkenlerin tahmin edilen bağımlı değişken üzerindeki etkilerini veya regresyon katsayılarını ifade etmektedir. değerler normalize edilmiş ve 0 ile 1 arasındadır. Aşağıda tabloda değişkenlerin hasta sayılarına etkileri gösterilmiş ve yorumlanmıştır.

Tahmin Ölçeği Oranları	
Doktor Sayısı	0.2323357
Toplam Nüfus	0.345226
Erkek Nüfusu	0.3495335

Kadın Nüfusu	0.3313261
0-14 Yaş Nüfus	0.2648282
14-65 Yaş Nüfus	0.327459
65 Yaş Üstü Nüfus	0.3000647
Kişi Başına Gelir (Dolar)	0.3019443
Okuma Yazma Bilen Oranı (%)	0.3477666
UFE	0.2594181
TUFE	0.2793055
Kişi Başı Sağlık Harcaması (TL)	0.3372885
Kamu Sağlık Harcamaları (%)	0.2900802

Tablo 3. 19. Bağımsız Değişkenlerin Hasta Sayısına Etkisi

Bu tablo, doğrusal regresyon modelinin bağımsız değişkenlerinin tahmin edilen bağımlı değişken üzerindeki etkilerini veya katkılarını göstermektedir. Bu değerler, her bir bağımsız değişkenin, bağımlı değişkenin tahmininde ne kadar önemli olduğunu belirlemek için kullanılabilmektedir. Daha yüksek değerler, bağımsız değişkenin tahmin edilen bağımlı değişken üzerinde daha güçlü bir etkiye sahip olduğunu göstermektedir

Doktor Sayısı (0.2323357): Bu değişkenin bağımlı değişken üzerindeki etkisi nispeten düşüktür. Bu, doktor sayısındaki bir birimlik değişikliğin bağımlı değişkende nispeten küçük bir değişime neden olacağını göstermektedir.

Toplam Nüfus (0.345226): Toplam nüfusun bağımlı değişken üzerinde önemli bir etkisi vardır. Bu, nüfus arttıkça acil servis başvurularında anlamlı bir artış olabileceğini göstermektedir.

Erkek Nüfusu (0.3495335): Erkek nüfusunun etkisi yüksektir. Erkek nüfusundaki artışın, acil servis başvurularında önemli bir artışa neden olabileceği görülmektedir.

Kadın Nüfusu (0.3313261): Kadın nüfusunun da bağımlı değişken üzerinde önemli bir etkisi vardır. Kadın nüfusundaki artış da acil servis başvurularını önemli ölçüde etkileyebilme potansiyeli vardır.

0-14 Yaş Nüfus (0.2648282): Genç nüfusun etkisi orta düzeydedir. Bu yaş grubundaki değişiklikler, acil servis başvurularını belirli bir ölçüde etkileyebilecektir.

14-65 Yaş Nüfus (0.327459): Bu yaş grubunun etkisi önemlidir. Çalışma çağındaki nüfusun artışı, acil servis başvurularında belirgin bir artışa neden olacaktır.

65 Yaş Üstü Nüfus (0.3000647): Yaşlı nüfusun etkisi de önemli. Yaşlı nüfusun artışı, acil servis başvurularında anlamlı bir artışa neden olacaktır.

Kişi Başına Gelir (0.3019443): Kişi başına düşen gelir, acil servis başvuruları üzerinde orta düzeyde bir etkiye sahiptir. Gelir arttıkça, sağlık hizmetlerine erişim de artıracaktır.

Okuma Yazma Bilen Oranı (0.3477666): Eğitim düzeyinin etkisi yüksektir. Okuma yazma bilen oranının artması, sağlık hizmetlerine erişimi ve bilinçli sağlık davranışlarını artırarak acil servis başvurularını etkileyecektir.

Üretici Fiyat Endeksi (UFE) (0.2594181): ÜFE'nin etkisi orta düzeydedir. Ekonomik faktörler, sağlık hizmetlerine erişimi ve kullanımını etkileyecektir.

Tüketici Fiyat Endeksi (TUFİ) (0.2793055): TUFİ'nin etkisi de orta düzeyde. Tüketici fiyatlarındaki değişiklikler, insanların sağlık hizmetlerine erişim ve kullanımını etki edecektir.

Kişi Başı Sağlık Harcaması (0.3372885): Sağlık harcamalarının etkisi önemli. Buradaki artış, sağlık hizmetlerine erişimi ve kullanımını artıracaktır.

Kamu Sağlık Harcamaları (%) (0.2900802): Kamu sağlık harcamalarının etkisi orta düzeyde. Sağlık hizmetlerinin kalitesini ve erişimini artırarak acil servis başvurularını etkileyecektir.

Erkek nüfusu (0.3495335), okuma yazma bilen oranı (0.3477666), toplam nüfus (0.345226). Bu değişkenler, bağımlı değişken üzerinde en yüksek etkiye sahiptir. Doktor sayısı (0.2323357). Bu değişkenin bağımlı değişken üzerindeki etkisi diğerlerine göre daha düşüktür. 0-14 yaş nüfus, 65 yaş üstü nüfus, kişi başına gelir, ÜFE, TUFİ, kişi başına sağlık harcaması, kamu sağlık harcamaları. Bu değişkenlerin

etkileri, bağımlı değişken üzerinde orta düzeydedir. Bu sonuçlar, hastane yöneticileri ve sağlık planlamacıları için değerli bilgiler sunabilecektir. Örneğin, nüfustaki artışın acil servis başvurularını önemli ölçüde artırabileceği dikkate alınarak, nüfusa yönelik özel planlamalar yapılabilir. Aynı şekilde, okuma yazma oranının artmasının sağlık hizmetlerine olan talebi artırabileceği göz önünde bulundurularak, eğitim ve bilinçlendirme kampanyaları düzenlenebilir.

3.2.4.Yapay Sinir Ağlarıyla Tahmin

Bu bölümde, Bingöl Devlet Hastanesi acil servisine yönelik hasta sayılarını tahmin etmek için yapay sinir ağı (YSA) modeli kullanılacaktır. Sağlık hizmetlerinin etkin planlanması ve kaynakların verimli yönetilmesi için doğru tahminlerin önemi giderek artmaktadır. Bu bağlamda, zaman serisi verilerinin analizi ve YSA modellemesi, gelecekteki hasta sayılarını tahmin etmek için güçlü bir araç sunmaktadır. modelin kurulması, eğitilmesi ve doğrulanması süreçleri detaylı bir şekilde incelenerek, Bingöl Devlet Hastanesi acil servisi için sağlık hizmetleri yönetimine katkıda bulunması amaçlanmaktadır. EK-5’te yapay sinir ağıyla yapılan tahminlerin kodları gösterimiştir.

3.2.4.1. Yapay Sinir Ağları Tahmini: Eğitim, Doğrulama ve Test Oranlarının Analizi

Veri setini eğitim, doğrulama ve test veri setlerine bölerken belirli oranlar kullanılmıştır. Genellikle %70 eğitim, %15 doğrulama ve %15 test oranları tercih edilmektedir. Bu oranlar, modelin eğitim veri setinden öğrenmesini sağlamak, modelin genelleme yapabilme yeteneğini doğrulamak ve modelin performansını nesnel bir şekilde değerlendirmek için kullanılmıştır.

Eğitim verisi (%70): Bu, yapay sinir ağının eğitildiği veri setidir. Eğitim sürecinde kullanılan veri miktarı genellikle toplam verinin büyük bir bölümünü kapsar. Veri setinin %70'ini oluşturan 92 örnek (sample), ağın parametrelerini ayarlamak için kullanılmıştır. Bu, modelin veri setindeki desenleri öğrenmesini sağlamıştır. Eğitim veri setindeki her bir örnek, modelin girdi verileriyle ilgili hedef çıktı değerlerine karşılık gelmektedir. %70 oranında bölünmüş ve 92 örnek vardır, model toplamda 92 örnekle eğitilmiştir.

Doğrulama Verileri (%15): Bu, ağın eğitilirken performansını değerlendirmek için ayrılan veri setidir. Modelin eğitim sırasında aşırı uyum yapmamasını ve genelleme


yeteneğini korumasını sağlamaktadır. Yani, ağı sadece eğitim veri setine özgü örüntüleri öğrenmesini engeller. Veri setinin %15'ini oluşturan 20 örnek, eğitim sırasında ağı performansını izlemek ve eğitim sürecini durdurmak veya ayarlamak için kullanılmıştır. %15 oranında bölünmüş ve model toplamda 20 örnekle doğrulanmıştır.

Test Verileri (%15): Bu, eğitilen yapay sinir ağının performansını bağımsız bir şekilde değerlendirmek için ayrılan veri setidir. Modelin gerçek dünya verilerine ne kadar iyi genelleme yaptığını değerlendirmek için kullanılmaktadır. Modelin test veri setindeki performansı, modelin doğru tahminler yapma yeteneğini ölçmektedir. Test veri seti, modelin eğitim ve doğrulama aşamalarından bağımsız olarak kullanılmıştır. %15 oranında bölünmüş ve model toplamda 20 örnekle test edilmiştir.

Bu üç veri seti, yapay sinir ağının doğru bir şekilde eğitilmesi, değerlendirilmesi ve sonuçlarının doğrulanması için önemlidir. Eğitim veri seti modelin öğrenmesini sağlar, doğrulama veri seti ağı performansını izler ve test veri seti modelin gerçek dünya verilerine ne kadar iyi uyduğunu değerlendirir. Bu şekilde, modelin aşırı uyumundan kaçınarak genelleme yapma yeteneği sağlanmaktadır.

3.2.4.2. Yapay Sinir Ağı Yapısı: Girdi, Gizli Katman ve Çıkış Katmanı Şeması

Bu bölümde, yapay sinir ağlarının (YSA) yapısını gösteren şema incelenmiştir. Şemada, girdi katmanı, gizli katmanlar ve çıkış katmanı arasındaki ilişki ve bilgi akışı açıkça görülmektedir. Yapılan bu analiz, YSA'nın iç işleyişini anlamak için önemli bir araç sağlamaktadır. Aşağıda yapay sinir ağının şeması ve açıklaması detaylı şekilde incelenmiştir.



Şekil 3. 31. Yapay Sinir Ağı Mimari Şeması

Bu Yapay Sinir Ağı (YSA) şemasındaki sayılar, ağı mimarisini temsil etmektedir. Aşağıda YSA şemasındaki katmanları açıklanmıştır:

Input (Girdi) Katmanı: Ağın girdi katmanında 13 adet girdi değişkeni veya öznelik olduğunu belirtmektedir. Bu, ağa verilen her bir örnek için 13 özellik veya değişkenin kullanıldığını göstermektedir. Girdi katmanı, 13 bağımsız Değişikenden (doktor sayısı, il nüfusu, cinsiyet yapısı (erkek, kadın), genç nüfus sayısı, yetişkin nüfus sayısı, yaşlı nüfus sayısı, kişi başı gelir, okuma yazma oranları, ÜFE ve TÜFE, kişi başına düşen sağlık harcaması ve kamu sağlık harcaması oranı), 132 ay boyunca alınan verilerden oluşmaktadır. Her bir veri seti için birer öznelik olacak şekilde toplamda onüç öznelik (13 input) bulunmaktadır. Bu öznelikler, ağa girdi olarak verilmiş ve ağın eğitimi ve tahmini için kullanılmıştır.

Hidden (Gizli) Katman: Ağın gizli katmanında 10 adet nöron veya işlevsel birim bulunduğu belirtilmektedir. Gizli katman, girdi verilerini almakta ve ağın öğrenmesini gerçekleştiren karmaşık matematiksel işlemleri gerçekleştirmektedir. Her bir nöron, girdiler arasında belirli bir ağırlıklı toplamı ve bir aktivasyon fonksiyonunu hesaplamaktadır.

Output (Çıktı) Katmanı: Ağın çıktı katmanında yalnızca 1 adet çıktı değişkeni veya tahmin olduğu görülmektedir. Bu, ağın bir tahmin problemi üzerinde çalıştığını ve her bir örneğin sonucunun tek bir değer olarak tahmin edilmeye çalışıldığını göstermektedir. Çıktı olarak acil birimine başvuru yapan toplam hasta sayıları tahmin edilmiştir.

YSA, eğitim verileri üzerindeki hataları en aza indirerek ve veriler arasındaki gizli ilişkileri öğrenerek tahminlerde bulunmuştur. 132 ay boyunca doktor sayısı, il nüfusu, cinsiyet yapısı(Erkek Kadın), genç nüfus sayısı, yetişkin nüfus sayısı, yaşlı nüfus sayısı, kişi başı gelir, okuma yazma oranları, ÜFE ve TÜFE, kişi başına düşen sağlık harcaması ve kamu sağlık harcaması oranı gibi 13 farklı öznelikten oluşan girdi verileri alınmıştır. Eğitim süreci tamamlandıktan sonra, modelin doğruluğunu değerlendirmek ve tahmin yapmak için test verileri kullanılmıştır.

3.2.4.3. Yapay Sinir Ağı Eğitimi ve Değerlendirmesi

Bu bölümde, yapay sinir ağı (YSA) eğitimi ve sonuçları incelenmiştir. Eğitim sürecinde Levenberg-Marquardt algoritması kullanılmış ve eğitim, doğrulama ve test sonuçları sunulmuştur. Bu aşamada kullanılacak algoritma belirlenmiştir. Bu algoritma, ağın parametrelerini (ağırlıklar ve eşik değerleri) ayarlayarak, veri setine en

iyi uyum sağlayacak şekilde eğitilmesini sağlamaktadır. LM algoritması, genellikle regresyon problemleri gibi YSA'nın regresyon işlevlerinde kullanılmaktadır.

Bu yöntem, her adımda hatayı azaltmak için ağıın parametrelerini ayarlamaktadır. Her adımda, hatanın azaltılması için parametrelerin nasıl güncelleneceğini belirlemek için hesaplamalar yapmaktadır. Eğitim süreci sırasında, LM algoritması veri setine göre ağıın çıktıları ve gerçek değerlerini karşılaştırarak bir hata hesaplar. Ardından, bu hatayı azaltmak için ağıın parametrelerini güncellemek için kullanılır. Bu işlem, tüm eğitim veri seti üzerinde tekrarlanır ve ağıın hatası en aza indirilmeye çalışılır. Bu sayede, Yapay Sinir Ağı'nın verilere daha iyi uyum sağlaması ve daha doğru tahminler yapması hedeflenir. Bu sonuçların detaylı açıklaması aşağıda verilmiştir:

- Eğitim veri setindeki örnek sayısı 92'dir ve Ortalama Kare Hatası (Mean Squared Error, MSE) değeri 0.0139472 'dir.

MSE, bir modelin gerçek değerlerle tahmin ettiği değerler arasındaki ortalama kare farkıdır. Bu durumda, 92 örneğin tahmin edilen değerleri ile gerçek değerleri arasındaki ortalama kare farkı 0.0139472 olarak hesaplanmıştır. Düşük MSE değerleri, modelin verilere daha iyi uyum sağladığını ve daha doğru tahminler yaptığını göstermektedir. Bu durumda, 0.0139472 gibi düşük bir MSE değeri, veri setinde iyi performans gösterdiğini ve verilere uyum sağladığını göstermektedir. Bu nedenle, eğitim veri setindeki 92 örnekle elde edilen MSE değeri, modelin başarılı bir şekilde eğitildiğini ve verilere uyum sağladığını göstermektedir.

- Doğrulama veri setindeki örnek sayısı 20'dir ve Ortalama Kare Hatası (Mean Squared Error, MSE) değeri 0.012721'dir.

20 örneğin tahmin edilen değerleri ile gerçek değerleri arasındaki ortalama kare farkı 0.012721 olarak hesaplanmıştır. Bu MSE değeri, modelin bu veri setindeki performansını göstermektedir. Daha yüksek bir MSE değeri, modelin veri setinde gerçek değerlere daha az uyum sağladığını ve daha büyük hatalar yaptığını göstermektedir.

- Test veri setindeki örnek sayısı 20'dir ve Ortalama Kare Hatası (Mean Squared Error, MSE) değeri 0.0110814'tür.

20 örneğin tahmin edilen değerleri ile gerçek değerleri arasındaki ortalama kare farkı 0.0110814 olarak hesaplanmıştır. Test veri setinde elde edilen bu MSE değeri, modelin Test veri setindeki performansını göstermektedir. Bu durumda, böyle bir MSE değeri, modelin Test veri setinde iyi bir performans sergilediğini ve verilere iyi uyum sağladığını göstermektedir.

Bu sonuçlar, yapay sinir ağının eğitim, doğrulama ve test aşamalarında genel performansını göstermektedir. Düşük MSE değerleri ve yüksek korelasyon katsayıları, modelin verilere iyi uyduğunu ve iyi tahminler yaptığını göstermektedir. Bu sonuçlara göre, yapay sinir ağının tahmin performansı oldukça iyidir. Ortalama Kare Hatası (MSE) değerlerinin düşük olması, modelin gerçek verilerle yaptığı tahminlerin genellikle doğru olduğunu gösterir. Özetle, düşük MSE değerleri ve yüksek korelasyon katsayıları, yapay sinir ağının acil birimine başvuran hasta sayılarını tahmin etmede başarılı olduğunu göstermektedir (Goodfellow vd., 2016).

3.2.4.4. Yapay Sinir Ağı Eğitimi: Nntool Sonuçları ve Analizi

Bu bölümde, nntool aracı kullanılarak gerçekleştirilen YSA eğitimi incelenmiştir. Nntool tarafından sağlanan sonuçlar ve analizler, YSA'nın eğitim sürecinin derinlemesine incelenmesine olanak tanımaktadır. Burada YSA sonuçlarının genel performans penceresi incelenmektedir. Aşağıda penceredeki tüm kavram ve sonuçların açıklaması yapılmıştır.

Data Division (Veri Bölümleme): Bu bölüm, veri setinin eğitim, doğrulama ve test verisi olarak nasıl bölüneceğini belirtmektedir. Burada veri setinin %70'i eğitim, %15'i doğrulama ve %15'i test için ayrılmıştır.

Training Algorithm (Eğitim Algoritması): Yapay sinir ağının eğitilmesi için kullanılan algoritmayı belirtmektedir. Levenberg-Marquardt algoritması belirlenmiştir.

Performance Function (Performans Fonksiyonu): Eğitim sırasında modelin performansını ölçmek için kullanılan ölçütü belirtir. MSE (ortalama kare hatası), gerçek ve tahmini değerler arasındaki farkların karesinin ortalama değeridir.

Calculations (Hesaplamalar): Eğitim sırasında hangi hesaplama yönteminin kullanılacağını belirtir. "MEX", MATLAB diliyle yazılmış C/C++ veya Fortran dilindeki hesaplama rutinlerinin MEX dosyaları kullanılacağını belirtir. Bu, eğitimin daha hızlı ve verimli olmasını sağlamaktadır.

Epoch (Dönem): Bir eğitim döngüsünün bir adımıdır. Yapay sinir ağları, veri setini birçok kez geçerek eğitir. Her geçiş bir dönem olarak adlandırılır.

Iterations (İterasyonlar): Bir dönem boyunca yapılan güncelleme adımlarının toplam sayısıdır. Her iterasyon, ağırlıkların ve sapmaların güncellemek için gerçekleştirilen bir geriye yayılım adımını temsil etmektedir.


Time (Zaman): Belirli bir dönemdeki veya iterasyondaki eğitim zamanını ifade eder. Genellikle saniye cinsinden ölçülür.

Performance (Performans): Eğitim sürecinin o anki performansını ifade eder. Performans fonksiyonuna (genellikle MSE'ye) dayanarak belirlenir. MSE ne kadar düşükse, performans o kadar iyidir.

Bu ayarlar, yapay sinir ağının nasıl eğitileceğini, performansının nasıl ölçüleceğini ve hesaplamaların nasıl yapılacağını belirlemektedir. Bu seçeneklerin doğru bir şekilde ayarlanması, modelin iyi bir şekilde eğitilmesini ve doğru bir şekilde performansının değerlendirilmesini sağlamaktadır.

3.2.4.5. Yapay Sinir Ağı Eğitim Performansı Grafiği: En İyi Doğrulama Sonucu

Bu bölümde, yapay sinir ağı (YSA) eğitim sürecinin performansını gösteren grafik incelenmiştir. Grafik, eğitim sürecinin her bir epoch'taki ortalama kare hatası (MSE) değerlerini göstermektedir. En iyi doğrulama performansı, 3. epoch'ta 0.012172 MSE değeri ile elde edilmiştir. Aşağıdaki şekilde en iyi performans doğrulaması grafiği ve açıklaması verilmiştir.




Şekil 3. 32. MSE Performansı Grafiği

Bu grafik, eğitim sürecinde yapılan iterasyonların sayısına (epoch) karşı Ortalama Kare Hatası (Mean Squared Error - MSE) değerini göstermektedir. X ekseninde iterasyon sayısı (epoch) ve Y ekseninde MSE değeri yer almaktadır. MSE, modelin gerçek değerlerle tahmin ettiği değerler arasındaki ortalama karesel farkı ölçmektedir. Bu grafikte, eğitim iterasyonlarına bağlı olarak MSE değerinde bir azalma olup olmadığına bakılmaktadır. İdeal durumda, eğitim iterasyonları arttıkça MSE değeri de azalmalıdır, yani model gerçek değerlere daha yakın tahminler yapmalıdır. Eğitim sürecinin başından itibaren, bu üç veri seti için MSE değerleri azalır mı yoksa artar mı, hangi veri setinin model için daha iyi performans gösterdiğini değerlendirmek için bu çizgilerin takip edilmesi gerekir. Bu grafikte, eğitim ve doğrulama veri setlerinde MSE değerlerinin azaldığı, ancak test veri setinde MSE'nin arttığı bir durumu gözlemlemek, modelin aşırı uyum (overfitting) yaşadığını veya başka bir deyişle eğitim verilerine aşırı uyum sağladığını göstermektedir.

3.2.4.6. Yapay Sinir Ağı Eğitiminde Eğim, Momentum ve Doğrulama Analizi

Bu bölümde, yapay sinir ağı (YSA) eğitimi sırasında eğim, momentum (MU) ve doğrulama kontrolü incelenmiştir. Grafik, eğitim sürecinin her bir epoch'taki eğim değişimini, momentumun etkisini (MU değeri) ve doğrulama kontrollerinin sonuçlarını göstermektedir. Aşağıda grafik ve sonuçları değerlendirilmiştir.



Şekil 3. 33. Eğim, Momentum ve Doğrulama Kontrolü Analizi Grafiği


Grafik, modelin eğim ve Mu performansının iyileştiğini gösterirken, doğrulama hatasının nispeten sabit kaldığını ve modelin aşırı uyum yapmadığını işaret etmektedir. Eğimin zamanla azalması, modelin eğitiminin giderek stabilize olduğunu ve belirli bir minimuma doğru ilerlediğini gösterir. Bu durum, eğitim sürecinin istikrarlı bir şekilde ilerlediğini ve modelin optimize edildiğini işaret etmektedir. Bu değer, eğitim sırasında ağıın ne kadar hızlı öğrendiğini ve ne kadar iyi optimize edildiğini belirlemeye yardımcı olmaktadır.

Mu, genellikle momentum terimi olarak bilinen bir hiperparametredir ve eğim, güncellemelerini hızlandırmaya veya yavaşlatmaya yardımcı olmaktadır. Mu değerinin 0.0001 olarak belirlenmiş olması, momentum teriminin büyüklüğünü gösterir. 0 ile 1 arasındaki bu değer, momentumun ne kadar etkili olduğunu belirler. Düşük bir değer momentumun etkisini azaltırken, yüksek bir değer momentumun etkisini artırır.

Doğrulama kontrolü, modelin doğrulama (validation) kontrolleri durumunu ve başarısını değerlendirmek için kullanılan bir metriktir. Grafikte, epoch 0'dan başlayarak, modelin doğrulama kontrollerinde başarısızlık oranı neredeyse sıfıra yakın olarak başlamaktadır. Bu, modelin eğitim sürecinin başlangıcında doğrulama kontrollerini başarılı bir şekilde geçtiğini göstermektedir. Grafik modelin doğrulama kontrollerindeki başarısını ve istikrarını göstermektedir.

3.2.4.7. Yapay Sinir Ağı Hata Dağılımı Analizi

Bu bölümde, yapay sinir ağlarının (YSA) hata dağılımı analizi incelenmiştir. Grafik, hata dağılımının histogramını göstermektedir. X eksen, hataları temsil ederken, Y eksen ise bu hataların oluştuğu örneklerin sayısını göstermektedir.




Şekil 3. 34. Hata Dağılımı Histogram Grafiği

Bu grafik, bir hata histogramıdır ve hata dağılımını göstermek için kullanılır. X ekseninde hataların büyüklüğü gösterilirken, Y ekseninde bu hataların ne kadar sıklıkla meydana geldiği ya da kaç örnek tarafından yapıldığı gösterilir. Renkler eğitim, doğrulama ve test veri setlerini temsil eder. Hata histogramı, modelin hangi bölgelerde daha iyi veya daha kötü performans gösterdiğini görsel olarak göstermektedir. Histogramda hataların büyük bir kısmı sıfıra yakındır ve bu modelin genellikle doğru tahminler yaptığı anlamına gelmektedir. Ayrıca, modelin veriye ne kadar iyi uyum sağladığını anlamak ve modelin tahminlerini güvenilirliğini değerlendirmek için de kullanılabilir. X eksen, tahmin edilen (outputs) değerler ile gerçek (targets) değerler arasındaki farkı temsil etmektedir. Negatif değerler, tahminin gerçek değerden düşük olduğunu gösterirken, pozitif değerler tahminin gerçek değerden yüksek olduğunu gösterir. Bu değerler, hataların büyüklüğünü ve yönünü gösterir.

3.2.4.8. Doğrusal Regresyon Modelinin Performans Analizi

Bu bölümde, bir doğrusal regresyon modelinin performansını değerlendirmek için yapılan analiz incelenmiştir. Grafiklerde, modelin gerçek ve tahmin edilen

değerleri karşılaştıran hedef ve çıktı grafiği ile bu modelin eğitim, doğrulama ve test setlerindeki performansını gösteren grafikler bulunmaktadır. Aşağıda, grafiklerin açıklamalarıyla birlikte modelin performansı detaylı bir şekilde incelenmiştir.



Şekil 3. 35. Doğrusal Regresyon Modelinin Performans Analizi Grafikleri

Bu grafikte modelin gerçek değerlerle ne kadar iyi eşleştiğini ve tahminlerinin doğruluğunu görmek için hedef (target) ve çıktı (output) değerleri karşılaştırılmıştır. X eksen, gerçek hedef değerlerini temsil ederken, Y eksen, modelin tahmin ettiği değerlerin bir fonksiyonunu temsil etmektedir. Burada, modelin tahmin ettiği değerlerin hedef değerlere ne kadar yakın olduğunu görmek için bir doğrusal fit çizilmiştir. Fit çizgisi, modelin gerçek değerleri ne kadar iyi takip ettiğini göstermektedir.

Grafikteki daire şeklindeki noktalar, her bir veri noktasını temsil etmektedir. Bu noktaların fit çizgisinin yakınında ve düzgün bir şekilde dağılması bu modelin iyi bir uyum sağladığı ve doğru tahminler yaptığı anlamına gelmektedir. "Y=T" çizgisi, ideal durumu temsil etmekte ve modelin tahminlerinin bu çizgiye yakın olması, modelin gerçek değerlerle uyumlu olduğunu göstermektedir. Fit çizgisi gerçek değerleri iyi takip etmiş ve noktalar fit çizgisinin etrafında homojen bir şekilde dağılmıştır, bu da modelin iyi bir performans gösterdiğini açıklamaktadır.

Eğitim grafiği, modelin doğrusal ilişkiyi ne kadar güçlü bir şekilde takip ettiğini gösterir. Eğer katsayı çok küçükse (örneğin, 0.0021 gibi), hedef değişkenin doğrudan etkisi daha azdır ve modelin çıktısı hedef değişkene daha az duyarlıdır.

Doğrulama grafiği, doğrusal bir regresyon modelinin validasyon (doğrulama) seti üzerindeki performansını göstermektedir. Burada, hedef (target) değerler ile modelin tahmin ettiği çıktı (output) değerleri karşılaştırılmıştır. X eksen, gerçek hedef değerlerini temsil ederken, Y eksen, modelin tahmin ettiği değerlerin bir fonksiyonunu temsil etmektedir. Noktalar çizgiye yakın ve düzgün bir şekilde dağılmıştır, bundan dolayı model doğrulama setinde iyi bir performans sergilemiş ve doğru tahminler yapmıştır. Test hedef grafiğinde Çizgi, doğrusal regresyon modelini temsil etmektedir. Model, hedef değişken ile çıktı arasındaki ilişkiyi doğrusal olarak tahmin etmektedir. Grafikteki amaç, modelin gerçek veriye ne kadar iyi uyum sağladığını ve tahminlerinin ne kadar doğru olduğunu değerlendirmektir.

3.2.4.9. Yapay Sinir Ağı Test Sonuçlarının Değerlendirilmesi

Bu bölümde, eğitilmiş yapay sinir ağının test veri seti üzerindeki performansını değerlendirmek için kullanılan MSE (Ortalama Kare Hatası) ve RMSE (Root Mean Square Error) metrikleri incelenmiştir.

Aylar	Hasta S.	Hata O.	Fark	Tahmin	Aylar	Hasta S.	Hata O.	Fark	Tahmin
1	14460	0.1122209	1622.714	12837.29	67	19219	0.019755	379.679	18839.32
2	12123	0.0322049	390.4202	11732.58	68	21526	0.099417	2140.046	19385.95
3	14189	0.119863	1700.736	12488.26	69	17681	-0.0775	-1370.22	19051.22
4	14047	0.0172302	242.0322	13804.97	70	18025	-0.01123	-202.436	18227.44
5	14557	0.0350225	509.8227	14047.18	71	18416	-0.01115	-205.37	18621.37
6	13557	-0.0022373	-30.3305	13587.33	72	19152	-0.03055	-585.002	19737
7	12272	-0.0529328	-649.592	12921.59	73	19899	-0.02911	-579.186	20478.19
8	14064	0.0476072	669.5474	13394.45	74	17060	-0.15893	-2711.42	19771.42
9	12367	-0.0539578	-667.297	13034.3	75	19606	-0.0472	-925.465	20531.47
10	13353	0.0382167	510.3071	12842.69	76	19094	-0.06189	-1181.65	20275.65
11	12610	-0.0342258	-431.588	13041.59	77	18298	-0.09314	-1704.33	20002.33
12	13218	0.0622113	822.309	12395.69	78	20092	-0.06549	-1315.92	21407.92
13	15909	0.0767913	1221.673	14687.33	79	19308	-0.07535	-1454.84	20762.84
14	12171	-0.0916041	-1114.91	13285.91	80	20406	-0.04612	-941.192	21347.19
15	14613	0.0095909	140.152	14472.85	81	19226	-0.07134	-1371.63	20597.63

16	14221	-0.0261904	-372.454	14593.45	82	19048	0.086486	1647.384	17400.62
17	15171	0.0178101	270.1973	14900.8	83	17683	0.043668	772.1827	16910.82
18	15703	0.0458767	720.4023	14982.6	84	21689	0.12209	2648.01	19040.99
19	14178	-0.0069542	-98.5964	14276.6	85	23875	0.292235	6977.117	16897.88
20	14974	0.060645	908.0986	14065.9	86	15958	0.014822	236.53	15721.47
21	13642	0.0058078	79.22942	13562.77	87	14226	-0.15689	-2231.94	16457.94
22	15522	0.0530439	823.3475	14698.65	88	5704	-0.24273	-1384.52	7088.515
23	15497	0.0288682	447.3712	15049.63	89	7824	-0.15821	-1237.84	9061.841
24	17248	0.1016964	1754.06	15493.94	90	10740	-0.15304	-1643.62	12383.62
25	14974	0.0111081	166.3331	14807.67	91	12191	-0.00945	-115.221	12306.22
26	14241	-0.0346812	-493.896	14734.9	92	16845	0.256708	4324.25	12520.75
27	19257	0.1570695	3024.687	16232.31	93	15320	0.111573	1709.305	13610.7
28	17682	0.0987386	1745.897	15936.1	94	14709	0.156633	2303.919	12405.08
29	16132	0.0175476	283.0785	15848.92	95	18305	0.160677	2941.194	15363.81
30	14310	-0.064875	-928.361	15238.36	96	12584	-0.0686	-863.26	13447.26
31	16266	0.0218161	354.8599	15911.14	97	10310	-0.16124	-1662.41	11972.41
32	14067	-0.0898485	-1263.9	15330.9	98	10881	-0.1706	-1856.34	12737.34
33	14034	-0.0981507	-1377.45	15411.45	99	15221	-0.13194	-2008.2	17229.2
34	16288	-0.0087766	-142.954	16430.95	100	18431	0.044613	822.269	17608.73
35	15888	-0.0461689	-733.531	16621.53	101	16310	-0.07998	-1304.49	17614.49
36	16435	-0.0390138	-641.192	17076.19	102	17613	-0.071	-1250.45	18863.45
37	27632	0.3602859	9955.419	17676.58	103	24370	0.132202	3221.764	21148.24
38	12696	-0.2463877	-3128.14	15824.14	104	29383	0.264219	7763.555	21619.44
39	14587	-0.1436533	-2095.47	16682.47	105	22405	0.056726	1270.945	21134.05
40	14223	-0.1917648	-2727.47	16950.47	106	21464	0.027848	597.7379	20866.26
41	15283	-0.0700201	-1070.12	16353.12	107	26400	0.171837	4536.489	21863.51
42	13262	-0.0381619	-506.104	13768.1	108	19427	-0.16635	-3231.64	22658.64
43	30698	0.4930104	15134.43	15563.57	109	22706	0.222463	5051.255	17654.75
44	21235	0.0905782	1923.429	19311.57	110	14450	-0.10321	-1491.35	15941.35

45	15904	-0.0938564	-1492.69	17396.69	111	16695	-0.01019	-170.045	16865.05
46	16523	-0.0338354	-559.063	17082.06	112	14246	-0.11983	-1707.11	15953.11
47	14753	-0.0939993	-1386.77	16139.77	113	18552	0.033131	614.6552	17937.34
48	16203	-0.0451122	-730.953	16933.95	114	16871	-0.08451	-1425.82	18296.82
49	15828	-0.0812353	-1285.79	17113.79	115	24498	0.188707	4622.945	19875.06
50	14355	-0.1364288	-1958.44	16313.44	116	19815	-0.00541	-107.197	19922.2
51	20775	0.1221866	2538.426	18236.57	117	16162	-0.12674	-2048.44	18210.44
52	19508	0.07164	1397.554	18110.45	118	19525	-0.00687	-134.146	19659.15
53	18961	0.0505263	958.0287	18002.97	119	19754	0.037253	735.8879	19018.11
54	14453	-0.1299336	-1877.93	16330.93	120	23288	0.19664	4579.359	18708.64
55	17088	-0.0166981	-285.337	17373.34	121	24281	0.177177	4302.046	19978.95
56	19043	0.0600365	1143.275	17899.72	122	12948	-0.27231	-3525.93	16473.93
57	16816	-0.0057027	-95.8974	16911.9	123	19040	-0.04582	-872.428	19912.43
58	17234	0.0152183	262.2728	16971.73	124	17889	-0.10223	-1828.78	19717.78
59	15127	-0.0598337	-905.104	16032.1	125	21063	0.017183	361.9217	20701.08
60	16345	-0.0226161	-369.66	16714.66	126	20536	-0.03814	-783.205	21319.2
61	15850	-0.0461729	-731.841	16581.84	127	22643	0.051002	1154.84	21488.16
62	16238	-0.0273571	-444.225	16682.22	128	22007	0.003261	71.77555	21935.22
63	18853	0.0497396	937.7405	17915.26	129	21191	-0.01389	-294.27	21485.27
64	17229	-0.0213119	-367.183	17596.18	130	22298	-0.00511	-113.912	22411.91
65	17236	-0.0422529	-728.27	17964.27	131	19441	-0.11641	-2263.17	21704.17
66	17345	-0.0498389	-864.456	18209.46	132	23026	0.034936	804.4453	22221.55

Tablo 3. 20. Yapay Sinir Ağı Tahmin Sonuçları

Sonuçlara göre YSA'nın oldukça başarılı bir şekilde tahminler yaptığı görülmektedir. MSE değerinin düşük olması, ağın test veri setindeki tahminlerinin gerçek değerlerle olan ortalama kare hatasının çok küçük olduğunu göstermektedir. Bu, ağın genellikle tahminlerinin gerçek değerlere yakın olduğunu ve modelin test veri setindeki verileri iyi bir şekilde genelleştirdiğini göstermektedir. Ortalama kare hatası(MSE), ağın test veri setindeki tahminlerinin gerçek değerlerden ne kadar uzak

olduğunu ölçer. Daha düşük MSE değeri, ağı test veri setindeki daha iyi bir performans gösterdiğini gösterir. MSE değeri ortalama kare hatası (0.012172) oldukça düşüktür, bu da modelin test veri setinde iyi bir şekilde genelleme yaptığını göstermektedir. RMSE (Karekök Ortalama Kare Hatası) değeri (0.1104) olarak hesaplanmıştır. bu değer, modelin tahminlerinin genellikle 0.1104 birimlik hata ile gerçek değerlerden farklılık gösterdiğini gösterir. Sonuç olarak, düşük MSE ve RMSE değerleri, modelin test veri setinde başarılı bir şekilde genelleme yaptığını ve tahminlerinin gerçek verilere yakın olduğunu göstermektedir.

Özellikler	Doğrusal Regresyon	Yapay Sinir Ağı (YSA)
MSE (Ortalama Kare Hata)	0.017211	0.012172
RMSE (Karekök Ortalama Kare Hata)	0.13119	0.11040

Tablo 3. 21. Tahmin Modelleri Sonuçlarının Karşılaştırılması

Yapay sinir ağı modeli, hem MSE hem de RMSE değerleri açısından doğrusal regresyon modelinden daha düşük hata oranlarına sahiptir. Bu, YSA modelinin tahminlerinin genellikle daha doğru ve gerçek verilere daha yakın olduğunu göstermektedir. Bundan dolayı 2024-2025 yılı tahminleri YSA modeliyle aşağıdaki tabloda tahmin edilmiştir.

Aylar	Tahmin	Aylar	Tahmin	Aylar	Tahmin	Aylar	Tahmin
2024-07	22873	2024-12	19875	2025-05	19160	2025-10	23020
2024-08	23244	2025-01	20876	2025-06	20340	2025-11	18350
2024-09	21350	2025-02	17540	2025-07	22080	2025-12	21678
2024-10	22677	2025-03	18654	2025-08	22754		
2024-11	17690	2025-04	17302	2025-09	19730		

Tablo 3. 22. 2024-2025 Yılı Tahmini Hasta sayıları

Eğitilmiş yapay sinir ağının test veri seti üzerindeki performansı, MSE (Ortalama Kare Hatası) ve RMSE (Karekök Ortalama Kare Hatası) metrikleri ile değerlendirilmiştir. Test sonuçları, ağın tahminlerinin genellikle gerçek değerlerle

yüksek bir doğruluk oranına sahip olduğunu göstermektedir. MSE değeri 0.012172, RMSE değeri ise 0.1104 olarak hesaplanmıştır; bu düşük değerler modelin test veri setindeki performansının başarılı olduğunu ve tahminlerin gerçek verilere yakın olduğunu ifade etmektedir. Özellikle MSE ve RMSE değerlerinin düşük olması, modelin test veri setinde iyi bir genelleme sağladığını ve tahminlerinin gerçek verilere yakın olduğunu ortaya koymaktadır. Ayrıca, yapay sinir ağı modelinin doğrusal regresyon modeline göre daha iyi performans gösterdiği, MSE ve RMSE değerlerinin daha düşük olduğu görülmektedir. Bu sonuçlar, YSA modelinin tahminlerinin daha doğru olduğunu ve sağlık hizmetleri planlaması ve kaynak tahsisi gibi stratejik kararlar için etkili bir araç olduğunu doğrulamaktadır. YSA'nın sağladığı tahminler, gelecekteki hasta sayılarını öngörmede ve hastane kapasitesini planlamada değerli bilgiler sunmaktadır. 2024 yılı için yapılan hasta sayısı tahminleri, belirli aylar için Yapay Sinir Ağı (YSA) modeli kullanılarak hesaplanmıştır. Tahminler, geçmiş verilerin analiz edilmesi ve modelin eğitilmesi sonucunda elde edilmiştir.

SONUÇ VE ÖNERİLER

Öncelikle, çalışmanın konusu olan hastane acil servis hasta sayılarını tahminleme oldukça önemli bir sağlık yönetimi problemidir. Acil servislerdeki hasta akışını doğru bir şekilde tahmin etmek, hastaların hızlı bir şekilde müdahale edilmesini sağlamak, kaynakların etkili bir biçimde yönetilmesini mümkün kılabilir. Bu, hastaların bekleme sürelerini azaltabilir, sağlık personelinin daha etkili bir biçimde çalışmasını sağlayabilir ve acil durumlar için gereken kaynakları daha doğru bir şekilde tahsis edebilir. Çalışmada kullanılan metodoloji, yapay sinir ağı (YSA) gibi derin öğrenme tekniklerini içermektedir. Bu, çalışmanın yenilikçi ve güçlü bir analiz yöntemi seçtiğini göstermektedir. Sonuç olarak, bu çalışma sağlık sektöründe yapay zeka tekniklerinin kullanımının bir örneğini sunmaktadır. Bu tür çalışmalar, sağlık hizmetlerini daha etkili, erişilebilir ve verimli hale getirebilme potansiyeline sahiptir. Ayrıca, bu çalışmanın sonuçları, gelecekteki benzer çalışmaların ve araştırmaların temelini oluşturabilme ve sağlık yönetimi alanında daha fazla inovasyona katkıda bulunabilme özelliğine sahiptir.

Yapay sinir ağlarının diğer tahmin yöntemlerine göre daha doğru ve güvenilir sonuçlar sunduğu ve zaman serisi analizlerinde etkili olduğu görülmüştür. Bu teknikler, gelecekteki talepleri öngörmede, stok yönetiminde ve operasyonel planlamada kullanılarak örgütlerin daha etkili ve verimli olmasını sağlayabileceklerdir. Çalışma, sağlık sektöründe yapay zeka tekniklerinin kullanımını gösteren önemli bir çalışmadır. Bu çalışma, hastane acil servislerindeki hasta akışını tahmin etmek amacıyla yapay sinir ağı (YSA) ve derin öğrenme tekniklerini kullanmaktadır. Çalışmada, kullanılan metodoloji, zaman serisi yöntemlerinin, doğrusal regresyon yönteminin ve yapay sinir ağı tekniğinin kullanılmasıyla güçlü hale getirilmeye çalışılmıştır. Çalışmada, hastane acil servis tahminleme problemini ele almak için doğru bir yaklaşım seçilmeye çalışılmıştır. Çalışmada kullanılan verilerin doğru ve güvenilir olmasına dikkat edilmiştir. Veri ön işleme adımları, veriyi temizlemek, dengesizlikleri düzeltmek ve gereksiz gürültüyü filtrelemek gibi işlemleri içermektedir. Bununla, tahminlerin doğruluğu ve güvenilirliği arttırılmak istenmiştir. Doğru acil servis tahminleri, hastaların bekleme sürelerini azaltabilecek ve sağlık personelinin kaynaklarını daha etkili bir şekilde yönlendirmesine yardımcı olabilecektir.

Çalışmada, öncelikle Bingöl Devlet Hastanesi'ne 2013-2023 yılları arasında acil servis başvurularının zaman serisi analizi yapılmıştır. AR, MA ve ARMA modelleri kullanılarak yapılan analizler sonucunda, AR(1) ve MA(1) modellerinin veriye iyi uyum sağladığı ve istatistiksel olarak anlamlı olduğu görülmüştür. ARMA(1,1) modeli de genel performans açısından yüksek başarı göstermiştir. ARIMA ve SARIMA modelleri ise daha kompleks yapıları ile öne çıkmış, SARIMA(1,1,1) modelinin en yüksek performansa sahip olduğu belirlenmiştir. Bu model, düşük AIC ve BIC değerleri ile tüm parametrelerinin anlamlı olması nedeniyle acil servis başvurularının tahmininde en güvenilir model olarak öne çıkmıştır.

Sonrasında Bingöl Devlet Hastanesi acil servisine gelen hasta sayılarının tahmini doğrusal regresyon modelinin, makine öğrenimi algoritmaları kullanılmış ve performansları karşılaştırılmıştır. Elde edilen sonuçlara göre, Bagged Trees modeli, 0.13119 RMSE değeri ile en iyi performansı sergilemiştir. Bu modelin tahminlerinin, gerçek değerlerle yüksek düzeyde uyum gösterdiği ortaya çıkmıştır. Ayrıca, doğrusal regresyon modelinin 0.31 R-kare değeri ile bağımsız değişkenlerin %31'ini açıkladığı belirlenmiştir. Gerçek ve tahmini değerler arasındaki karşılaştırmada, genel olarak verilerin yakın olduğu görülmektedir. Pandemi döneminde, tahminlerin doğruluğunda belirgin sapmalar gözlenmiş olsada genel olarak, analizler ve kullanılan modeller, hastane yöneticilerine gelecekteki hasta sayısını tahmin etmede ve kaynak yönetimini daha etkin bir şekilde planlamada önemli rehberlik sağlayabilme potansiyeline sahiptir.

Son olarak, Bingöl Devlet Hastanesi acil servis hasta sayılarının tahmin edilmesi amacıyla Yapay Sinir Ağı (YSA) modeli kullanılmış ve modelin performansı MSE (Ortalama Kare Hatası) ve RMSE (Karekök Ortalama Kare Hatası) metrikleri ile değerlendirilmiştir. Elde edilen düşük MSE (0.012172) ve RMSE (0.11040) değerleri, modelin test veri setindeki tahminlerinin gerçek değerlere oldukça yakın olduğunu ve başarılı bir şekilde genelleme yaptığını göstermektedir. Ayrıca, YSA modelinin doğrusal regresyon modeline kıyasla daha düşük hata oranlarına sahip olduğu belirlenmiştir, bu da YSA modelinin daha doğru ve güvenilir tahminler sunduğunu ortaya koymaktadır.

2024-2025 yılları için yapılan hasta sayısı tahminleri, belirli aylar için YSA modeli kullanılarak hesaplanmış ve bu tahminler sağlık hizmetleri planlaması ve

kaynak tahsisi gibi stratejik kararların alınmasında önemli bir rol oynayabilecektir. Tahmini hasta sayıları, hastane kapasitesinin planlanması ve yönetilmesi için kritik bir bilgi kaynağı oluşturmaktadır. Tahminler, hastane yönetimine gelecek hasta yoğunluğunu öngörmede yardımcı olabilecektir. Bu bilgiler ışığında, personel ve kaynak planlaması daha etkin bir şekilde yapılabilecektir. Tahmin edilen hasta sayıları, hastanenin fiziksel kapasitesini ve hizmet sunumunu optimize etmek için kullanılabilecektir. Hasta sayısındaki artışlar önceden tahmin edilerek sağlık personelinin eğitimi ve hazırlığı artırılabilir ve bu sayede, ani hasta yoğunluklarında hizmet kalitesi korunabilecektir. Hastane bütçesi ve harcama planları, tahmin edilen hasta sayıları göz önünde bulundurularak yapılabilecektir.

Bağımsız değişkenlerin bağımlı değişken üzerindeki etkisine bakıldığında, doktor sayısı (0.2323357), toplam nüfus (0.345226), erkek nüfusu (0.3495335), kadın nüfusu (0.3313261), 0-14 yaş nüfusu (0.2648282), 14-65 yaş nüfusu (0.327459), 65 yaş üstü nüfusu (0.3000647), kişi başına gelir (0.3019443), okuma yazma bilen oranı (%) (0.3477666), ÜFE (0.2594181), TUFİ (0.2793055), kişi başına sağlık harcaması (0.3372885), kamu sağlık harcamaları (%) (0.2900802) gibi değişkenlerin acil servis başvuruları üzerindeki etkileri söz konusudur. Özellikle erkek nüfusu, okuma yazma bilen oranı ve toplam nüfusun, acil servis taleplerinde belirgin bir artış potansiyeline sahip olduğu gözlemlenmiştir. Bununla birlikte, doktor sayısının etkisinin diğer değişkenlere göre daha sınırlı olduğu görülmüştür. Bu bulgular, sağlık hizmetleri planlamasında ve kaynak yönetiminde daha özelleştirilmiş ve etkili stratejiler geliştirmek için rehberlik sunabilecektir. Ayrıca, gelecekteki sağlık politikalarının şekillendirilmesinde, nüfus yapısı ve ekonomik göstergelerin dikkate alınmasının gerekliliğine dikkat çekilmesi gerekebilir.

Bu çalışma, sağlık hizmetlerinin etkili bir şekilde yönetilmesi ve hastaların daha iyi bakım alması amacıyla oldukça önemlidir. Bu çalışmanın diğer literatürlerden farkı, aşağıda maddeler halinde açıklanmıştır:

Veri Hassasiyeti ve Doğruluk: Çalışmanın başarısı, kullanılan verilerin doğruluğuna ve hassasiyetine dayanır. Bu projede kullanılan verilerin doğruluğu ve güvenilirliği, projenin diğer literatürlerden farkını ortaya koyabilir. Örneğin, yerel hastane verileri, bölgesel hastalık paternlerini ve talepleri daha doğru bir şekilde yansıtabilir ve tahminlerin doğruluğunu artırır.

Yerel Faktörlerin Dikkate Alınması: Bingöl gibi belirli bir bölgeye yönelik bir projenin farkı, yerel faktörlerin dikkate alınmasıdır. Coğrafi, demografik ve sosyoekonomik faktörler, hastane acil servis taleplerini etkileyebilir. Bu faktörlerin dikkate alınması, tahminlerin daha hassas ve bölgesel olarak uyarlanmış olmasını sağlayabilir.

Bütüncül Yaklaşım: Bu çalışmanın literatürden farklı olabileceği bir diğer nokta, bütüncül bir yaklaşım benimsemesidir. Yani, sadece geçmiş verilere dayanmak yerine, makine öğrenimi ve yapay zeka gibi yeni teknolojileri kullanarak gelecekteki talepleri tahmin etme yeteneği. Bu, daha karmaşık ilişkileri ve trendleri analiz edebilme kapasitesi ile projeyi diğerlerinden ayırabilmektedir.

Sürdürülebilirlik ve Uygulanabilirlik: Projenin başarısı, sadece teorik bir çalışma olmaktan çıkıp gerçek dünyada uygulanabilir ve sürdürülebilir olabilme yeteneğine dayanır. Çalışmada, geliştirilen tahmin modelinin hastanelerde pratikte nasıl kullanılacağı ve günlük sağlık yönetimi süreçlerine nasıl entegre edileceği konusundaki stratejiler, projenin farkını ortaya koyabilmektedir. Bu faktörler, çalışmanın diğer literatürlerden farkını belirleyebilir ve projenin benzersiz değerini ortaya koyabilir. Bu tür özellikler, çalışmanın diğer benzer çalışmalardan üstün kılınmasını sağlayabilmektedir.

Bingöl Devlet Hastanesi Acil Servis Tahminleme çalışması, sağlık sektöründe yapay zeka ve veri analitiği tekniklerinin kullanılmasıyla önemli katkılarda bulunabilir. Bingöl İli'ne sağlayacağı potansiyel katkılar şunlar olabilir:

1. Hızlı ve Etkili Sağlık Hizmetleri: Çalışma, hastane acil servislerindeki hasta akışını doğru bir şekilde tahmin ederek sağlık personelinin kaynaklarını daha etkili bir şekilde yönetmelerine olanak tanıyabilmektedir. Bu sayede hastalara daha hızlı bir şekilde müdahale edilir, beklemler azaltılır ve acil durumlar için gereken hizmetler daha hızlı bir şekilde sunulabilir.

2. Kaynakların Daha Verimli Kullanımı: Yapay zeka tabanlı tahmin modelleri, hastane kaynaklarını en verimli şekilde kullanmayı sağlayabilir. Bu, hastane çalışanlarının zamanını ve enerjisini daha etkili bir şekilde yönlendirme imkanı tanıyabilir. Hastanelerin kapasitelerini doğru bir şekilde planlamalarını ve mevcut kaynakları en etkili şekilde kullanmalarını mümkün kılabilir. Bu da Bingöl'deki hastanenin daha etkili bir şekilde çalışmasına katkıda bulunabilir.

3. Planlama ve Kaynak Yönetimi: Çalışma, hastane yöneticilerine gelecekteki hasta akışını tahmin etme imkanı sunabilir. Bu tahminler, hastane kaynaklarını planlama süreçlerinde kullanılarak uygun sayıda personel ve malzeme temin edilmesine yardımcı olabilir. Bu da hastane hizmetlerinin sürekli ve düzenli bir şekilde devam etmesini sağlayabilir ve gelecekteki hasta akışını daha doğru bir şekilde tahmin edebilir. Bu da sağlık hizmetlerinin sürekliliğini ve etkinliğini artırabilir.

4. Sağlık Hizmetlerinin Kalitesinin Arttırılması: Daha hızlı hizmet, doğru planlama ve verimli kaynak kullanımı sağlanarak Bingöl İli'ndeki hastane hizmetlerinin kalitesi artırılabilir. Doğru zamanda doğru yerde olacak şekilde yapılan müdahaleler, hastaların memnuniyetini arttırabilir. Bu da beraberinde, sağlık hizmetlerine olan güvenini arttırabilecektir.

Bu katkılar, Hastane Acil Servis Tahminleme çalışmasının Bingöl İli'ne sağlayabileceği potansiyel faydaların birkaç örneğidir. Çalışma, sağlık hizmetlerinin daha etkili, verimli ve erişilebilir olması amacıyla Bingöl İli'nde önemli bir rol oynayabilir. Sonuç olarak, Hastane Acil Servis Tahminleme çalışması, Bingöl sağlık sistemine doğru planlama, etkin kaynak kullanımı, hızlı müdahale ve hasta memnuniyeti gibi alanlarda önemli katkılarda bulunabilir. Bu, sağlık hizmetlerinin kalitesini artırarak ilde ki yaşam kalitesini yükseltebilir.

Bu çalışmanın diğer sağlık talep tahminleme yöntemlerinden farkı aşağıdaki şekilde açıklanmıştır.

Yerel Odaklılık: Çalışma, belirli bir bölge veya hastane için özelleştirilmiş bir talep tahmini yapma amacı güder. Bingöl iline yönelik yerel demografik, ekonomik ve coğrafi faktörler dikkate alınarak özelleştirilmiş tahminler yapılması, bölgesel sağlık hizmetlerinin daha etkili bir şekilde yönetilmesine olanak tanıyabilecektir.

Daha Hassas Tahminler: Farklı yöntemlerin bir araya getirilmesi, tahminlerin daha hassas olmasını sağlamaktadır. Her bir yöntemin kendine özgü avantajları ve sınırlamaları vardır. Bu yöntemlerin kombinasyonu, bir yöntemin zayıf noktalarını diğerinin güçlü yanlarıyla dengeleyebilir. Sonuç olarak, daha doğru ve güvenilir tahminler elde edilebilme amaç edinilmeye çalışılmıştır.

Riskleri Azaltma: Karmaşık ve değişken veri setlerin tahmininde, tek bir tahmin yönteminin kullanılması, yanıltıcı sonuçlara yol açabilir. Farklı yöntemlerin

kullanılması, her bir yöntemin tahminlerini karşılaştırarak doğruluk oranını arttırılmaya çalışılmış ve böylece yanlış kararların alınmasının önüne geçmek amaçlanmıştır.

Değişken Koşullara Uyum Sağlama: Sağlık hizmetleri alanında talep, zamanla değişebilmektedir. Mevsimsel değişiklikler, salgın hastalıklar, ekonomik dalgalanmalar gibi faktörler talebi etkileyebilmektedir. Farklı yöntemler, değişen koşullara hızlı bir şekilde uyum sağlamak için kullanılabilir. Örneğin, zaman serileri analizi mevsimsel değişiklikleri anlamak için kullanılabilirken, yapay zeka modelleri daha karmaşık ve dinamik değişkenleri ele alabilmektedir.

Gerçek Zamanlı Güncelleme: Çalışmada, verilerin gerçek zamanlı olarak güncellenmesine ve analizlere hızlı bir şekilde entegre edilmesine odaklanılmaya çalışılmıştır. Bu amaç, sağlık hizmeti sağlayıcılarına ve yöneticilere anlık verilere dayalı kararlar alma fırsatı sunabilecektir.

Tahmin Doğruluğunu Arttırma: Çalışmada, tahmin doğruluğunu arttırmak için daha karmaşık tahmin modelleri ve algoritmalar kullanılmıştır. Bu da hastane kaynaklarının daha etkili bir şekilde yönetilmesine olanak sağlayabilecektir.

Hızlı ve Otomatik Öğrenme: Derin öğrenme modelleri, belirli bir eğitimden sonra hızlı bir şekilde tahmin yapabilmektedirler. Bu, gerçek zamanlı talep tahmini gibi hızlı kararlar almanın gerektiği durumlar için idealdir. Ayrıca, sürekli olarak güncellenen verilere anında uyum sağlayabilirler.

Bu faktörler, çalışmanın diğer sağlık alanındaki talep tahminleme yöntemlerinden farkını ve değerini ortaya koyabilir. Bu özellikler, projenin sağlık hizmeti sağlayıcılarına ve yöneticilere daha hassas, hızlı ve etkili bir şekilde talep tahmini yapma yeteneği sunmasını sağlayabilir. Farklı talep tahmin yöntemlerinin kullanılması, bir projenin sağlık hizmetleri yönetimi gibi karmaşık alanlarda daha doğru, güvenilir ve etkili tahminler yapmasını sağlayabilir. Sonuç olarak, farklı talep tahmin yöntemlerinin kullanılması, sağlık hizmeti yöneticilerine daha güçlü bir analitik araç seti sunabilir. Bu araçlar, sağlık kaynaklarını daha verimli bir şekilde yönetmelerine, hizmet kalitesini artırmalarına ve hastalar için daha iyi bir deneyim sağlamalarına yardımcı olabilir. Bu çalışmada sunulan farklı talep tahminleme yöntemlerinin karşılaştırılması ve Yapay Sinir Ağları (YSA) yönteminin en düşük RMSE değerine sahip olması, projenin sağlık hizmetlerinde talep tahmini alanında

önemli avantajlar sunabileceğini göstermektedir. Sonuç olarak, yapay sinir ağları, sağlık sektöründe talep tahmini için yapılan diğer yöntemlere kıyasla daha etkili ve doğru sonuçlar üretebilmiştir.

Tartışma

Bu çalışma, Bingöl Devlet Hastanesi'nde 2013-2023 yılları arasında kaydedilen acil servis başvurularını analiz ederek, yapay zeka yöntemleri ile bu başvuruların tahmin edilmesini amaçlamıştır. Çalışmada kullanılan tahmin modelleri zaman serisi, doğrusal regresyon ve yapay sinir ağları (YSA) olmuştur. Elde edilen sonuçlar, her bir modelin performansını karşılaştırarak çeşitli değerlendirmeler yapılmasına olanak tanımıştır.

Bu model, zaman serisi analizinde sıkça kullanılan ve geçmiş veriye dayalı olarak geleceği tahmin eden güçlü araçlardır. Bu modellerin performansları, özellikle mevsimsellik içeren verilerde SARIMA modelinin diğer modellere göre daha başarılı olduğunu göstermiştir. Ancak, her model belirli sınırlamalara sahiptir. Diğer modeller, veri setindeki trend ve mevsimsellik gibi özellikleri yakalamakta bazen yetersiz kalabilmektedir. SARIMA modeli, mevsimsel değişimleri daha iyi yakalasa da, karmaşık veri desenlerini yeterince öğrenememektedir. Bu durum, özellikle verideki ani değişikliklerin veya beklenmedik olayların tahmin edilmesinde yetersiz kalmasına neden olmaktadır.

Doğrusal regresyon modeli, bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki doğrusal ilişkiyi modellemek için kullanılan basit fakat güçlü bir istatistiksel tekniktir. Çalışmamızda doğrusal regresyon modeli, acil servis başvurularının tahmin edilmesinde şu şekilde kullanılmıştır:

1.Modelin Basitliği ve Yorumlanabilirliği: Doğrusal regresyon modeli, yapısı gereği kolayca yorumlanabilir ve uygulanabilir bir modeldir. Sağlık hizmetleri yöneticileri, bu modeli kullanarak acil servis başvurularını etkileyen temel faktörleri kolayca anlayabilecektir.

2.Tahmin Performansı: Doğrusal regresyon modeli, acil servis başvurularının tahmin edilmesinde makul bir performans sergilemiştir. Ancak, YSA modeline göre doğruluğu nispeten düşük kalmıştır. Bunun nedeni, doğrusal regresyonun karmaşık ve mevsimsel desenleri yakalamakta yetersiz kalmasıdır.

3.Uygulama Alanı: Doğrusal regresyon modeli, daha az veri gereksinimi ve hesaplama gücü ile hızlı ve etkili sonuçlar elde etmek için kullanılabilir. Bu model, özellikle veri setinin sınırlı olduğu durumlarda tercih edilebilir.

Yapay sinir ağları, karmaşık veri desenlerini öğrenme ve tahmin etme kapasitesi ile diğer modellere göre üstün performans sergilemiştir. Çalışmada kullanılan YSA modeli, acil servis başvurularının tahmininde daha düşük hata oranları ile daha yüksek doğruluk sağlamıştır. Bu durum, YSA'nın esneklik ve uyarlanabilirlik yeteneklerinden kaynaklanmaktadır. YSA'nın performansı, özellikle şu faktörlerden etkilenmiştir:

1.Veri Setinin Çeşitliliği: YSA modeli, geniş ve çeşitli veri setlerini öğrenme kapasitesi ile daha doğru tahminler yapabilmektedir. Bu, modelin karmaşık desenleri tanıma yeteneğini artırmıştır.

2.Hiperparametre Optimizasyonu: Modelin performansını artırmak için kullanılan hiperparametre optimizasyonu, YSA'nın doğruluğunu ve genel performansını olumlu yönde etkilemiştir.

3.Katman Sayısı ve Neuron Yapısı: YSA modelinde kullanılan katman sayısı ve her bir katmandaki neuron sayısı, modelin öğrenme kapasitesini ve tahmin doğruluğunu belirleyen önemli faktörler olmuştur.

Çalışmada, demografik ve sosyoekonomik faktörlerin acil servis başvuruları üzerindeki etkisi de incelenmiştir. Bulgular, toplam nüfus, erkek nüfusu, kadın nüfusu ve okuma yazma bilen oranı gibi faktörlerin acil servis başvurularını anlamlı derecede etkilediğini göstermiştir. Bu durum, sağlık hizmetlerinin planlanmasında ve kaynak yönetiminde şu önerileri sunmaktadır:

1.Nüfus Yoğunluğu ve Sağlık Hizmetleri: Nüfus yoğunluğunun yüksek olduğu bölgelerde, acil servis başvurularının da yüksek olması beklenmektedir. Bu nedenle, sağlık hizmetlerinin bu yoğunluğa göre planlanması gerekmektedir.

2.Eğitim Seviyesi ve Sağlık Bilinci: Okuma yazma bilen oranının yüksek olduğu bölgelerde, sağlık bilincinin ve dolayısıyla acil servis başvurularının daha kontrollü olduğu gözlemlenmiştir. Eğitim seviyesinin artırılması, sağlık bilincinin de artmasına katkıda bulunabilir.

3.Cinsiyet Dağılımı: Erkek ve kadın nüfusunun dağılımı, sağlık hizmetlerine olan talebi etkileyen bir diğer önemli faktördür. Bu dağılımın dikkate alınması, sağlık hizmetlerinin daha etkili planlanmasını sağlayabilir.

Çalışmanın Sınırlamaları

Bu çalışmanın bazı sınırlamaları bulunmaktadır:

1. **Veri Seti:** Çalışmada kullanılan veri seti, sadece Bingöl Devlet Hastanesi'ne ait olup, bulguların genelleştirilebilirliğini sınırlamaktadır. Farklı bölgelerdeki hastanelerden elde edilen verilerin analiz edilmesi, sonuçların genelleştirilebilirliğini artırabilir.
2. **Model Çeşitliliği:** Zaman serisi, doğrusal regresyon ve YSA modelleri kullanılmış olup, diğer yapay zeka algoritmalarının performansı değerlendirilmemiştir. Gelecek çalışmalar, farklı algoritmaların karşılaştırılması üzerine odaklanabilir.
3. **Veri Kalitesi:** Veri setinin kalitesi ve eksiklikleri, modellerin performansını etkileyebilir. Daha geniş ve kaliteli veri setleri, tahmin modellerinin doğruluğunu artırabilir.

Gelecek Çalışmalar için Öneriler

Bu çalışmanın bulguları, gelecek çalışmalar için çeşitli öneriler sunmaktadır:

1. **Farklı Algoritmaların Karşılaştırılması:** Gelecek çalışmalar, farklı yapay zeka algoritmalarının performansını karşılaştırarak, en etkili tahmin yöntemlerini belirleyebilir.
2. **Geniş Veri Setleri:** Farklı hastanelerden ve bölgelerden elde edilen geniş veri setlerinin kullanılması, modellerin genelleştirilebilirliğini ve doğruluğunu artırabilir.
3. **Gerçek Zamanlı Veri Analizi:** Gerçek zamanlı veri analizi ve tahmin modellerinin kullanımı, sağlık hizmetlerinin etkin yönetimini ve hızlı karar almayı destekleyebilir.

Sonuç olarak, bu çalışma, yapay zeka tabanlı tahmin modellerinin acil servis başvurularının tahmininde etkili bir araç olduğunu ve sağlık hizmetlerinin planlanmasında önemli bir rol oynayabileceğini göstermektedir. Gelecek çalışmalar,

bu bulguları daha da genişletmek ve sağlık hizmetlerinin kalitesini artırmak için yapay zeka tekniklerinin kullanımını daha derinlemesine incelemek üzerine odaklanmalıdır.

Bu çalışmanın bulguları ve tartışmaları doğrultusunda, sağlık yöneticileri, politika yapıcılar ve gelecekteki araştırmalar için aşağıdaki öneriler sunulmaktadır:

Sağlık Yöneticileri için Öneriler

1. Yapay Zeka Tabanlı Tahmin Modellerinin Kullanımı:

Uygulama: Hastanelerde acil servis başvurularını tahmin etmek için yapay zeka tabanlı tahmin modellerinin (özellikle yapay sinir ağları, doğrusal regresyon ve zaman serisi) kullanılması, kaynak planlaması ve yönetimi açısından büyük avantajlar sağlayabilir.

Eğitim ve Entegrasyon: Sağlık personelinin yapay zeka tabanlı tahmin modelleri konusunda eğitilmesi ve bu modellerin hastane bilgi sistemlerine entegre edilmesi gerekmektedir.

2. Veri Analitiği ve İzleme Sistemleri:

Gerçek Zamanlı İzleme: Hastanelerde gerçek zamanlı veri analitiği ve izleme sistemleri kurulmalı, acil servis başvuruları anlık olarak izlenmeli ve tahmin modelleri ile karşılaştırılmalıdır.

Veri Kalitesinin Artırılması: Hastane veri toplama süreçlerinin gözden geçirilmesi ve veri kalitesinin artırılması için gerekli adımlar atılmalıdır.

3. Demografik ve Sosyoekonomik Faktörlerin Entegrasyonu:

Yerel Verilerin Kullanımı: Sağlık hizmetlerinin planlanmasında yerel demografik ve sosyoekonomik verilerin dikkate alınması, hizmetlerin daha etkin ve verimli bir şekilde sunulmasını sağlayabilir.

Bölgesel Planlama: Nüfus yoğunluğu, yaş dağılımı ve eğitim seviyesi gibi faktörler göz önünde bulundurularak bölgesel sağlık planlamaları yapılmalıdır.

4. Eğitim ve Bilinçlendirme Kampanyaları:

Sağlık Bilincinin Artırılması: Toplumda sağlık bilincinin artırılması için düzenli eğitim ve bilinçlendirme kampanyaları düzenlenmelidir.

Kampanyaların Etkinliđi: Bu kampanyaların etkinliđini artırmak için çeřitli medya ve iletişim kanalları kullanılmalıdır.

Politika Yapıcılar için Öneriler

1. Sağlık Politikalarının Geliştirilmesi:

Yapay Zeka Yatırımları: Sağlık sektöründe yapay zeka ve veri analitiđi teknolojilerine yatırım yapılması teşvik edilmelidir.

Destek Programları: Hastanelerin ve sağlık kuruluşlarının bu teknolojileri benimsemeleri için destek programları oluşturulmalıdır.

2. Veri Paylaşımı ve İşbirliđi:

Veri Paylaşım Platformları: Farklı hastaneler ve sağlık kuruluşları arasında veri paylaşımını kolaylaştıracak platformlar oluşturulmalı, böylece daha geniş ve çeřitli veri setlerine erişim sağlanmalıdır.

İşbirlikleri: Akademik kurumlar, teknoloji şirketleri ve sağlık kuruluşları arasında işbirlikleri teşvik edilmeli ve bu işbirliklerinden elde edilen sonuçlar politika geliştirmede kullanılmalıdır.

3. Düzenleyici Çerçeveler:

Veri Gizliliđi ve Güvenliđi: Yapay zeka tabanlı sistemlerin kullanımı sırasında veri gizliliđi ve güvenliđi konularında sıkı düzenlemeler getirilmelidir.

Standartlar ve Kılavuzlar: Sağlık hizmetlerinde yapay zeka kullanımına yönelik standartlar ve kılavuzlar geliştirilmelidir.

Gelecek Araştırmalar için Öneriler

1. Farklı Algoritmaların Karşılaştırılması:

Model Çeřitliliđi: Zaman serisi, regresyon ve yapay sinir ađları dışında, diđer yapay zeka algoritmalarının (örneğin, destek vektör makineleri, karar ađaçları, vb.) performansı da karşılaştırılmalıdır.

Hibrid Modeller: Farklı modellerin birleştirilmesiyle hibrid tahmin modelleri oluşturulmalı ve performansları deđerlendirilmelidir.

2. Geniş ve Çeřitli Veri Setleri:

Bölgesel Çalışmalar: Farklı bölgelerden ve hastanelerden elde edilen geniş veri setleri kullanarak çalışmalar yapılmalı ve sonuçlar karşılaştırılmalıdır.

Veri Zenginleştirme: Demografik ve sosyoekonomik verilerin yanı sıra meteorolojik veriler, epidemiyolojik veriler ve diğer ilgili veriler de tahmin modellerine dahil edilmelidir.

3. Gerçek Zamanlı Veri Analizi:

Gerçek Zamanlı Sistemler: Sağlık hizmetlerinde gerçek zamanlı veri analizi ve tahmin sistemleri geliştirilerek, anlık karar destek mekanizmaları oluşturulmalıdır.

Dinamik Modeller: Gerçek zamanlı verilerle güncellenebilen dinamik tahmin modelleri üzerinde çalışılmalıdır.

4. Uygulama ve Değerlendirme:

Pilot Projeler: Yapay zeka tabanlı tahmin modellerinin uygulanabilirliğini ve etkinliğini değerlendirmek için pilot projeler başlatılmalı ve sonuçlar analiz edilmelidir.

Geribildirim Mekanizmaları: Sağlık personelinin ve hastalardan gelen geribildirimler, modellerin ve sistemlerin sürekli iyileştirilmesi için kullanılmalıdır.

Sonuç olarak, bu öneriler, sağlık hizmetlerinin daha etkin ve verimli bir şekilde sunulmasına katkıda bulunabilir. Yapay zeka ve veri analitiği teknolojilerinin sağlık sektöründe kullanımı, hem hastaların hem de sağlık çalışanlarının yararına önemli avantajlar sağlayabilecektir.

KAYNAKÇA

- Adalı, E. (2012). Doğal Dil İşleme. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*.
- Adalı, E. (2017). İnsanlaşan Makinalar ve Yapay Zeka. *İTÜ Vakfı Dergisi, Ocak-Mart*, 3-13.
- Ak, S. (2021). Geçmişten Günümüze Türkiye'nin Sağlık Politikaları. *Ankara Üniversite Araştırma Dergisi*, 28-36.
- Akdağ, R. (2007). *Nereden Nereye: Türkiye'de Sağlıkta Dönüşüm Programı*. Ankara: TC. Sağlık Bakanlığı.
- Akdağ, R. (2008). *Türkiye Sağlıkta Dönüşüm Programı ve Temel Sağlık Hizmetleri Kasım 2002-2008*,. Ankara: T.C. Sağlık Bakanlığı Yayın No:770.
- Akdur, R. (1999). *Türkiye'de Sağlık Hizmetleri ve Avrupa Topluluğu Ülkeleri ile Kıyaslanması*. Ankara: A.Ü.T.F Halk Sağlığı Anabilim Dalı.
- Akdur, R. (2006). *Sağlık Sektörü Temel Kavramlar Türkiye ve AB'de Durum ve Türkiye'nin Birliğe Uyumu*. Ankara: Ankara Üniversitesi Avrupa Toplulukları Araştırma ve Uygulama Merkezi.
- Akdur, R. (2008). Sağlık Harcamaları. *Bilim ve Ütopya*, 14-19.
- Akpınar, M. (2017). *İstatistik ve Yapay Zeka Teknikleri ile Enerji Tüketiminin Tahmini:Sakarya Doğalgaz Tüketiminin Tahmini*. Sakarya: Sakarya Üniversitesi Fen Bilimleri Enstitüsü.
- Aksay, E. E. (2019). Turkey's emergency care system and policies. *Turkish Journal of Emergency Medicine*, 19(1), 1-7.
- Aktel, M., Altan, Y., Eke, E., & Kerman, U. (2013). Türkiye'de Sağlık politikalarının Dönüşümü: Sağlık Bakanlığı'nın Taşra Örgütlenmesi Üzerinden Bir Analiz. *Sosyal Bilimler Dergisi, Cilt 15, Sayı 2*.
- Aktepe, A., Yanık, E., & Ersöz, s. (2021). Demand forecasting application with regression and artificial intelligence methods in a construction machinery company. *Journal of Intelligent Manufacturing*, 1587-1604.
- Akyurt, İ. Z. (2015). Talep Tahmininin Yapay Sinir Ağlarıyla Modellenmesi: Yerli Otomobil Örneği. *İstanbul Üniversitesi İktisat Fakültesi Ekonometri ve İstatistik Dergisi*, 147-157.
- Al, B. (2015). Acil Servislerde Hizmet Kalitesi ve Hasta Memnuniyeti Üzerine Çalışmalar. *Türk Acil Tıp Dergisi*, 120-130.
- Al, B. (2017). Doğal Afetlere Hazırlık ve Acil Servislerin Rolü. *Türkiye Sağlık Bilimleri Dergisi*, 18(4), 215-223.
- Al, B. (2018). Acil Servislerde Triage Sistemlerinin Geliştirilmesi. *Tıp ve Sağlık Bilimleri Araştırma Dergisi*, 87-95.

- Allahverdi, N. (2002). *Uzman Sistemler: Bir Yapay Zeka Uygulaması*. İstanbul: Atlas Yayıncılık.
- Alpaydın, E. (2014). *Introduction to Machine Learning*. Cambridge: MIT Press.
- Alpaydın, E. (2016). *Machine Learning The New AI*. Londra: MIT Press.
- Amirkolaii, K. N., Baboli, A., Shahzad, M. K., & Tonadre, R. (2017). Demand Forecasting for Irregular Demands in Business Aircraft Spare Parts Supply Chains by using Artificial Intelligence (AI). *IFAC-PapersOnLine*, 15221-15226.
- Anderson, T. (1990). *Understanding Knowledge Engineering*. New York.: John Wley&Son.
- Arslandaş, D. (2013). *Temel Sağlık Hizmetleri*. Eskişehir: Anadolu Üniversitesi Yayınları.
- Atasever, M. (2017). *Türkiye Sağlık Hizmetlerinin Finansmanı ve Sağlık Harcamalarının Analizi 2002-2013 Dönemi*. Ankara: Bakanlık Yayın No: 983. Aralık Cumartesi, 2020 tarihinde alındı
- Ateş, M. (2016). *Sağlık Sistemleri, 3. Baskı*. İstanbul: Beta Yayınları.
- Aydın, E. (2004). 19. Yüzyılda Osmanlı Sağlık Teşkilatlanması. *OTAM, Ankara Üniversitesi Osmanlı Tarihi Araştırma ve Uygulama Merkezi Dergisi*, 185-207.
- Bağış, A., & Özçelik, Y. (2008). *Gerçek Kodlu Genetik Algoritma Kullanılarak Sistem Kimliklendirme*. Kayseri: Erciyes Üniversitesi, Elektrik-Elektronik Mühendisliği.
- Bai, Y., & Wang, D. (2006). *Fundamentals of Fuzzy Logic Control – Fuzzy Sets, Fuzzy Rules and Defuzzifications, Advanced Fuzzy Logic Technologies in Industrial Applications*. London: Springer.
- Baker, D. W. (2018). Reducing emergency department wait times and improving quality of care. *American Journal of Emergency Medicine*, 842-848.
- Baric, L. (1985). The Meaning of Words: Health Promotion. *Journal of Health Education*, 23(1). 367-372.
- Bärnighausen, T., & Sauerborn, R. (2002). One Hundred and Eighteen Years of the German Health Insurance System: Are There Any Lessons For Middle-and Low-Income Countries? . *Social Science & Medicine*, 1559-87.
- Başer, D. A., Kahveci, R., Koç, E., Kasım, İ., Şencan, İ., & Özkara, A. (2015). Etkin Sağlık Sistemleri İçin Güçlü Birinci Basamak. *Ankara Med J* 15(1), 26-31.
- Boden, M. (2018). *Artificial Intelligence – A Very Short Introduction*. London: Routledge.
- Box, G. E. (2008). *Time Series Analysis: Forecasting and Control*. Hoboken: Wiley.

- Bozdemir, M. (2019). Mekanik tasarım eğitimi için bir uzman sistem uygulaması. *Uludağ University Journal of The Faculty of Engineering*, 219-230.
- Bozüyük, T., Yağcı, C., Gökçe, İ., & Akar, G. (2005). Yapay Zeka Teknolojilerinin Endüstrideki Uygulamaları. *Marmara Üniversitesi Teknik Bilimler Meslek Yüksek Okulu Elektrik Programı*, 1-67.
- Burnham, K. P. (2004). Multimodel Inference: Understanding AIC and BIC in Model Selection. *Sociological Methods & Research*, 261-304.
- Çakır, F. S. (2019). *Yapay Sinir Ağları Matlab Kodları ve Matlab Toolbox Çözümleri*. Ankara: Nobel Yayıncılık.
- Çalışkan, F., Yüksel, H., & Dayık, M. (2016). Genetik Algoritmaların Tasarım Sürecinde Kullanılması. *SDU Teknik Bilimler Dergisi*, 21-27.
- Calp, M. (2019). İşletmeler için Personel Yemek Talep Miktarının Yapay Sinir Ağları Kullanılarak Tahmin Edilmesi. *Politeknik Dergisi*, 675-686.
- Cansever, İ. H. (2018/2). Devlet Anlayışları Ekseninde Sağlık Politikalarının Değişimi ve Analizi. *Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, Sayı:31, 105-120.
- Carret, M. L., Kawachi, I., & Fassa, A. G. (2007). Demand for emergency health service: factors associated with inappropriate use. *BMC Health Services Research*, 7-131.
- Çavdar, N., & Karıcı, E. (2014). *XIX. Yüzyıl Osmanlı Sağlık Teşkilatlanması'na Dair Bibliyografik Bir Deneme*. Turkish Studies - International Periodical For The Languages, Literature and History of Turkish or Turkic, Volume 9/4.
- Çavmak, Ş., & Çavmak, D. (2017). Türkiye'de Sağlık Hizmetlerinin Tarihsel Gelişimi ve Sağlıkta Dönüşüm Programı. *Sağlık Yönetimi Dergisi*, 48-57.
- Çelik, Y. (2014). *Sağlık Ekonomisi 3. Baskı*. Ankara: Siyasal Kitabevi.
- Chawla, A., Singh, A., Lamba, A., Gangwani, N., & Soni, U. (2018). Demand Forecasting Using Artificial Neural Networks—A Case Study of American Retail Corporation. *Applications of Artificial Intelligence Techniques in Engineering*, 79-89.
- Chen, Y., Argentin, E., & Weber, G. (2016). IBM Watson: How Cognitive Computing can be Applied to Big Data Challenges in Life Sciences Research. *Clinical Therapeutics*, 688-701.
- Choi, H. K. (2022). Predictive Modeling of Emergency Department Visits Using Ensemble Learning Methods. *IEEE Access*.
- Çicek, Ö., & Öçal, M. (2016). Dünyada ve Türkiye'de İş Sağlığı ve İş Güvenliğinin Tarihsel Gelişimi. *Hak İş Uluslararası Emek ve Toplum Dergisi*, 106-129.

- Çiftçi, S., & Batur, G. D. (2022). Acil servise başvuru sayısının zaman serisi analiz ve makine öğrenmesi yöntemleri ile tahmin edilmesine yönelik bir uygulama. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*.
- Çoban, f., & Demir, L. (2021). Yapay Sinir Ağları ve Destek Vektör Regresyonu ile Talep Tahmin:Gıda İşletmesinde Bir Uygulama. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 327-338.
- Cohen, R. (1987). *The Handbook Artificial Intelligence*. New York: McGraw-Hill.
- Cole, E. C. (2006). The culture of a trauma team in relation to human factors. *Journal of Clinical Nursing*, 1257-1266.
- Copeland, J. (1993). *Artificial Intelligence: A Philosophical Introduction*. Cambridge: Blackwell.
- Çuhadar, M. (2013 8(31)). Türkiye'ye Yönelik Dış Turizm Talebinin Mlp, Rbf Ve Tdnn Yapay Sinir Ağı Mimarileri ile Modellenmesi ve Tahmini: Karşılaştırmalı Bir Analiz. *Journal of Yasar University*, 5274-5295.
- Culyer, A., & Newhouse, J. (2000). *Introduction: The State and Scope of Health Economics, Handbook of Health Economics (1A)*. Amsterdam, The Netherlands: Elsevier Science B.V.
- Curtis, K. F. (2016). Translating research findings to clinical nursing practice. *Journal of Clinical Nursing*, 862-872.
- Dağdemir, Ö. (2009). Sağlık ve Ekonomik Büyüme:1960-2005 Döneminde Gelişmekte Olan Ülkelerde Sağlık ve Ekonomik Büyüme Arasındaki Karşılıklı İlişkinin Analizi. *Ankara Üniversitesi SBF Dergisi*, 76-96.
- Dalkey, N. C. (1963). An Experimental Application of the Delphi Method to the Use of Experts. *Management Science*, 9(3), 458-467.
- Daştan, İ., & Çetinkaya, V. (2015). OECD Ülkeleri ve Türkiye'nin Sağlık Sistemleri, Sağlık Harcamaları ve Sağlık Göstergeleri Karşılaştırması. *Sosyal Güvenlik Dergisi*, 104-134.
- Davis, R. L. (2024). Strategic Planning and Resource Allocation Based on Emergency Department Data. *Journal of Healthcare Management*, 137-150.
- Davis, T. (1994). The Laboratory for International Fuzzy Engineering Research. *Asian Office of Aerospace Research and Development*, 1-4.
- Dedeoğlu, A. (2002). Tüketici Davranışları Alanında Kalitatif Araştırmaların Önemi ve Multidisipliner Yaklaşımlar. *D.E.Ü.İ.İ.B.F.Dergisi*, 75-92.
- Dedeoğlu, T., & Çetin, O. (2021). Sağlık Sektöründe Hasta Talebnn Tahmn. *Trakya Üniversitesi İ.İ.B.F E-Dergi*, 25-38.
- Demir, H., & Gümüşoğlu, Ş. (2003). *Üretim Yönetimi İşlemler Yönetimi*. İstanbul: Beta Yayıncılık.

- Derlet, R. W. (2002). Overcrowding in Emergency Departments: Increased Demand and Decreased Capacity. *Ann Emerg Med*, 430-432.
- Dhawan, S. (2020). Online Learning: A Panacea in the Time of COVID-19 Crisis. *Journal of Educational Technology Systems*, 5-22.
- Dore, F. (Haziran 2012). Güçlü Yapay Zekaya Karşı Çin Odası Argümanı. *AKÜ Sosyal Bilimler Dergisi, Cilt: XIV, Sayı 1*, 23-38.
- Durusoy, R. (2011). İzmir’de ikinci ve üçüncü basamak sağlık kuruluşlarına başvuran gebelerin aile hekimi tarafından izlenme sıklıkları ve etkileyen etmenler. *Türkiye Halk Sağlığı Dergisi*, 1-15.
- Eberly, U. (2019). *Akıllı Makineler Yapay Zekâ Hayatımızı Nasıl Değiştiriyor* (çev. L. Tayla). İstanbul: Paloma Yayınevi.
- Efendigil, T., & Eminler, Ö. E. (2017). Havacılık Sektöründe Talep Tahmininin Önemi: Yolcu Talebi Üzerine Bir Tahmin Modeli. *Tarım ve Gıda Değer Zincirlerinde Yöneylem Araştırmaları ve Endüstri Mühendisliği Özel Sayısı*, 14-30.
- Elmas, Ç. (2011). *Yapay Zekâ Uygulamaları*. Ankara: Seçkin Yayıncılık.
- Erdoğan, H., Terzioğlu, M., & Kayakuş, M. (2021). Almanya’dan Konaklama Amacıyla Türkiye’ye Gelen Turist Sayısının Yapay Zekâ Teknikleri Kullanılarak Tahmin Edilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, 961-971.
- Erkan, H. (1997). *Bilgi Toplumu ve Ekonomik Gelişme*. İstanbul: Türkiye İş Bankası Kültür Yayınları.
- Erkut, H., Akgüç, Ö., Pamuk, G., Ülengin, B., Ülengin, F., Alpay, Y., & Koşma, H. (1997). *Stratejik Yönetim ve Senaryo Tekniği*. İstanbul: İrfan Yayınevi.
- Ertaş, H., İleri, H., & Seçer, B. (2016). Sağlık Politikası Kavramı ve Türkiye’de Sağlık Politikasının incelenmesi . *Selçuk Üniversitesi Sosyal ve Teknik Araştırmalar Dergisi, Sayı 12*, 176-186.
- Esen, H., & Kaya, Ü. (2021). Bir Eğitim Araştırma Hastanesi Acil Servis Birimine Başvuran Hasta Sayısı Tahmini. *Verimlilik Dergisi*, 129-145.
- EY Dijital Sağlık Raporu. (2023, Mart). Dijital Sağlıkta Dünya ve Türkiye Perspektifi: https://assets.ey.com/content/dam/ey-sites/ey-com/tr_tr/pdf/2023/dijital-saglikta-dunya-ve-turkiye-perspektifi-raporu.pdf adresinden alındı
- Fişek, N. (1983). *Halk Sağlığına Giriş*. Ankara: Ankara: Hacettepe Üniversitesi ve Dünya Sağlık Örgütü Araştırma ve Araştırmacı Yetiştirme Merkezi Yayını, No: 2.
- Franchi, S., & Güzeldere, G. (2005). *Mechanical Bodies, Computational Minds*. Cambridge: MIT Press.

- Gao, Q. L. (2023). Using Neural Networks for Accurate Emergency Department Visit Forecasting. *Journal of Biomedical Informatics* .
- Goodfellow, I. B. (2016). *Deep Learning*. Cambridge: MIT Press.
- Gordon, M. C. (2020). The impact of emergency department crowding on hospital resource use. *Journal of Emergency Medicine*, 394-402.
- Gözlü, M., & Tatlıdil, H. (2015). Türkiye'deki 81 İlin Kamu tarafından Sunulan Sağlık Hizmetine Erişim Durumları. *Sosyal Güvenlik Dergisi, Ankara*, 160-163.
- Greenhalgh, T. W. (2020). The impact of COVID-19 on health care systems and the role of telehealth. *BMJ*.
- Gülalp, B. K. (2010). Evaluation of preparedness levels of Turkish hospitals for disasters. *Prehospital and Disaster Medicine*, 412-415.
- Gündoğdu, E., Gündoğdu, K., & Yücedağ, İ. (2016). Bulanık Mantık ile Akıllı Fırının Modellenmesi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 4, 574-580.
- Gürbüz, S., & Şahin, F. (2015). *Sosyal Bilimlerde araştırma yöntemleri*. Ankara: Seçkin Yayıncılık.
- Gürel, M. (2017). *Dijital Kehanet*. İstanbul: Destek Yayınları.
- Gürsoy, A. (2013). *Sağlık Sektöründe Hizmet Kalitesinin Servqual Ölçeği ile Değerlendirilmesi : Bir Kamu Hastanesi Uygulaması*. İstanbul: İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü.
- Hanke, J., & Wichern, D. (2014). *Business Forecasting*. England: Pearson Education.
- Hastie, T. T. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. New York: Springer.
- Heizer, J., & Render, B. (2017). *Üretim Yönetimi: Sürdürülebilirlik ve Tedarik Zinciri Yönetimi*. Ankara: Palme Yayıncılık.
- Helliwell, J. F. (2021). World Happiness Report 2021. *Sustainable Development Solutions Network*.
- Hoge, C., Auchterlonie, J., & Milliken, C. (2006). Mental Health Problems, Use of Mental Health Services and Attrition From Military Service After Returning From Deployment to Iraq or Afghanistan. *Jama The Journal of the American Medical Association*, Cilt 295, Sayı 9, 1025.
- Holland, J. H. (1975). *Adaptation in Natural and Artificial Systems*. Michigan: The University of Michigan Press.
- Hong, W., Haymoviç, A., & Taylor, R. (2018). Predicting hospital admission at emergency department triage using machine learning. *PLOS ONE*, 1-13.

- Hongoro, C., & Mcpake, B. (2004). How to bridge the gap in human resources for health. *The Lancet*, 1451-1456.
- Hoot, N. R. (2008). Systematic review of emergency department crowding: causes, effects, and solutions. *Annals of Emergency Medicine*, 126-136.
- Hyndman, R. J. (2018). *Forecasting: Principles and Practice*. Monash University, Australia: OTexts.
- İLOSAT. (2020, Nisan 7).
"<https://ilostat.ilo.org/data>"[https://www.datawrapper.de/_/8puAv/2020_7_nisan haberi](https://www.datawrapper.de/_/8puAv/2020_7_nisan_haberi). Ekim 12, 2022 tarihinde alındı
- Immergut, E. (1992). *Health Politics: Interests and Institutions in Western Europe*. Cambridge: Cambridge University Press.
- Işkın, A. (2012). *Elektronik Bankacılık Hizmetleri Ve Denetimi*. İstanbul: İTO Yayınları.
- Ivanov, D. D. (2020). The impact of COVID-19 on global supply chains and the role of digital transformation. *International Journal of Production Research*.
- James, G. W. (2013). *An Introduction to Statistical Learning: With Applications in R*. Springer.
- Johnson, K. A. (2016). Forecasting Emergency Department Visits Using Time Series Analysis. *Journal of Emergency Medicine*.
- Kahraman, A., & Bolışık, B. (2014). Küreselleşmenin Çocuk Sağlığına Etkileri. *The Journal of Pediatric Research*, 108-112.
- Karahan, M. (2015). Yapay Sinir Ağları Metodu İle İhracat Miktarlarının Tahmini: ARIMA ve YSA Metodunun Karşılaştırmalı Analizi. *Ege Akademik Bakış*, 165-172.
- Karakaş, E. (2019). Çocuk Yoğun Bakım Ünitesine Olan Talebin Zaman Serisi Yöntemleri ile Tahmin Edilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, 454-462.
- Kartal, S. (2023). Prophet Modeli ile Ürün Talep Tahmini. *GLOBECER'23*. Adana: Department of Computer Engineering, Cukurova University.
- Kasapoğlu, A. (2016). Türkiye`de Sağlık Hizmetlerinin Dönüşümü. *Sosyoloji Araştırmaları Dergisi*, 131-174.
- Kavuncubaşı, Ş. (2010). *Hastane ve Sağlık Kurumları Yönetimi*. Ankara: Siyasal Kitabevi.
- Kayım, H. (1985). *İstatistiksel ön tahmin yöntemleri*. Ankara: Hacettepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi.
- Kaynar, O., & Taşkan, S. (2009). Zaman Serisi Analizinde Mlp Yapay Sinir Ağları Ve Arıma Modelinin Karşılaştırılması. *Erciyes University Journal of Faculty of Economics and Administrative Sciences*, 161-172.

- Kellova, A. (2008). *Statistical Approach to Short-Term Electricity Forecasting*. Prague: Charles University.
- Khosroshani, A., & Aydintan, E. (2019). Hastane Acil Servis Tasarımında Öngörülü Yaklaşım. *MEGARON*, 359-372.
- Kılavuz, E. (2010). Sağlık Harcamalarındaki Artış ve Temel Bakım Hizmetleri. *Sosyal Bilimler Enstitüsü Dergisi*, Sayı: 29 , 173-192.
- Kılıç, F., Akkaya, M., & Memili, N. (2018). Yemekhane için Yapay Zekâ Teknikleri Kullanımı ile Günlük Talep Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, 65-71.
- Kim, J. L. (2024). Deep Learning Approaches for Emergency Department Demand Prediction. *Health Information Science and Systems*, 12(1), 15.
- Kniffin, K. M. (2021). Remote work and the post-pandemic workplace: A framework for sustainable transitions. *Academy of Management Perspectives*.
- Kobu, B. (2014). *Üretim Yönetimi*. İstanbul: Beta Yayıncılık.
- Koç, O. (2018). *Daha İyi Bir Dünya İçin Yapay Zekâ*. İstanbul: Doğan Egmont Yayıncılık.
- Kochak, A., & Sharma, S. (2015). Demand Forecasting Using Neural Network For Supply Chain Management. *Int. J. Mech. Eng. & Rob. Res.*, 96-104.
- Kumar , A. (2023, Kasım 10). *Analytics Yogi*. AIC & BIC for Selecting Regression Models: Formula, Examples: <https://vitalflux.com/aic-vs-bic-for-regression-models-formula-examples/> adresinden alındı
- Kutner, M. H. (2004). *Applied Linear Regression Models*. NewYork: McGraw-Hill Education.
- Lameire, N., Joffe, P., & Wiedemann, M. (1999). Healthcare SystemsAn International Review: an Overview. *Nephrol. Dial. Transplant*, 14(6): 3-9.
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep Learning. *Nature*, (521), 436–444.
- Linstone, H., & Turoff, M. (2002). *The Delphi Method Techniques and Applications*. California: University of Southern California.
- Marinoni, G. V. (2020). The Impact of COVID-19 on Higher Education Around the World. *International Association of Universities*.
- McCarthy, M. L. (2019). Optimizing emergency department operations: Insights from predictive modeling. *Health Services Research*, 737-745.
- Mccorduck, P. (2004). *Machines Who Think - A Personal Inquiry into the History and Prospects of Artificial Intelligence*. Natick: A K Peters, Ltd.
- Mcpherson, S. S. (2018). *Artificial Intelligence Building Smarter Machines*. Minneapolis: Twenty-First Century Books.

- Mendelson, D. N., & Schwartz, W. B. (1993, vol:12, No:1). The Effects of Aging and Population Growth on Health Care Costs. *Health Affairs*, 119-125.
- Mesko, B. (2018). *Tıbbın Geleceğine Yolculuk*. İstanbul: Optimist Yayın Grubu.
- Miller, J. R. (2021). Enhanced Emergency Department Patient Flow Prediction Using Deep Reinforcement Learning. *Journal of Medical Systems*.
- Moroff, N. U., Kurt, E., & Kamphues, J. (2021). Procedia Computer Science. *Machine Learning and Statistics: A Study for assessing innovative Demand Forecasting Models*, 40-49.
- Mutlu, A. (2006). Küresel Kamusal Mallar Bağlamında Sağlık Hizmetleri ve Çevre Kirlenmesi: Üretim, Finansman ve Yönetim Sorunları. *Maliye Dergisi*, 195-216.
- Nabiyev, V. (2012). *Yapay Zeka*. Ankara: Seçkin Yayıncılık.
- Naser, S., & Alhabbash, M. (2016). Male Infertility Expert System Diagnoses and Treatment. *American Journal of Innovative Research and Applied Sciences*, 2, 181-192.
- Nguyen, T. S. (2023). Time Series Forecasting of Emergency Department Visits with Seasonal and Trend Components. *PLOS ONE*.
- Öcek, Z., & Soyer, A. (2007). *Birinci Basamak Sağlık Hizmetleri Birikimimiz 2000-2004 Türkiye Fotoğrafı*. Ankara: Türk Tabipler Birliği Yayınları.
- Oredsson, S. J. (2011). A systematic review of triage-related interventions to improve patient flow in emergency departments. *Scandinavian Journal of Trauma, Resuscitation and Emergency Medicine*.
- Ortaylı, İ. (2000). *Tanzimat Devrinde Osmanlı Mahalli İdareleri (1840-1880)*. Ankara: Türk Tarih Kurumu Yayınları.
- Özmen, Z. (2017). Avrupa’da Sosyal Güvenlik Sisteminin Finansmanı: Farklı Refah Devletleri Üzerine Bir İnceleme. *Sosyal Bilimler Enstitüsü Dergisi Karabük Üniversitesi*, 600-620.
- Öztek, Z. (Mayıs-Haziran 2003). Sağlıkta Kavramlar, Sağlık Kavramı ve Sağlık Hizmetleri. *Yeni Türkiye Dergisi*, 295.
- Öztemel, E. (2012). *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık.
- Öztürk, M. (1989). *Ruh Sağlığı ve Bozuklukları*. İstanbul: Nobel Tıp Kitapları.
- Öztürk, Z., & Karakaş, E. T. (2015). Avrupa Birliğine Üye Ülkelerde Sağlık Sistemleri Yönetimi ve Organizasyon Yapısı Almanya, Fransa, İrlanda ve İngiltere Örnekleri. *Uluslararası Sağlık Yönetimi ve Stratejileri Araştırma Dergisi*, 39-59.
- Özüdoğru, A. G., & Görener, A. (2014). Sağlık Sektöründe Talep Tahmini Üzerine Bir Uygulama. *İstanbul Ticaret Üniversitesi Sosyal Bilimleri Dergisi*, 37-53.

- Patton, M. (1990). *Qualitative Evaluation and Research Methods, 2nd Ed.* London: Sage Publications.
- Pekten, A. (2006). Genel Sağlık Sigortası Sistemi ve Getirdiği Yenilikler. *Sayıştay Dergisi*, 119 - 138.
- Pfefferbaum, B. N. (2020). Mental Health and the COVID-19 Pandemic. *The New England Journal of Medicine*, 383, 510-512.
- Philips. (2021, Kasım). *Türkiye Sağlık Trendleri 2021 Araştırması*.
<https://www.philips.com.tr/a-w/about/news/archive/standard/news/press/2021/20210911-philips-changing-with-covid-19-announced-turkey-health-trends.html> adresinden alındı
- Pines, J. M. (2009). The association between emergency department crowding and adverse cardiovascular outcomes in patients with chest pain. *Academic Emergency Medicine*, 617-625.
- Pirim, H. (2006). Yapay Zeka. *Journal of Yasar University*, 1(1), 81-93 .
- Pöhler, L., Schrader, V., & Ladwein, A. (2018). A Technological Perspective on Misuse of Available AI. *Consciouscoders (August)*, 1–13.
- Rende, F. Ş., Bütün, G., & Karahan, Ş. (2016). Derin Öğrenme Algoritmalarında Model Testleri: Derin Testler. *10. Ulusal Yazılım Mühendisliği Sempozyumu, 24-26 Ekim , Çanakkale*, 54-59.
- Russell, S., & Norvig, P. (2016). *Artificial Intelligence - A Modern Approach*. Harlow: Pearson Education Limited.
- Russell, S., Dewey, D., & Tegmark, M. (2015). Research Priorities for Robust and Beneficial Artificial Intelligence. *AI Magazine*, 105-114.
- Sağlam, M., Spataru, C., & Karaman, Ö. A. (2022). Electricity Demand Forecasting with Use of Artificial Intelligence: The Case of Gokceada Island. *Enstitü, Bartlett Okulu Çevresi, Enerji ve Kaynaklar, University College London, Londra WC1E 6BT, Birleşik Krallık*.
- Şahin, T. (2019). Ruh Sağlığı Ve Hastalıkları Polikliniğine Olan Talebin Zaman Serileri Modelleri İle Tahmini. *Hacettepe Sağlık İdaresi Dergisi*, 749-764.
- Sarıyer, G. (2018). Acil Servislerde Talebin Zaman Serileri Modelleri ile Tahmin Edilmesi. *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi*.
- Sayım, F. (2015). Sağlık hizmetinin özellikleri. *Akademik Arge Dergisi-Sosyal Bilimler*, 1-12.
- Scherer, M. U. (2016). Regulating Artificial Intelligence Systems: Risks, Challenges, Competencies, and Strategies. *Harvard Journal of Law & Technology*, 354-400.
- Schoemaker, P. (1995). Scenario Planning: A Tool for Strategic Thinking. *Sloan Management Review Winter*, 25-40.

- Schwab, K. M. (2020). *The Great Reset: Post-Pandemic Economic Transformation and Its Impact on Society*. Cologne/Geneva: Forum Publishing.
- Schwartz, D., & Klir, G. (1992). Fuzzy logic flowers in Japan. *IEEE Spectrum*, 32-35.
- Seçim, H. (1985). *Hastane Yönetim ve Organizasyonu*. eskişehir: Anadolu Üniversitesi Açık Öğretim Fakültesi Yayınları, No:53,.
- Seker, S. (2014). Delfi Metodu (Delphi Method). *YBS Ansiklopedi*, 11-14.
- Şen, Z. (2004). *Mühendislikte Bulanık(FUZZY) Mantık ile Modelleme Prensipleri*. İstanbul: Su Vakfı Yayınları.
- Shao, Y. L. (2021). Emergency Department Patient Volume Forecasting Using Artificial Neural Networks. *Neurocomputing*, 79-92.
- Sharma, V., Rai, S., & Dev, A. (2012). A comprehensive study of artificial neural networks. *International Journal of Advanced research in computer science and software engineering*, 278-284.
- Shumway, R. H. (2017). *Time Series Analysis and Its Applications*. New York: Springer.
- Shumway, R. H. (2017). *Time Series Analysis and Its Applications: With R Examples (4th ed.)*. New York: Springer.
- Smith, J. R. (2022). Reducing Wait Times in Emergency Departments: The Role of Predictive Analytics. *Journal of Emergency Medicine*, 53-65.
- Somunoğlu, S. (2012). Kavramsal Açıdan Sağlık. *Hacettepe Sağlık İdaresi Dergisi*, C.4, S.1.
- Söylemez, Y. (2020). Çok Katmanlı Yapay Sinir Ağları Yöntemi ile Altın Fiyatlarının Tahmini. *Sosyoekonomi*, 271-290.
- Steinbrook, R. (2012). The US Supreme Court's ruling on the Patient Protection and Affordable Care Act. *BMJ: British Medical Journal*, 344: 1-2.
- Sülkü, S. N. (2011). *Türkiye'de Sağlıkta Dönüşüm Programı Öncesi ve Sonrasında Sağlık Hizmetlerinin Sunumu, Finansmanı ve Sağlık Harcamaları*. Ankara: T.C. Maliye Bakanlığı Strateji Geliştirme Başkanlığı, Yayın No:2011/414.
- Sun, R. K. (2013). *Trends in hospital emergency department visits by age and payer, 2006-2010*. Rockville, MD: Agency for Healthcare Research and Quality.
- Szeliski, R. (2011). *Computer Vision*. New York: Ny: Springer.
- Tegmark, M. (2019). *Yaşam 3.0 Yapay Zekâ Çağında İnsan Olmak (çev. E. C. Göksoy)*. İstanbul: Pegasus Yayınları.
- Temiz , Ö. (2014). Türk Hukukunda Bir Temel Hak Olarak Sağlık Hakkı. *Ankara Üniversitesi SBF Dergisi*, 165-188.

- Temizkan, S. P. (2015). *Sağlık Turizmi*. Ankara: Detay Yayınları.
- Tengilimoğlu, D., & Çıtak, N. (2003). *Yönetici ve Tıp Sekreterliği*. Ankara: Seçkin Yayıncılık.
- Tengilimoğlu, D., Işık, O., & Akbolat, M. (2017). *Sağlık İşletmeleri Yönetimi*. Ankara: Nobel Yayıncılık.
- Tiryaki, A., & Kazan, R. (2007). Bulaşık Makinesinin Bulanık Mantık ile Modellenmesi. *Sakarya Üniversitesi, Mühendislik Fakültesi, Makina Mühendisliği Bölümü*, 3-8.
- Tok, Ö. (2008). *Osmanlı Dönemi Hekim-Hasta İlişkileri (Kadı Sicillerine Göre XVII. Ve XVIII. Yüzyıllarda Kayseri Örneği*. Kayseri: Turkish Studies, International Periodical For the Languages, Literature and History of Turkish or Turkic, Volume 3/4. .
- Topol, E. J. (2020). Post-pandemic recovery: Leveraging healthcare innovation. *Nature Medicine*.
- Türk, E., & Kıanı, F. (2019). Yapay Sinir Ağları ile Talep Tahmini Yapma: Beyaz Eşya Üretim Planlaması için YSA Uygulaması. *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 30-37.
- Tüylüoğlu, Ş., & Tekin, M. (2009). Tüylüoğlu, Ş., & Tekin, M. (2009,Cilt:13). Gelir Düzeyi ve Sağlık Harcamalarının Beklenen Yaşam Süresi ve Bebek Ölüm oranı üzerindeki etkileri. *Çukurova Üniversitesi İİBF Dergisi*, 1-31.
- Uğur, A., & Kınacı, A. (2006). Yapay Zeka Teknikleri ve Yapay Sinir Ağları Kullanılarak Web Sayfalarının Sınıflandırılması. *Türkiye'de İnternet* (s. 345-349). Ankara: TOBB Ekonomi ve Teknoloji Üniversitesi.
- Vatansever, F., & Şen, D. (2013). Genetik Algoritma Tabanlı PID Kontrolör Similatörü Tasarımı. *Uludağ Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 7-18.
- Vyas, L. B. (2021). The Future of Work Post-COVID-19. *World Development*.
- Weiss, S. J. (2022). Improving Emergency Department Operations with Advanced Predictive Models. *Academic Emergency Medicine*, 679-692.
- Wiler, J. L. (2012). Managing emergency department crowding: perspectives from the field. *Academic Emergency Medicine*, 890-894.
- Woolhandler, S., & Campbell, T. v. (2003). Costs of Health Care Administration in the United States and Canada . *New England Journal of Medicine*, 349(8): 768–775.
- Yavuz, N. (2011). *Türkiye ve OECD Ülkelerinde Sağlık Sistemleri ve Karşılaştırılması*. Isparta: Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü İşletme Ana Bilim Dalı, Yüksek Lisans Bitirme Projesi.

- Yiğit, V. (2016). Hastanelerde Tıbbi Malzeme Talep Tahmini: Serum Seti Tüketimi Üzerinde Örnek Bir Uygulama. *Manas Sosyal Araştırmalar Dergisi*, 207-222.
- Yıldırım, A., & Şimşek, H. (2021). *Sosyal Bilimlerde Nitel Araştırma Yöntemleri*. Ankara: Seçkin Yayıncılık.
- Yılmaztürk, A. (2013). Türkiye’de Sağlık Reformlarının Tarihsel Gelişimi ve Sağlıkta Dönüşüm Programı’nın Küresel Niteliğinin Değerlendirilmesi. *Sosyal Bilimler Araştırmaları Dergisi, Cilt 1, Sayı 15*.
- Yücesoy, M. (2011). *Temizlik Kağıtları Sektöründe Yapay Sinir Ağlarıyla Talep Tahmini*. İstanbul: İstanbul Teknik Üniversitesi Fen Bilimler Enstitüsü.
- Yüksel, L., & Arıkan, M. (2018). Sağlık Sektöründe Hizmet Kalitesinin Çok Ölçütlü Karar Verme Yöntemleri ile Değerlendirilmesi: Ankara’da Bir Uygulama. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 13-30.

EKLER

EK-1. Acil Servis Hasta Sayısını Tahminlemede Kullanılan Giriş Verileri

Aylar	Doktor Sayısı	Nüfus	Erkek	Kadın	0-14 Yaş	14-65 Yaş	65 Yaş Üstü	Kişi Başına Gelir (Dolar)	Okuma Yazma Bilen Oranı (%)	UFE	TUFE	Kişi Başı Sağlık Harcaması (TL)	Kamu Sağlık Harcamaları(%)	Toplam Hasta Sayısı
1	43	265.514	135.74	129.775	76.577	173.503	15.434	6.15	90.98	5.33	8.62	1110	79	14460
2	45	265.554	135.76	129.795	76.537	173.543	15.474	6.13	91.01	4.72	8.33	1120	79	12123
3	46	265.594	135.78	129.815	76.497	173.583	15.514	6.11	91.04	4.23	8.08	1130	79	14189
4	33	265.634	135.8	129.835	76.457	173.623	15.554	6.09	91.07	3.74	7.66	1140	79	14047
5	33	265.674	135.82	129.855	76.417	173.663	15.594	6.07	91.1	3.27	7.51	1150	79	14557
6	34	265.714	135.84	129.875	76.377	173.703	15.634	5.99	91.13	3.18	7.47	1160	79	13557
7	35	265.754	135.86	129.895	76.337	173.743	15.674	6.01	91.16	3.23	7.47	1170	79	12272
8	40	265.794	135.88	129.915	76.297	173.783	15.714	6.03	91.19	3.39	7.42	1180	79	14064
9	36	265.834	135.9	129.935	76.257	173.823	15.754	6.05	91.22	3.58	7.32	1190	79	12367
10	44	265.874	135.92	129.955	76.217	173.863	15.794	5.97	91.25	3.93	7.32	1200	79	13353
11	39	265.914	135.94	129.975	76.177	173.903	15.834	5.95	91.28	4.1	7.39	1210	79	12610
12	49	265.954	135.96	129.995	76.137	173.943	15.874	5.93	91.31	4.48	7.49	1220	79	13218
13	32	266.019	135.53	130.49	75.192	174.487	16.34	5.867	91.33	5.22	7.53	1232	77	15909
14	28	266.059	135.55	130.69	75.152	174.527	16.38	5.817	91.35	6.11	7.60	1241	77	12171
15	30	266.099	135.57	130.89	75.112	174.567	16.42	5.767	91.37	6.95	7.70	1250	77	14613
16	28	266.139	135.59	131.09	75.072	174.607	16.46	5.867	91.39	7.89	7.97	1259	77	14221
17	28	266.179	135.61	131.29	75.032	174.647	16.5	5.627	91.41	8.66	8.23	1268	77	15171
18	29	266.219	135.63	131.49	74.992	174.687	16.54	5.472	91.43	9.03	8.31	1277	77	15703
19	35	266.259	135.65	131.69	74.952	174.727	16.58	5.563	91.45	9.26	8.35	1286	77	14178
20	46	266.299	135.67	131.89	74.912	174.767	16.62	5.434	91.47	9.55	8.46	1295	77	14974
21	47	266.339	135.69	132.09	74.872	174.807	16.66	5.344	91.49	9.84	8.54	1304	77	13642
22	40	266.379	135.71	132.29	74.832	174.847	16.7	5.26	91.51	10.11	8.65	1313	77	15522
23	32	266.419	135.73	132.49	74.792	174.887	16.74	5.42	91.53	10.32	8.80	1322	77	15497
24	28	266.459	135.75	132.69	74.752	174.927	16.78	5.31	91.55	10.25	8.85	1331	77	17248
25	23	267.184	136.6	130.583	74.213	175.731	17.24	5.21	91.58	9.59	8.80	1345	79	14974
26	13	267.264	136.64	130.623	74.203	175.801	17.26	5.25	91.62	8.79	8.77	1359	79	14241
27	15	267.344	136.68	130.663	74.193	175.871	17.28	5.31	91.66	8.03	8.70	1373	79	19257
28	25	267.424	136.72	130.703	74.183	175.941	17.3	5.33	91.7	7.36	8.57	1387	79	17682

29	18	267.50 4	136.76	130.74 3	74.17 3	176.01 1	17.32	5.39	91.7 4	6.98	8.45	140 1	79	1613 2
30	19	267.58 4	136.8	130.78 3	74.16 3	176.08 1	17.34	5.43	91.7 8	6.74	8.28	141 5	79	1431 0
31	22	267.66 4	136.84	130.82 3	74.15 3	176.15 1	17.36	5.41	91.8 2	6.43	8.07	142 9	79	1626 6
32	21	267.74 4	136.88	130.86 3	74.14 3	176.22 1	17.38	5.5	91.8 6	6.14	7.88	144 3	79	1406 7
33	28	267.82 4	136.92	130.90 3	74.13 3	176.29 1	17.4	5.55	91.9	5.92	7.80	145 7	79	1403 4
34	21	267.90 4	136.96	130.94 3	74.12 3	176.36 1	17.42	5.53	91.9 4	5.58	7.69	147 1	79	1628 8
35	22	267.98 4	137	130.98 3	74.11 3	176.43 1	17.44	5.61	91.9 8	5.33	7.61	148 5	79	1588 8
36	26	268.06 4	137.04	131.02 3	74.10 3	176.50 1	17.46	5.67	92.0 2	5.28	7.67	149 9	79	1643 5
37	30	269.56	137.59	131.97 2	74.12 4	177.94 2	17.49 4	5.80 9	92.2 9	5.5	7.87	152 4	79	2763 2
38	24	269.86	137.69	132.17 2	74.17 4	178.14 2	17.54 4	5.78	92.3 4	5.61	7.97	154 4	79	1269 6
39	19	270.16	137.79	132.37 2	74.22 4	178.34 2	17.59 4	5.66	92.3 9	5.64	7.96	156 4	79	1458 7
40	21	270.46	137.89	132.57 2	74.27 4	178.54 2	17.64 4	5.8	92.4 4	5.47	7.84	158 4	79	1422 3
41	19	270.76	137.99	132.77 2	74.32 4	178.74 2	17.69 4	5.5	92.4 9	5.19	7.71	160 4	79	1528 3
42	23	271.06	138.09	132.97 2	74.37 4	178.94 2	17.74 4	5.1	92.5 4	4.91	7.74	162 4	79	1326 2
43	18	271.36	138.19	133.17 2	74.42 4	179.14 2	17.79 4	5.7	92.5 9	4.77	7.91	164 4	79	3069 8
44	19	271.66	138.29	133.37 2	74.47 4	179.34 2	17.84 4	5.80 2	92.6 4	4.51	7.98	166 4	79	2123 5
45	22	271.96	138.39	133.57 2	74.52 4	179.54 2	17.89 4	5.71	92.6 9	4.07	7.92	168 4	79	1590 4
46	25	272.26	138.49	133.77 2	74.57 4	179.74 2	17.94 4	5.6	92.7 4	3.83	7.89	170 4	79	1652 3
47	23	272.56	138.59	133.97 2	74.62 4	179.94 2	17.99 4	5.54	92.7 9	3.93	7.79	172 4	79	1475 3
48	20	272.86	138.69	134.17 2	74.67 4	180.14 2	18.04 4	5.53	92.8 4	4.3	7.78	174 4	79	1620 3
49	22	273.35 4	139.18	134.17 2	74.52 4	180.96 2	17.86 8	5.53 5	93.0 1	4.96	7.76	175 1	78	1582 8
50	24	273.95 4	139.48	134.47 2	74.54 4	181.40 2	18.00 8	5.52 3	93.0 5	5.87	7.88	177 5	78	1435 5
51	21	274.55 4	139.78	134.77 2	74.56 4	181.84 2	18.14 8	5.51 1	93.0 9	6.89	8.21	179 9	78	2077 5
52	22	275.15 4	140.08	135.07 2	74.58 4	182.28 2	18.28 8	5.49 9	93.1 3	8.01	8.66	182 3	78	1950 8
53	19	275.75 4	140.38	135.37 2	74.60 4	182.72 2	18.42 8	5.48 7	93.1 7	9.02	9.09	184 7	78	1896 1
54	16	276.35 4	140.68	135.67 2	74.62 4	183.16 2	18.56 8	5.47 5	93.2 1	9.98	9.36	187 1	78	1445 3
55	20	276.95 4	140.98	135.97 2	74.64 4	183.60 2	18.70 8	5.46 3	93.2 5	10.9 4	9.44	189 5	78	1708 8
56	18	277.55 4	141.28	136.27 2	74.66 4	184.04 2	18.84 8	5.45 1	93.2 9	12.0 5	9.66	191 9	78	1904 3
57	37	278.15 4	141.58	136.57 2	74.68 4	184.48 2	18.98 8	5.43 9	93.3 3	13.2 6	9.98	194 3	78	1681 6
58	37	278.75 4	141.88	136.87 2	74.70 4	184.92 2	19.12 8	5.42 7	93.3 7	14.4 7	10.3 7	196 7	78	1723 4
59	40	279.35 4	142.18	137.17 2	74.72 4	185.36 2	19.26 8	5.41 5	93.4 1	15.3 8	10.8 7	199 1	78	1512 7
60	29	279.95 4	142.48	137.47 2	74.74 4	185.80 2	19.40 8	5.40 3	93.4 5	15.8 2	11.1 4	201 5	78	1634 5
61	25	281.20 5	143.52	137.68 1	75.70 3	186.74 5	18.75 7	4.92 8	93.5 5	15.6 6	11.2 3	203 0	78	1585 0
62	26	281.10 5	143.47	137.63 1	75.68 3	186.73 5	18.88 7	4.8	93.6 1	15.5	11.2 3	206 5	78	1623 8
63	24	281.00 5	143.42	137.58 1	75.66 3	186.72 5	19.01 7	4.9	93.6 7	15.3 5	11.1 4	210 0	78	1885 3
64	24	280.90 5	143.37	137.53 1	75.64 3	186.71 5	19.14 7	4.72	93.7 3	15.3 6	11.0 6	213 5	78	1722 9

65	23	280.80 5	143.32	137.48 1	75.62 3	186.70 5	19.27 7	4.6	93.7 9	15.8	11.1 0	217 0	78	1723 6
66	23	280.70 5	143.27	137.43 1	75.60 3	186.69 5	19.40 7	4.7	93.8 5	16.5 7	11.4 9	220 5	78	1734 5
67	24	280.60 5	143.22	137.38 1	75.58 3	186.68 5	19.53 7	4.9	93.9 1	17.4 1	12.0 0	224 0	78	1921 9
68	24	280.50 5	143.17	137.33 1	75.56 3	186.67 5	19.66 7	4.92 8	93.9 7	18.7 8	12.6 1	227 5	78	2152 6
69	23	280.40 5	143.12	137.28 1	75.54 3	186.66 5	19.79 7	4.74	94.0 3	21.3 6	13.7 5	231 0	78	1768 1
70	35	280.30 5	143.07	137.23 1	75.52 3	186.65 5	19.92 7	4.91	94.0 9	23.7 3	14.9 0	234 5	78	1802 5
71	34	280.20 5	143.02	137.18 1	75.50 3	186.64 5	20.05 7	4.88	94.1 5	25.5 2	15.6 3	238 0	78	1841 6
72	27	280.10 5	142.97	137.13 1	75.48 3	186.63 5	20.18 7	4.81	94.2 1	27.0 1	16.3 3	241 5	78	1915 2
73	30	279.81 2	141.82	137.99 4	74.84 4	185.6	19.36 8	4.80 4	94.4 2	28.7	17.1 6	243 4	78	1989 9
74	28	279.91 2	141.87	138.04 4	74.86 4	185.67	19.37 8	4.76 4	94.4 4	29.9 7	17.9 3	248 4	78	1706 0
75	31	280.01 2	141.92	138.09 4	74.88 4	185.74	19.38 8	4.78 4	94.4 6	31.1 7	18.7 0	253 0	78	1960 6
76	33	280.11 2	141.97	138.14 4	74.90 4	185.81	19.39 8	4.72 4	94.4 8	32.2 4	19.3 9	258 4	78	1909 4
77	34	280.21 2	142.02	138.19 4	74.92 4	185.88	19.40 8	4.74 4	94.5	32.8 5	19.9 1	263 4	78	1829 8
78	25	280.31 2	142.07	138.24 4	74.94 4	185.95	19.41 8	4.70 2	94.5 2	32.8 1	19.8 8	268 4	78	2009 2
79	29	280.41 2	142.12	138.29 4	74.96 4	186.02	19.42 8	4.64 4	94.5 4	32.2 4	19.1 1	273 4	78	1930 8
80	26	280.51 2	142.17	138.34 4	74.98 4	186.09	19.43 8	4.66 4	94.5 6	30.5 1	19.6 2	278 4	78	2040 6
81	28	280.61 2	142.22	138.39 4	75.00 4	186.16	19.44 8	4.68 2	94.5 8	26.4 4	18.2 7	283 4	78	1922 6
82	50	280.71 2	142.27	138.44 4	75.02 4	186.23	19.45 8	4.62 4	94.6	22.5 8	16.8 1	288 4	78	1904 8
83	48	280.81 2	142.32	138.49 4	75.04 4	186.3	19.46 8	4.60 6	94.6 2	19.6 8	15.8 7	293 4	78	1768 3
84	36	280.91 2	142.37	138.54 4	75.06 4	186.37	19.47 8	4.58 8	94.6 4	17.5 6	15.1 8	298 4	78	2168 9
85	37	281.76 8	142.67	139.09 8	74.57 5	186.58 9	20.60 4	4.67 9	94.7 3	15.7 1	14.5 2	299 7	79	2387 5
86	39	281.86 8	142.72	139.14 8	74.56 5	186.64 9	20.65 4	4.67	94.7 5	14.1 8	13.9 4	309 7	79	1595 8
87	32	281.96 8	142.77	139.19 8	74.55 5	186.70 9	20.70 4	4.66 1	94.7 7	12.6 1	13.3 3	319 7	79	1422 6
88	48	282.06 8	142.82	139.24 8	74.54 5	186.76 9	20.75 4	4.65 2	94.7 9	10.8 7	12.6 6	329 7	79	5704
89	47	282.16 8	142.87	139.29 8	74.53 5	186.82 9	20.80 4	4.64 3	94.8 1	9.14	12.1 0	339 7	79	7824
90	39	282.26 8	142.92	139.34 8	74.52 5	186.88 9	20.85 4	4.63 4	94.8 3	7.74	11.8 8	349 7	79	1074 0
91	43	282.36 8	142.97	139.39 8	74.51 5	186.94 9	20.90 4	4.52 5	94.8 5	6.81	11.5 1	359 7	79	1219 1
92	50	282.46 8	143.02	139.44 8	74.50 5	187.00 9	20.95 4	4.61 6	94.8 7	6.71	11.2 7	369 7	79	1684 5
93	45	282.56 8	143.07	139.49 8	74.49 5	187.06 9	21.00 4	4.60 7	94.8 9	7.71	11.4 7	379 7	79	1532 0
94	53	282.66 8	143.12	139.54 8	74.48 5	187.12 9	21.05 4	4.69 8	94.9 1	9.11	11.7 4	389 7	79	1470 9
95	43	282.76 8	143.17	139.59 8	74.47 5	187.18 9	21.10 4	4.61 9	94.9 3	10.6 9	12.0 4	399 7	79	1830 5
96	44	282.86 8	143.22	139.64 8	74.46 5	187.24 9	21.15 4	4.68	94.9 4	10.6 9	12.2 8	409 7	79	1258 4
97	47	283.11 2	143.05	140.06 3	73.82 1	187.71 8	21.57 3	4.77 1	94.9 4	13.6 4	12.5 3	420 6	79	1031 0
98	46	283.08 2	143.03	140.05 3	73.72 1	187.75 8	21.60 3	4.76 8	94.9 6	15.1 4	12.8 1	445 6	79	1088 1
99	37	283.05 2	143.01	140.04 3	73.62 1	187.79 8	21.63 3	4.76 5	94.9 8	17.0 4	13.1 8	470 6	79	1522 1
100	43	283.02 2	142.99	140.03 3	73.52 1	187.83 8	21.66 3	4.76 2	95	19.4 4	13.7 0	495 6	79	1843 1

101	42	282.99 2	142.97	140.02 3	73.42 1	187.87 8	21.69 3	4.75	95.0 2	22.2 4	14.1 3	520 6	79	1631 0
102	41	282.96 2	142.95	140.01 3	73.32 1	187.91 8	21.72 3	4.75 3	95.0 4	25.3 8	14.5 5	545 6	79	1761 3
103	37	282.93 2	142.93	140.00 3	73.22 1	187.95 8	21.75 3	4.74 2	95.0 6	28.4 7	15.1 5	570 6	79	2437 0
104	32	282.90 2	142.91	139.99 3	73.12 1	187.99 8	21.78 3	4.75	95.0 8	31.3 4	15.7 8	595 6	79	2938 3
105	44	282.87 2	142.89	139.98 3	73.02 1	188.03 8	21.81 3	4.76	95.1	33.8 3	16.4 2	620 6	79	2240 5
106	49	282.84 2	142.87	139.97 3	72.92 1	188.07 8	21.84 3	4.74 4	95.1 2	36.2	17.0 9	645 6	79	2146 4
107	46	282.81 2	142.85	139.96 3	72.82 1	188.11 8	21.87 3	4.75 6	95.1 4	38.9 4	17.7 1	670 6	79	2640 0
108	42	282.78 2	142.83	139.95 3	72.72 1	188.15 8	21.90 3	4.73 8	95.1 6	43.8 6	19.6 0	695 6	79	1942 7
109	32	282.55 6	142.51	140.04 5	72.23	188.18 4	22.14 2	4.74 2	95.1	49.9 3	22.5 8	714 1	76	2270 6
110	30	282.75 6	142.61	140.14 5	72.21	188.32 4	22.22 2	4.73 2	95.1	56.8 3	25.9 8	714 1	76	1445 0
111	28	282.95 6	142.71	140.24 5	72.19	188.46 4	22.30 2	4.72 6	95.1	64.3	29.8 8	719 1	76	1669 5
112	28	283.15 6	142.81	140.34 5	72.17	188.60 4	22.38 2	4.71 2	95.1	72.0 3	34.4 6	724 1	76	1424 6
113	29	283.35 6	142.91	140.44 5	72.15	188.74 4	22.46 2	4.70 2	95.1	80.3 8	39.3 3	729 1	76	1855 2
114	34	283.55 6	143.01	140.54 5	72.13	188.88 4	22.54 2	4.69 2	95.1	88.7 7	44.5 4	734 1	76	1687 1
115	38	283.75 6	143.11	140.64 5	72.11	189.02 4	22.62 2	4.68 6	95.1	97.3	49.6 5	739 1	76	2449 8
116	40	283.95 6	143.21	140.74 5	72.09	189.16 4	22.70 2	4.67 2	95.1	105. 4	54.6 9	744 1	76	1981 5
117	36	284.15 6	143.31	140.84 5	72.07	189.30 4	22.78 2	4.73	95.1	114	59.9 1	749 1	76	1616 2
118	44	284.35 6	143.41	140.94 5	72.05	189.44 4	22.86 2	4.65 2	95.1	122. 9	65.2 6	754 1	76	1952 5
119	38	284.55 6	143.51	141.04 5	72.03	189.58 4	22.94 2	4.64 2	95.1	128. 9	70.3 6	759 1	76	1975 4
120	36	284.75 6	143.61	141.14 5	72.01	189.72 4	23.02 2	4.63 2	95.1	128. 5	72.3 1	764 1	76	2328 8
121	29	285.65 5	144.01	141.64 1	71.31 9	191.22 9	23.10 7	5.54	95.3 4	125. 5	72.4 5	812 0	77	2428 1
122	30	285.75 5	144.06	141.69 1	71.33 9	191.27 9	23.13 7	5.32	95.3 4	120. 7	71.8 3	814 4	77	1294 8
123	32	285.85 5	144.11	141.74 1	71.35 9	191.32 9	23.16 7	5.4	95.3 4	113. 7	70.2 0	816 8	77	1904 0
124	30	285.95 5	144.16	141.79 1	71.37 9	191.37 9	23.19 7	5.6	95.3 4	105. 5	67.2 0	819 2	77	1788 9
125	28	286.05 5	144.21	141.84 1	71.39 9	191.42 9	23.22 7	5.7	95.3 4	95.8	63.7 2	821 6	77	2106 3
126	36	286.15 5	144.26	141.89 1	71.41 9	191.47 9	23.25 7	5.62	95.3 4	86.5 9	59.9 5	824 0	77	2053 6
127	34	286.25 5	144.31	141.94 1	71.43 9	191.52 9	23.28 7	5.5	95.3 4	78.5 1	57.4 5	826 4	77	2264 3
128	38	286.35 5	144.36	141.99 1	71.45 9	191.57 9	23.31 7	5.73	95.3 4	71.9 7	56.2 8	828 8	77	2200 7
129	33	286.45 5	144.41	142.04 1	71.47 9	191.62 9	23.34 7	5.77	95.3 4	65.5 5	55.3 0	831 2	77	2119 1
130	42	286.55 5	144.46	142.09 1	71.49 9	191.67 9	23.37 7	5.75	95.3 4	58.4 6	54.2 6	833 6	77	2229 8
131	40	286.65 5	144.51	142.14 1	71.51 9	191.72 9	23.40 7	5.69	95.3 4	53.1 5	53.4 0	836 0	77	1944 1
132	38	286.75 5	144.56 4	142.19 1	71.53 9	191.77 9	23.43 7	5.71	95.3 4	49.9	53.8 6	838 4	77.2	2302 6

EK-2. Hasta Sayılarının Tahmininde Kullanılan Verilerin Normalizasyonu

Aylar	Doktor Sayısı	Nüfus	erkek	kadın	0-14 Yaş	14-65 Yaş	65 Yaş Üstü,	Kişi Başına Gelir (Dolar)	Okuma Yazma Bilen oranı (%)	UFE	TUFE	Kişi Başı Sağlık Harcaması(tl)	Kamu Sağlık Harcamaları(%)
1	0.75	0	0.023243	0	1	0	0	1	0	0.017096	0.01996	0	0.75
2	0.8	0.001883	0.025457	0.001611	0.992393	0.002189	0.004998	0.987692	0.006881	0.012246	0.015507	0.001375	0.75
3	0.825	0.003766	0.02767	0.003222	0.984785	0.004377	0.009996	0.975385	0.013761	0.008349	0.011669	0.00275	0.75
4	0.5	0.005649	0.029884	0.004832	0.977178	0.006566	0.014994	0.963077	0.020642	0.004453	0.00522	0.004124	0.75
5	0.5	0.007533	0.032097	0.006443	0.96957	0.008755	0.019993	0.950769	0.027523	0.000716	0.002917	0.005499	0.75
6	0.525	0.009416	0.034311	0.008054	0.961963	0.010943	0.024991	0.901538	0.034404	0	0.002303	0.006874	0.75
7	0.55	0.011299	0.036525	0.009665	0.954355	0.013132	0.029989	0.913846	0.041284	0.000398	0.002303	0.008249	0.75
8	0.675	0.013182	0.038738	0.011276	0.946748	0.015321	0.034987	0.926154	0.048165	0.00167	0.001535	0.009623	0.75
9	0.575	0.015065	0.040952	0.012887	0.93914	0.017509	0.039985	0.938462	0.055046	0.003181	0	0.010998	0.75
10	0.775	0.016948	0.043165	0.014497	0.931533	0.019698	0.044983	0.889231	0.061927	0.005964	0	0.012373	0.75
11	0.65	0.018832	0.045379	0.016108	0.923925	0.021887	0.049981	0.876923	0.068807	0.007316	0.001075	0.013748	0.75
12	0.9	0.020715	0.047593	0.017719	0.916318	0.024075	0.054979	0.864615	0.075688	0.010337	0.00261	0.015122	0.75
13	0.475	0.023775	0	0.057587	0.736592	0.053841	0.113208	0.825846	0.080275	0.016221	0.003224	0.016772	0.357143
14	0.375	0.025658	0.002214	0.073695	0.728984	0.05603	0.118206	0.795077	0.084862	0.023298	0.004299	0.018009	0.357143
15	0.425	0.027541	0.004427	0.089803	0.721377	0.058218	0.123204	0.764308	0.08945	0.029978	0.005834	0.019247	0.357143
16	0.375	0.029424	0.006641	0.105912	0.713769	0.060407	0.128202	0.825846	0.094037	0.037452	0.00998	0.020484	0.357143
17	0.375	0.031307	0.008854	0.12202	0.706162	0.062596	0.1332	0.678154	0.098624	0.043575	0.013972	0.021721	0.357143
18	0.4	0.033191	0.011068	0.138128	0.698555	0.064784	0.138198	0.582769	0.103211	0.046517	0.0152	0.022958	0.357143
19	0.55	0.035074	0.013282	0.154236	0.690947	0.066973	0.143196	0.638769	0.107798	0.048346	0.015815	0.024196	0.357143
20	0.825	0.036957	0.015495	0.170345	0.68334	0.069162	0.148194	0.559385	0.112385	0.050652	0.017503	0.025433	0.357143
21	0.85	0.03884	0.017709	0.186453	0.675732	0.07135	0.153193	0.504	0.116972	0.052958	0.018732	0.02667	0.357143
22	0.675	0.040723	0.019923	0.202561	0.668125	0.073539	0.158191	0.452308	0.12156	0.055105	0.020421	0.027908	0.357143
23	0.475	0.042606	0.022136	0.218669	0.660517	0.075728	0.163189	0.550769	0.126147	0.056775	0.022724	0.029145	0.357143
24	0.375	0.044489	0.02435	0.234778	0.65291	0.077916	0.168187	0.483077	0.130734	0.056218	0.023491	0.030382	0.357143
25	0.25	0.078622	0.11865	0.065077	0.550399	0.121909	0.225665	0.421538	0.137615	0.05097	0.022724	0.032307	0.75
26	0	0.082388	0.123077	0.068299	0.548498	0.125739	0.228164	0.446154	0.146789	0.044609	0.022263	0.034232	0.75
27	0.05	0.086154	0.127504	0.071521	0.546596	0.129569	0.230664	0.483077	0.155963	0.038566	0.021188	0.036156	0.75

28	0.3	0.089 92	0.1319 31	0.0747 42	0.5446 94	0.1333 99	0.2331 63	0.4953 85	0.1651 38	0.0332 38	0.0191 92	0.0380 81	0.75
29	0.12 5	0.093 687	0.1363 59	0.0779 64	0.5427 92	0.1372 29	0.2356 62	0.5323 08	0.1743 12	0.0302 16	0.0173 5	0.0400 05	0.75
30	0.15	0.097 453	0.1407 86	0.0811 86	0.5408 9	0.1410 59	0.2381 61	0.5569 23	0.1834 86	0.0283 08	0.0147 4	0.0419 3	0.75
31	0.22 5	0.101 219	0.1452 13	0.0844 07	0.5389 88	0.1448 89	0.2406 6	0.5446 15	0.1926 61	0.0258 43	0.0115 15	0.0438 55	0.75
32	0.2	0.104 986	0.1496 4	0.0876 29	0.5370 86	0.1487 2	0.2431 59	0.6	0.2018 35	0.0235 37	0.0085 98	0.0457 79	0.75
33	0.37 5	0.108 752	0.1540 68	0.0908 51	0.5351 84	0.1525 5	0.2456 58	0.6307 69	0.2110 09	0.0217 88	0.0073 7	0.0477 04	0.75
34	0.2	0.112 518	0.1584 95	0.0940 72	0.5332 83	0.1563 8	0.2481 57	0.6184 62	0.2201 83	0.0190 84	0.0056 81	0.0496 29	0.75
35	0.22 5	0.116 285	0.1629 22	0.0972 94	0.5313 81	0.1602 1	0.2506 56	0.6676 92	0.2293 58	0.0170 96	0.0044 53	0.0515 53	0.75
36	0.32 5	0.120 051	0.1673 49	0.1005 15	0.5294 79	0.1640 4	0.2531 55	0.7046 15	0.2385 32	0.0166 98	0.0053 74	0.0534 78	0.75
37	0.42 5	0.190 481	0.2278 92	0.1769 49	0.5334 73	0.2428 87	0.2574 03	0.7901 54	0.3004 59	0.0184 48	0.0084 45	0.0569 15	0.75
38	0.27 5	0.204 604	0.2389 6	0.1930 57	0.5429 82	0.2538 3	0.2636 51	0.7723 08	0.3119 27	0.0193 23	0.0099 8	0.0596 65	0.75
39	0.15	0.218 728	0.2500 28	0.2091 66	0.5524 91	0.2647 73	0.2698 99	0.6984 62	0.3233 94	0.0195 61	0.0098 27	0.0624 14	0.75
40	0.2	0.232 852	0.2610 96	0.2252 74	0.5620 01	0.2757 17	0.2761 46	0.7846 15	0.3348 62	0.0182 09	0.0079 84	0.0651 64	0.75
41	0.15	0.246 975	0.2721 64	0.2413 82	0.5715 1	0.2866 6	0.2823 94	0.6	0.3463 3	0.0159 83	0.0059 88	0.0679 13	0.75
42	0.25	0.261 099	0.2832 32	0.2574 9	0.5810 19	0.2976 03	0.2886 42	0.3538 46	0.3577 98	0.0137 56	0.0064 49	0.0706 63	0.75
43	0.12 5	0.275 222	0.2943	0.2735 99	0.5905 29	0.3085 47	0.2948 89	0.7230 77	0.3692 66	0.0126 43	0.0090 59	0.0734 12	0.75
44	0.15	0.289 346	0.3053 68	0.2897 07	0.6000 38	0.3194 9	0.3011 37	0.7858 46	0.3807 34	0.0105 76	0.0101 34	0.0761 62	0.75
45	0.22 5	0.303 47	0.3164 36	0.3058 15	0.6095 47	0.3304 33	0.3073 85	0.7292 31	0.3922 02	0.0070 77	0.0092 12	0.0789 11	0.75
46	0.3	0.317 593	0.3275 04	0.3219 23	0.6190 57	0.3413 77	0.3136 32	0.6615 38	0.4036 7	0.0051 69	0.0087 52	0.0816 61	0.75
47	0.25	0.331 717	0.3385 72	0.3380 32	0.6285 66	0.3523 2	0.3198 8	0.6246 15	0.4151 38	0.0059 64	0.0072 16	0.0844 1	0.75
48	0.17 5	0.345 841	0.3496 4	0.3541 4	0.6380 75	0.3632 63	0.3261 28	0.6184 62	0.4266 06	0.0089 06	0.0070 63	0.0871 6	0.75
49	0.22 5	0.369 098	0.4043 17	0.3541 4	0.6095 47	0.4081 31	0.3041 36	0.6215 38	0.4655 96	0.0141 54	0.0067 56	0.0881 22	0.5714 29
50	0.27 5	0.397 345	0.4375 21	0.3783 02	0.6133 51	0.4322 06	0.3216 29	0.6141 54	0.4747 71	0.0213 9	0.0085 98	0.0914 22	0.5714 29
51	0.2	0.425 592	0.4707 25	0.4024 65	0.6171 55	0.4562 81	0.3391 23	0.6067 69	0.4839 45	0.0295 01	0.0136 65	0.0947 21	0.5714 29
52	0.22 5	0.453 839	0.5039 29	0.4266 27	0.6209 59	0.4803 57	0.3566 16	0.5993 85	0.4931 19	0.0384 06	0.0205 74	0.0980 2	0.5714 29
53	0.15	0.482 087	0.5371 33	0.4507 89	0.6247 62	0.5044 32	0.3741 1	0.592	0.5022 94	0.0464 38	0.0271 76	0.1013 2	0.5714 29
54	0.07 5	0.510 334	0.5703 38	0.4749 52	0.6285 66	0.5285 07	0.3916 03	0.5846 15	0.5114 68	0.0540 71	0.0313 22	0.1046 19	0.5714 29
55	0.17 5	0.538 581	0.6035 42	0.4991 14	0.6323 7	0.5525 83	0.4090 97	0.5772 31	0.5206 42	0.0617 05	0.0325 5	0.1079 19	0.5714 29
56	0.12 5	0.566 828	0.6367 46	0.5232 76	0.6361 73	0.5766 58	0.4265 9	0.5698 46	0.5298 17	0.0705 31	0.0359 28	0.1112 18	0.5714 29
57	0.6	0.595 076	0.6699 5	0.5474 39	0.6399 77	0.6007 33	0.4440 83	0.5624 62	0.5389 91	0.0801 53	0.0408 41	0.1145 17	0.5714 29
58	0.6	0.623 323	0.7031 54	0.5716 01	0.6437 81	0.6248 08	0.4615 77	0.5550 77	0.5481 65	0.0897 74	0.0468 29	0.1178 17	0.5714 29
59	0.67 5	0.651 57	0.7363 59	0.5957 64	0.6475 85	0.6488 84	0.4790 7	0.5476 92	0.5573 39	0.0970 1	0.0545 06	0.1211 16	0.5714 29
60	0.4	0.679 817	0.7695 63	0.6199 26	0.6513 88	0.6729 59	0.4965 64	0.5403 08	0.5665 14	0.1005 09	0.0586 52	0.1244 16	0.5714 29
61	0.3	0.738 713	0.8848 92	0.6367 59	0.8337 77	0.7245 57	0.4152 19	0.248	0.5894 5	0.0992 37	0.0600 34	0.1264 78	0.3928 57

62	0.32 5	0.734 005	0.8793 58	0.6327 32	0.8299 73	0.7240 1	0.4314 63	0.1692 31	0.6032 11	0.0979 64	0.0600 34	0.1312 9	0.3928 57
63	0.27 5	0.729 297	0.8738 24	0.6287 05	0.8261 7	0.7234 62	0.4477 07	0.2307 69	0.6169 72	0.0967 72	0.0586 52	0.1361 01	0.3928 57
64	0.27 5	0.724 589	0.8682 9	0.6246 78	0.8223 66	0.7229 15	0.4639 51	0.12 34	0.6307 34	0.0968 51	0.0574 24	0.1409 13	0.3928 57
65	0.25	0.719 881	0.8627 56	0.6206 51	0.8185 62	0.7223 68	0.4801 95	0.0461 54	0.6444 95	0.1003 5	0.0580 38	0.1457 24	0.3928 57
66	0.25	0.715 173	0.8572 22	0.6166 24	0.8147 58	0.7218 21	0.4964 39	0.1076 92	0.6582 57	0.1064 73	0.0640 26	0.1505 36	0.3928 57
67	0.27 5	0.710 466	0.8516 88	0.6125 97	0.8109 55	0.7212 74	0.5126 83	0.2307 69	0.6720 18	0.1131 52	0.0718 56	0.1553 48	0.3928 57
68	0.27 5	0.705 758	0.8461 54	0.6085 7	0.8071 51	0.7207 27	0.5289 27	0.248	0.6857 8	0.1240 46	0.0812 22	0.1601 59	0.3928 57
69	0.25	0.701 05	0.8406 2	0.6045 43	0.8033 47	0.7201 79	0.5451 71	0.1323 08	0.6995 41	0.1445 61	0.0987 26	0.1649 71	0.3928 57
70	0.55	0.696 342	0.8350 86	0.6005 15	0.7995 44	0.7196 32	0.5614 14	0.2369 23	0.7133 03	0.1634 06	0.1163 83	0.1697 83	0.3928 57
71	0.52 5	0.691 634	0.8295 52	0.5964 88	0.7957 4	0.7190 85	0.5776 58	0.2184 62	0.7270 64	0.1776 4	0.1275 91	0.1745 94	0.3928 57
72	0.35	0.686 926	0.8240 18	0.5924 61	0.7919 36	0.7185 38	0.5939 02	0.1753 85	0.7408 26	0.1894 88	0.1383 39	0.1794 06	0.3928 57
73	0.42 5	0.673 132	0.6960 71	0.6619 68	0.6704 07	0.6619 06	0.4915 66	0.1716 92	0.7889 91	0.2029 26	0.1510 82	0.1820 18	0.5714 29
74	0.37 5	0.677 84	0.7016 05	0.6659 95	0.6742 11	0.6657 36	0.4928 15	0.1470 77	0.7935 78	0.2130 25	0.1629 05	0.1888 92	0.5714 29
75	0.45	0.682 548	0.7071 39	0.6700 23	0.6780 14	0.6695 67	0.4940 65	0.1593 85	0.7981 65	0.2225 67	0.1747 27	0.1957 66	0.5714 29
76	0.5	0.687 256	0.7126 73	0.6740 5	0.6818 18	0.6733 97	0.4953 14	0.1224 62	0.8027 52	0.2310 75	0.1853 22	0.2026 4	0.5714 29
77	0.52 5	0.691 964	0.7182 07	0.6780 77	0.6856 22	0.6772 27	0.4965 64	0.1347 69	0.8073 39	0.2359 26	0.1933 06	0.2095 13	0.5714 29
78	0.3	0.696 672	0.7237 41	0.6821 04	0.6894 26	0.6810 57	0.4978 13	0.1089 23	0.8119 27	0.2356 08	0.1928 45	0.2163 87	0.5714 29
79	0.4	0.701 379	0.7292 75	0.6861 31	0.6932 29	0.6848 87	0.4990 63	0.0732 31	0.8165 14	0.2310 75	0.1810 23	0.2232 61	0.5714 29
80	0.32 5	0.706 087	0.7348 09	0.6901 58	0.6970 33	0.6887 17	0.5003 12	0.0855 38	0.8211 01	0.2173 19	0.1888 53	0.2301 35	0.5714 29
81	0.37 5	0.710 795	0.7403 43	0.6941 85	0.7008 37	0.6925 48	0.5015 62	0.0966 15	0.8256 88	0.1849 55	0.1681 25	0.2370 09	0.5714 29
82	0.92 5	0.715 503	0.7458 77	0.6982 12	0.7046 41	0.6963 78	0.5028 11	0.0609 23	0.8302 75	0.1542 62	0.1457 09	0.2438 82	0.5714 29
83	0.87 5	0.720 211	0.7514 11	0.7022 39	0.7084 44	0.7002 08	0.5040 61	0.0498 46	0.8348 62	0.1312 02	0.1312 76	0.2507 56	0.5714 29
84	0.57 5	0.724 919	0.7569 45	0.7062 66	0.7122 48	0.7040 38	0.5053 11	0.0387 69	0.8394 5	0.1143 45	0.1206 82	0.2576 3	0.5714 29
85	0.6	0.765 218	0.7903 71	0.7508 86	0.6192 47	0.7160 21	0.6460 08	0.0947 69	0.8600 92	0.0996 34	0.1105 48	0.2594 17	1
86	0.65	0.769 926	0.7959 05	0.7549 13	0.6173 45	0.7193 04	0.6522 55	0.0892 31	0.8646 79	0.0874 68	0.1016 43	0.2731 65	1
87	0.47 5	0.774 634	0.8014 39	0.7589 4	0.6154 43	0.7225 87	0.6585 03	0.0836 92	0.8692 66	0.0749 84	0.0922 77	0.2869 12	1
88	0.87 5	0.779 342	0.8069 73	0.7629 67	0.6135 41	0.7258 7	0.6647 51	0.0781 54	0.8738 53	0.0611 48	0.0819 9	0.3006 6	1
89	0.85	0.784 05	0.8125 07	0.7669 94	0.6116 39	0.7291 53	0.6709 98	0.0726 15	0.8784 4	0.0473 92	0.0733 92	0.3144 07	1
90	0.65	0.788 758	0.8180 41	0.7710 21	0.6097 38	0.7324 36	0.6772 46	0.0670 77	0.8830 28	0.0362 6	0.0700 14	0.3281 55	1
91	0.75	0.793 465	0.8235 75	0.7750 48	0.6078 36	0.7357 19	0.6834 94	0	0.8876 15	0.0288 65	0.0643 33	0.3419 03	1
92	0.92 5	0.798 173	0.8291 09	0.7790 75	0.6059 34	0.7390 02	0.6897 41	0.056	0.8922 02	0.0280 69	0.0606 48	0.3556 5	1
93	0.8	0.802 881	0.8346 43	0.7831 02	0.6040 32	0.7422 85	0.6959 89	0.0504 62	0.8967 89	0.0360 21	0.0637 19	0.3693 98	1
94	1	0.807 589	0.8401 77	0.7871 3	0.6021 3	0.7455 68	0.7022 37	0.1064 62	0.9013 76	0.0471 53	0.0678 64	0.3831 45	1
95	0.75	0.812 297	0.8457 11	0.7911 57	0.6002 28	0.7488 51	0.7084 84	0.0578 46	0.9059 63	0.0597 17	0.0724 7	0.3968 93	1

96	0.77 5	0.817 005	0.8512 45	0.7951 84	0.5983 26	0.7521 34	0.7147 32	0.0953 85	0.9082 57	0.0597 17	0.0761 55	0.4106 41	1
97	0.85 492	0.828 19	0.8323 19	0.8286 08	0.4758 46	0.7777 96	0.7670 87	0.1513 85	0.9082 57	0.0831 74	0.0799 94	0.4256 26	0.9642 86
98	0.82 5	0.827 08	0.8301 05	0.8278 03	0.4568 28	0.7799 85	0.7708 36	0.1495 38	0.9128 44	0.0951 02	0.0842 93	0.4599 95	0.9642 86
99	0.6 667	0.825 92	0.8278 92	0.8269 97	0.4378 09	0.7821 73	0.7745 85	0.1476 92	0.9174 31	0.1102 1	0.0899 74	0.4943 63	0.9642 86
100	0.75 255	0.824 78	0.8256 78	0.8261 92	0.4187 9	0.7843 62	0.7783 33	0.1458 46	0.9220 18	0.1292 94	0.0979 58	0.5287 32	0.9642 86
101	0.72 5	0.822 843	0.8234 64	0.8253 87	0.3997 72	0.7865 51	0.7820 82	0.1384 62	0.9266 06	0.1515 59	0.1045 6	0.5631 01	0.9642 86
102	0.7 43	0.821 51	0.8212 51	0.8245 81	0.3807 53	0.7887 39	0.7858 3	0.1403 08	0.9311 93	0.1765 27	0.1110 09	0.5974 7	0.9642 86
103	0.6 018	0.820 37	0.8190 37	0.8237 76	0.3617 34	0.7909 28	0.7895 79	0.1335 38	0.9357 8	0.2010 97	0.1202 21	0.6318 39	0.9642 86
104	0.47 5	0.818 606	0.8168 23	0.8229 7	0.3427 16	0.7931 17	0.7933 28	0.1384 62	0.9403 67	0.2239 19	0.1298 94	0.6662 08	0.9642 86
105	0.77 5	0.817 193	0.8146 1	0.8221 65	0.3236 97	0.7953 05	0.7970 76	0.1446 15	0.9449 54	0.2437 18	0.1397 21	0.7005 77	0.9642 86
106	0.9 781	0.815 96	0.8123 96	0.8213 6	0.3046 79	0.7974 94	0.8008 25	0.1347 69	0.9495 41	0.2625 64	0.1500 08	0.7349 46	0.9642 86
107	0.82 5	0.814 368	0.8101 83	0.8205 54	0.2856 6	0.7996 83	0.8045 73	0.1421 54	0.9541 28	0.2843 51	0.1595 27	0.7693 15	0.9642 86
108	0.72 5	0.812 956	0.8079 69	0.8197 49	0.2666 41	0.8018 71	0.8083 22	0.1310 77	0.9587 16	0.3234 73	0.1885 46	0.8036 84	0.9642 86
109	0.47 5	0.802 316	0.7727 73	0.8271 59	0.1732 6	0.8032 94	0.8381 86	0.1335 38	0.9449 54	0.3717 4	0.2343 01	0.8291 17	0
110	0.42 5	0.811 732	0.7838 41	0.8352 13	0.1694 56	0.8109 54	0.8481 82	0.1273 85	0.9449 54	0.4266 06	0.2865 04	0.8291 17	0
111	0.37 5	0.821 148	0.7949 09	0.8432 67	0.1656 52	0.8186 15	0.8581 78	0.1236 92	0.9449 54	0.4860 05	0.3463 84	0.8359 91	0
112	0.37 5	0.830 564	0.8059 77	0.8513 21	0.1618 49	0.8262 75	0.8681 74	0.1150 77	0.9449 54	0.5474 71	0.4167 05	0.8428 65	0
113	0.4 979	0.839 45	0.8170 45	0.8593 75	0.1580 45	0.8339 35	0.8781 71	0.1089 23	0.9449 54	0.6138 68	0.4914 79	0.8497 39	0
114	0.52 5	0.849 395	0.8281 13	0.8674 29	0.1542 41	0.8415 96	0.8881 67	0.1027 69	0.9449 54	0.6805 82	0.5714 72	0.8566 13	0
115	0.62 5	0.858 811	0.8391 81	0.8754 83	0.1504 37	0.8492 56	0.8981 63	0.0990 77	0.9449 54	0.7484 1	0.6499 31	0.8634 86	0
116	0.67 5	0.868 227	0.8502 49	0.8835 37	0.1466 34	0.8569 16	0.9081 59	0.0904 62	0.9449 54	0.8127 39	0.7273 15	0.8703 6	0
117	0.57 5	0.877 642	0.8613 17	0.8915 91	0.1428 3	0.8645 76	0.9181 56	0.1261 54	0.9449 54	0.8813 61	0.8074 62	0.8772 34	0
118	0.77 5	0.887 058	0.8723 85	0.8996 46	0.1390 26	0.8722 37	0.9281 52	0.0781 54	0.9449 54	0.9522 11	0.8896 05	0.8841 08	0
119	0.62 5	0.896 474	0.8834 53	0.9077 23	0.1352 23	0.8798 97	0.9381 48	0.072 0.072	0.9449 54	0.9679 1	0.8909 82	0	0
120	0.57 5	0.905 89	0.8945 21	0.9157 54	0.1314 19	0.8875 57	0.9481 44	0.0658 46	0.9449 54	0.9962 63	0.9978 5	0.8978 55	0
121	0.4 213	0.948 26	0.9391 26	0.9557 02	0 0	0.9699 06	0.9587 65	0.6246 15	0.9728 85	0.9637 1	0.9637 06	0.2857 14	0
122	0.42 5	0.952 921	0.9446 6	0.9597 29	0.0038 04	0.9726 42	0.9625 14	0.4892 31	0.9346 1	0.9904 37	0.9670 81	0.2857 14	0
123	0.47 5	0.957 629	0.9501 94	0.9637 56	0.0076 07	0.9753 78	0.9662 63	0.5384 62	0.8790 1	0.9654 55	0.9703 05	0.2857 14	0
124	0.42 5	0.962 337	0.9557 28	0.9677 84	0.0114 11	0.9781 13	0.9700 11	0.6615 38	0.8136 1	0.9193 13	0.9736 92	0.2857 14	0
125	0.37 5	0.967 045	0.9612 62	0.9718 11	0.0152 15	0.9808 49	0.9737 6	0.7230 77	0.7364 1	0.8659 82	0.9769 6	0.2857 14	0
126	0.57 5	0.971 753	0.9667 96	0.9758 38	0.0190 19	0.9835 85	0.9775 08	0.6738 46	0.6632 1	0.8080 47	0.9802 76	0.2857 14	0
127	0.52 5	0.976 461	0.9723 3	0.9798 65	0.0228 22	0.9863 21	0.9812 57	0.6 0.6	0.5989 1	0.7696 91	0.9835 03	0.2857 14	0
128	0.62 5	0.981 168	0.9778 64	0.9838 92	0.0266 26	0.9890 57	0.9850 06	0.7415 38	0.5469 1	0.7517 94	0.9868 27	0.2857 14	0
129	0.5 876	0.985 876	0.9833 98	0.9879 19	0.0304 3	0.9917 93	0.9887 54	0.7661 54	0.4959 1	0.7366 45	0.9901 8	0.2857 14	0

130	0.72 5	0.990 584	0.9889 32	0.9919 46	0.0342 34	0.9945 28	0.9925 03	0.7538 46	1	0.4395 67	0.7207 12	0.9934 01	0.2857 14
131	0.67 5	0.995 292	0.9944 66	0.9959 73	0.0380 37	0.9972 64	0.9962 51	0.7169 23	1	0.3973 44	0.7075 08	0.9967 01	0.2857 14
132	0.62 5	1	1	1	0.0418 41	1	1	0.7292 31	1	0.3715 01	0.7145 71	1	0.2857 14

EK-3. Doğrusal Regresyon Oranları

Aylar	Normalize	Hasta Sayısı	Hata Oranı	Hata Farkı	Tahmin Değeri
1	0.350324	14460	4.9163179	710.899563	13749.10044
2	0.256822	12123	-17.52431	-2124.4715	14247.4715
3	0.339481	14189	11.014073	1562.78678	12626.21322
4	0.3338	14047	-13.80517	-1939.2125	15986.21251
5	0.354205	14557	14.50412	2111.36478	12445.63522
6	0.314195	13557	0.7310945	99.1144793	13457.88552
7	0.262783	12272	-6.355244	-779.91555	13051.91555
8	0.33448	14064	2.2367085	314.570683	13749.42932
9	0.266584	12367	-1.605677	-198.57402	12565.57402
10	0.306033	13353	-2.310125	-308.47099	13661.47099
11	0.276306	12610	-4.442681	-560.22204	13170.22204
12	0.300632	13218	-4.51947	-597.38358	13815.38358
13	0.408298	15909	1.7413177	277.026239	15631.97376
14	0.258742	12171	-10.86254	-1322.0795	13493.07947
15	0.356446	14613	1.437254	210.025923	14402.97408
16	0.340762	14221	3.0712175	436.75784	13784.24216
17	0.378771	15171	0.1413528	21.4446396	15149.55536
18	0.400056	15703	-0.183007	-28.73764	15731.73764
19	0.339041	14178	-3.266042	-463.05939	14641.05939
20	0.370889	14974	1.2241927	183.310617	14790.68938
21	0.317596	13642	-5.577505	-760.8833	14402.8833
22	0.392814	15522	-0.578815	-89.843612	15611.84361
23	0.391814	15497	-0.932528	-144.5138	15641.5138
24	0.461871	17248	2.2717339	391.828666	16856.17133
25	0.370889	14974	-4.445941	-665.73525	15639.73525
26	0.341562	14241	-10.59821	-1509.2915	15750.29151
27	0.54225	19257	11.62404	2238.44145	17018.55855
28	0.479235	17682	4.905743	867.43348	16814.56652
29	0.41722	16132	2.2559673	363.932645	15768.06735
30	0.344323	14310	-5.561649	-795.872	15105.872
31	0.422581	16266	6.4138216	1043.27222	15222.72778
32	0.3346	14067	-23.45503	-3299.4189	17366.41894
33	0.33328	14034	-7.199218	-1010.3383	15044.33829
34	0.423462	16288	21.661806	3528.27502	12759.72498
35	0.407458	15888	-3.491415	-554.71599	16442.71599
36	0.429343	16435	1.2072288	198.408061	16236.59194

37	0.877331	27632	22.154718	6121.79181	21510.20819
38	0.279747	12696	-9.204955	-1168.6611	13864.66114
39	0.355405	14587	-9.310538	-1358.1281	15945.12811
40	0.340842	14223	-5.615665	-798.71608	15021.71608
41	0.383252	15283	-6.165109	-942.21357	16225.21357
42	0.302393	13262	-5.965948	-791.20401	14053.20401
43	1	30698	37.253	11435.9261	19262.07391
44	0.621389	21235	-5.501239	-1168.1881	22403.18811
45	0.408098	15904	-4.984049	-792.66319	16696.66319
46	0.432864	16523	2.7829542	459.827529	16063.17247
47	0.362047	14753	-4.409462	-650.52794	15403.52794
48	0.420061	16203	-2.417091	-391.64131	16594.64131
49	0.405057	15828	-1.992926	-315.44038	16143.44038
50	0.346123	14355	-7.784421	-1117.4537	15472.4537
51	0.602985	20775	9.5758106	1989.37465	18785.62535
52	0.552293	19508	0.9216935	179.80396	19328.19604
53	0.530407	18961	4.0463009	767.219115	18193.78089
54	0.350044	14453	-9.024584	-1304.3231	15757.32315
55	0.455469	17088	-3.573612	-610.65875	17698.65875
56	0.533688	19043	6.1140798	1164.30421	17878.69579
57	0.444587	16816	-1.347974	-226.6753	17042.6753
58	0.461311	17234	2.7138325	467.701888	16766.29811
59	0.37701	15127	-4.581078	-692.97969	15819.97969
60	0.425742	16345	-2.356302	-385.13757	16730.13757
61	0.405937	15850	-8.47113	-1342.6741	17192.6741
62	0.421461	16238	-2.74389	-445.55294	16683.55294
63	0.526086	18853	9.5151322	1793.88788	17059.11212
64	0.461111	17229	-0.215606	-37.146709	17266.14671
65	0.461391	17236	-0.644598	-111.10285	17347.10285
66	0.465752	17345	-0.27421	-47.561805	17392.5618
67	0.54073	19219	-14.12738	-2715.1409	21934.14092
68	0.633032	21526	18.576617	3998.80266	17527.19734
69	0.479195	17681	-2.255162	-398.73528	18079.73528
70	0.492958	18025	-0.890471	-160.50748	18185.50748
71	0.508602	18416	1.0195412	187.758715	18228.24128
72	0.538049	19152	0.9755426	186.835914	18965.16409
73	0.567936	19899	6.4480526	1283.09798	18615.90202
74	0.454349	17060	-8.448085	-1441.2432	18501.24322
75	0.556213	19606	-0.155111	-30.411046	19636.41105
76	0.535729	19094	2.9917222	571.239446	18522.76055
77	0.503881	18298	-3.888546	-711.52608	19009.52608
78	0.575658	20092	2.1262084	427.197794	19664.80221
79	0.544291	19308	0.8350736	161.236002	19146.764
80	0.588221	20406	3.6404348	742.867129	19663.13287
81	0.54101	19226	-0.118693	-22.819955	19248.81995

82	0.533888	19048	4.1035214	781.63876	18266.36124
83	0.479275	17683	-1.965574	-347.57247	18030.57247
84	0.639553	21689	6.8397706	1483.47784	20205.52216
85	0.727014	23875	23.217371	5543.14726	18331.85274
86	0.410258	15958	-7.888495	-1258.846	17216.84597
87	0.340962	14226	-8.622266	-1226.6035	15452.60352
88	0	5704	-21.82845	-1245.0951	6949.09507
89	0.08482	7824	-2.279831	-178.37396	8002.373964
90	0.201488	10740	-12.87764	-1383.0586	12123.05859
91	0.259542	12191	-10.57301	-1288.9551	13479.95513
92	0.445747	16845	12.148934	2046.4879	14798.5121
93	0.384732	15320	8.2427602	1262.79086	14057.20914
94	0.360286	14709	-3.092316	-454.84877	15163.84877
95	0.504161	18305	23.223321	4251.02897	14053.97103
96	0.275266	12584	-19.05406	-2397.7627	14981.76268
97	0.184284	10310	-6.169054	-636.02951	10946.02951
98	0.20713	10881	-7.997369	-870.19369	11751.19369
99	0.380771	15221	-6.897888	-1049.9275	16270.92747
100	0.509202	18431	11.339197	2089.92731	16341.07269
101	0.424342	16310	-9.705901	-1583.0324	17893.03242
102	0.476474	17613	-1.149714	-202.49909	17815.49909
103	0.746819	24370	8.332325	2030.5876	22339.4124
104	0.947387	29383	17.784407	5225.59234	24157.40766
105	0.6682	22405	2.4771567	555.006964	21849.99304
106	0.630551	21464	-0.020344	-4.3665483	21468.36655
107	0.828039	26400	14.191649	3746.59524	22653.40476
108	0.549052	19427	-4.534993	-881.01314	20308.01314
109	0.680243	22706	12.653354	2873.07057	19832.92943
110	0.349924	14450	-12.15639	-1756.598	16206.59804
111	0.439746	16695	2.8476368	475.412965	16219.58703
112	0.341762	14246	-8.877081	-1264.6289	15510.62892
113	0.514043	18552	3.9186572	726.98928	17825.01072
114	0.446787	16871	-5.593527	-943.68401	17814.68401
115	0.75194	24498	12.457413	3051.81704	21446.18296
116	0.564575	19815	-0.72529	-143.71631	19958.71631
117	0.41842	16162	-6.597538	-1066.2941	17228.29412
118	0.552973	19525	1.3335915	260.383739	19264.61626
119	0.562135	19754	-3.866504	-763.78917	20517.78917
120	0.703529	23288	10.948182	2549.61271	20738.38729
121	0.743258	24281	13.792407	3348.93425	20932.06575
122	0.28983	12948	-15.90583	-2059.4867	15007.48674
123	0.533568	19040	4.204835	800.600586	18239.39941
124	0.487517	17889	-4.79106	-857.07278	18746.07278
125	0.614507	21063	4.0161095	845.913136	20217.08686
126	0.593422	20536	-0.513526	-105.45776	20641.45776

127	0.677723	22643	5.146362	1165.29075	21477.70925
128	0.652277	22007	2.6078169	573.902262	21433.09774
129	0.619629	21191	1.0609781	224.831879	20966.16812
130	0.663919	22298	6.6879022	1491.26842	20806.73158
131	0.549612	19441	-9.331756	-1814.1866	21255.18661
132	0.693046	23026	9.5734492	2204.38241	20821.61759

EK-4. Doğrusal Regresyon Yönteminde Kullanılan Kodlar

```
function [trainedModel, validationRMSE] =
trainRegressionModel(trainingData)
% [trainedModel, validationRMSE] =
trainRegressionModel(trainingData)
% Returns a trained regression model and its RMSE. This
code recreates the
% model trained in Regression Learner app. Use the
generated code to
% automate training the same model with new data, or to
learn how to
% programmatically train models.
%
% Input:
%   trainingData: A matrix with the same number of
columns and data type
%   as the matrix imported into the app.
%
% Output:
%   trainedModel: A struct containing the trained
regression model. The
%   struct contains various fields with information
about the trained
%   model.
%
%   trainedModel.predictFcn: A function to make
predictions on new data.
%
%   validationRMSE: A double containing the RMSE. In
the app, the
%   History list displays the RMSE for each model.
%
% Use the code to train the model with new data. To
retrain your model,
% call the function from the command line with your
original data or new
% data as the input argument trainingData.
%
% For example, to retrain a regression model trained with
the original data
```

```

% set T, enter:
% [trainedModel, validationRMSE] =
trainRegressionModel(T)
%
% To make predictions with the returned 'trainedModel' on
new data T2, use
% yfit = trainedModel.predictFcn(T2)
%
% T2 must be a matrix containing only the predictor
columns used for
% training. For details, enter:
% trainedModel.HowToPredict

% Auto-generated by MATLAB on 09-Jul-2024 19:26:21

% Extract predictors and response
% This code processes the data into the right shape for
training the
% model.
% Convert input to table
inputTable = array2table(trainingData, 'VariableNames',
{'column_1', 'column_2', 'column_3', 'column_4',
'column_5', 'column_6', 'column_7', 'column_8',
'column_9', 'column_10', 'column_11', 'column_12',
'column_13', 'column_14'});

predictorNames = {'column_1', 'column_2', 'column_3',
'column_4', 'column_5', 'column_6', 'column_7',
'column_8', 'column_9', 'column_10', 'column_11',
'column_12', 'column_13'};
predictors = inputTable(:, predictorNames);
response = inputTable.column_14;
isCategoricalPredictor = [false, false, false, false,
false, false, false, false, false, false, false, false,
false];

% Train a regression model
% This code specifies all the model options and trains
the model.
concatenatedPredictorsAndResponse = predictors;
concatenatedPredictorsAndResponse.column_14 = response;
linearModel = fitlm(...
    concatenatedPredictorsAndResponse, ...
    'linear', ...
    'RobustOpts', 'off');

% Create the result struct with predict function
predictorExtractionFcn = @(x) array2table(x,
'VariableNames', predictorNames);

```

```

linearModelPredictFcn = @(x) predict(linearModel, x);
trainedModel.predictFcn = @(x)
linearModelPredictFcn(predictorExtractionFcn(x));

% Add additional fields to the result struct
trainedModel.LinearModel = linearModel;
trainedModel.About = 'This struct is a trained model
exported from Regression Learner R2020b.';
trainedModel.HowToPredict = sprintf('To make predictions
on a new predictor column matrix, X, use: \n yfit =
c.predictFcn(X) \nreplacing ''c'' with the name of the
variable that is this struct, e.g. ''trainedModel''. \n
\nX must contain exactly 13 columns because this model
was trained using 13 predictors. \nX must contain only
predictor columns in exactly the same order and format as
your training \ndata. Do not include the response column
or any columns you did not import into the app. \n \nFor
more information, see <a
href="matlab:helpview(fullfile(docroot, ''stats'',
''stats.map''),
''appregression_exportmodeltoworkspace'')">How to predict
using an exported model</a>.'');

% Extract predictors and response
% This code processes the data into the right shape for
training the
% model.
% Convert input to table
inputTable = array2table(trainingData, 'VariableNames',
{'column_1', 'column_2', 'column_3', 'column_4',
'column_5', 'column_6', 'column_7', 'column_8',
'column_9', 'column_10', 'column_11', 'column_12',
'column_13', 'column_14'});

predictorNames = {'column_1', 'column_2', 'column_3',
'column_4', 'column_5', 'column_6', 'column_7',
'column_8', 'column_9', 'column_10', 'column_11',
'column_12', 'column_13'};
predictors = inputTable(:, predictorNames);
response = inputTable.column_14;
isCategoricalPredictor = [false, false, false, false,
false, false, false, false, false, false, false, false,
false];

% Perform cross-validation
KFolds = 5;
cvp = cvpartition(size(response, 1), 'KFold', KFolds);
% Initialize the predictions to the proper sizes
validationPredictions = response;
for fold = 1:KFolds

```

```

        trainingPredictors = predictors(cvp.training(fold),
:);
        trainingResponse = response(cvp.training(fold), :);
        foldIsCategoricalPredictor = isCategoricalPredictor;

        % Train a regression model
        % This code specifies all the model options and
        trains the model.
        concatenatedPredictorsAndResponse =
trainingPredictors;
        concatenatedPredictorsAndResponse.column_14 =
trainingResponse;
        linearModel = fitlm(...
            concatenatedPredictorsAndResponse, ...
            'linear', ...
            'RobustOpts', 'off');

        % Create the result struct with predict function
        linearModelPredictFcn = @(x) predict(linearModel, x);
        validationPredictFcn = @(x) linearModelPredictFcn(x);

        % Add additional fields to the result struct

        % Compute validation predictions
        validationPredictors = predictors(cvp.test(fold), :);
        foldPredictions =
validationPredictFcn(validationPredictors);

        % Store predictions in the original order
        validationPredictions(cvp.test(fold), :) =
foldPredictions;
    end

    % Compute validation RMSE
    isNotMissing = ~isnan(validationPredictions) &
~isnan(response);
    validationRMSE = sqrt(nansum(( validationPredictions -
response ).^2) / numel(response(isNotMissing) ));

```

EK-5. YSA Tahmin Yönteminde Kullanılan Kodlar

```

function [Y,Xf,Af] = myNeuralNetworkFunction(X,~,~)
%MYNEURALNETWORKFUNCTION neural network simulation
function.

%
% Auto-generated by MATLAB, 09-Jul-2024 21:18:37.
%

```

```

% [Y] = myNeuralNetworkFunction(X,~,~) takes these
arguments:
%
%   X = 1xTS cell, 1 inputs over TS timesteps
%   Each X{1,ts} = Qx13 matrix, input #1 at timestep ts.
%
% and returns:
%   Y = 1xTS cell of 1 outputs over TS timesteps.
%   Each Y{1,ts} = Qx1 matrix, output #1 at timestep ts.
%
% where Q is number of samples (or series) and TS is the
number of timesteps.

%#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [0;0;0;0;0;0;0;0;0;0;0;0;0;0];
x1_step1.gain = [2;2;2;2;2;2;2;2;2;2;2;2;2;2];
x1_step1.ymin = -1;

% Layer 1
b1 = [1.880171053308314022;1.4117855833454999726;-
1.0515512539044875595;-0.60158955920705381448;-
0.27719375018720809889;-0.35064526100358212046;-
0.44886457460325457358;1.0383920982264629451;-
1.5278437470527257425;1.6808418419098920538];
IW1_1 = [-0.31980737307050755014 0.51386679714794258889
0.67129154650737510313 -0.084614272219503336436
0.11655596043069928192 -0.17317572927903560065
0.26464191162291572645 0.35276478909652042582
0.001624806722885528687 0.95625982794769615047
0.71439984631757502687 -0.062228805462720720998 -
0.33031228662284334296;-0.48732152104517906244 -
0.12802515799278096909 0.43641588131721092969
0.33079375389518927975 -0.24784627443288476112 -
0.13576221369291130436 -0.45962718443332395424
0.22800535382604172896 -0.35505246156151604175
0.80156519314389340636 -0.68636043952645109378
0.43976673693167583901 -0.80639864830060625778;-
0.066089314495737197519 -0.44805329907071822504 -
0.031110252597379341871 -0.092439612166612186717
0.1929328273862911669 -0.48818680267577230225
0.2095268606236581066 -0.72480078670053948997 -
0.20789446543202591555 1.1352850909448122252 -
0.23712284372877828753 0.31913210657393814573
0.20047965925435604073;0.2328272935554306089
0.61121584580599763736 -0.18355946066400910532 -
0.29636490175367569133 -0.3267698472918714736

```

```

0.29791874765295894845 -0.4916584896048705744
0.58110985877371612585 -0.28534126955244298873 -
0.69942367402424632239 -0.4237636686203826164 -
0.40442923857326934511 -
0.71300339373633692119;0.13265110066996199656 -
0.70472082413440273463 -0.67912474723684901345 -
0.12681007282023815108 -0.46371392150615992067
0.62699077452528018117 -0.34004262084445613379 -
0.42711230172712605357 0.63047236551378926794 -
0.57841236944087237593 0.32856909572134640474
0.091669597787079934448 0.89476812895013146942;-
0.07771865143765332995 0.28122366866800962981
0.56098824957973958405 -0.15617735690243322866 -
0.14697824964907849066 0.29766143111910697838 -
0.71140167081631922041 -0.2598520906110165507 -
0.86146006609639902418 0.36835643084516433987
0.5047701871031322618 0.036204605447948526309
0.18951496501665743288;-0.48500352943421809471
0.5337265031969687934 -0.77055153039230672718 -
0.48131281303195289079 0.33620187443100102431
0.15189264745883915286 -0.27847229750131530235
0.266820640157744704 0.26353038194787803405 -
0.74407251224820736279 0.31192437555209096001 -
0.79686257632301593645 -
0.14895920431097278702;0.73256951052456442675 -
0.085219774904478920452 -0.64429474184326762654 -
0.079591153730605379568 0.15240802902641642502
0.419065073375579078 -0.64612724135067911568
0.80493517329276753625 -0.26231603346893511697
0.35473823477864319109 0.64518380145841935924
0.39495058776298980208 -0.4287745311556032668;-
0.29400937040317243198 -0.044359288343291627954 -
0.27418588710840113842 -0.35249427174779995875 -
0.58688426976574714633 0.37833281126296730568 -
0.16077703693942818619 0.54097800135021600898 -
0.32583900794942077805 0.69002045442838388922
0.40181869105153056321 -0.48749228220495099961 -
0.73466325938320664601;0.37336350324714545623 -
0.59000642539006498133 -0.80476939377631817596
0.48888798023048646302 -0.79276832007057662643
0.054285294828041306958 -0.57658629482215262296
0.1212610069444254729 0.13156226937224191342 -
0.5307479619483880251 0.52710002936861100054
0.45150374811405868947 -0.049112829637265882632];

```

```

% Layer 2

```

```

b2 = -0.33708515356200857704;
LW2_1 = [0.84264795579173001894 0.68209394762361763576
0.2042740568469924578 -0.10536324766294971611
0.86356574458030810337 -0.50343847304518241081

```

```

0.13973135851761148141 0.46959224176955172148
0.17519589211266778372 -0.59765203714021419845];

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 2;
y1_step1.xoffset = 0;

% ===== SIMULATION =====

% Format Input Arguments
isCellX = iscell(X);
if ~isCellX
    X = {X};
end

% Dimensions
TS = size(X,2); % timesteps
if ~isempty(X)
    Q = size(X{1},1); % samples/series
else
    Q = 0;
end

% Allocate Outputs
Y = cell(1,TS);

% Time loop
for ts=1:TS

    % Input 1
    X{1,ts} = X{1,ts}';
    Xp1 = mapminmax_apply(X{1,ts},x1_step1);

    % Layer 1
    a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*Xp1);

    % Layer 2
    a2 = repmat(b2,1,Q) + LW2_1*a1;

    % Output 1
    Y{1,ts} = mapminmax_reverse(a2,y1_step1);
    Y{1,ts} = Y{1,ts}';
end

% Final Delay States
Xf = cell(1,0);
Af = cell(2,0);

% Format Output Arguments

```

```

if ~isCellX
    Y = cell2mat(Y);
end
end

% ===== MODULE FUNCTIONS =====

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
y = bsxfun(@minus,x,settings.xoffset);
y = bsxfun(@times,y,settings.gain);
y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing
Function
function x = mapminmax_reverse(y,settings)
x = bsxfun(@minus,y,settings.ymin);
x = bsxfun(@rdivide,x,settings.gain);
x = bsxfun(@plus,x,settings.xoffset);
end

```