



T.C.  
İSTANBUL MEDİPOL ÜNİVERSİTESİ  
SOSYAL BİLİMLER ENSTİTÜSÜ  
DOKTORA TEZİ

**SAĞLIK HİZMETLERİNDE YAPAY ZEKA UYGULAMALARI:  
YOĞUN BAKIM ÖRNEĞİ**

ZEHRA NUR CANBOLAT GÖÇMEN

YÖNETİM VE STRATEJİ DOKTORA PROGRAMI

DANIŞMAN

Prof. Dr. Gökhan SİLAHTAROĞLU

İSTANBUL- 2022

## BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar tüm safhalarında etik dışı olabilecek bir davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar çerçevesinde elde ettiğimi, bu tez çalışması ile elde edilmeyen tüm bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynakçaya aldığımı, yine bu tez çalışmasında ve yazım sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

Zehra Nur CANBOLAT GÖÇMEN

## ÖNSÖZ

Akademik yolculuğumun başından beri bilgi ve tecrübelerinden faydalandığım ve doktora eğitimim boyunca bilimsel yaratıcılığı ile çalışmalarımı destekleyen değerli danışmanım Sayın Prof. Dr. Gökhan SİLAHTAROĞLU'na teşekkür ederim.

Akademik süreçte bilimsel katkı ve önerileriyle yolumu aydınlatan ve cesaretlendiren büyük saygı duyduğum Sayın Prof. Dr. Nihat ALAYOĞLU'na teşekkürlerimi sunarım.

Mesleki tecrübeleri ile tezime bilimsel katkılarını sunan ve tez konusunun mutfağında gerekli eğitimleri almamı sağlayan, yoğun bakım ünitesindeki süreçleri yerinde görme imkanı sağlayan Bağcılar Medipol Mega Üniversite Hastanesi Anestezi ve Reanimasyon Hekimi Doç. Dr. Kadir İDİN'e teşekkürlerimi sunarım. İstanbul Medipol Üniversitesi İşletme ve Yönetim Bilimleri Fakültesindeki hocalarıma desteklerini esirgemedikleri için teşekkür ederim. Eğitimim boyunca problemlere beraber çözüm bulmayı amaçladığımız Pusula Kurumsal İş Çözümleri Yazılım Danışmanlık Şirketindeki çalışma arkadaşlarıma teşekkür ederim.

Doktora tez çalışmam sürecinde bana hem bilimsel araştırma açısından hem manevi açıdan destek olan Doç. Dr. Rabia Meryem YILMAZ'a, Dr. Fatih PINARBAŞI'na, Araş.Görv. Mehmet Hulusi EKREN'e ve Araş. Görv. Emine GÜNDOĞMUŞ'a teşekkür ederim. Daimi motivasyon kaynaklarım, Hicran ERTUĞRAL ve Tuğçe ÇETİNKAYA'ya desteklerinden ötürü teşekkür ederim.

Çalışmalarım süresince desteklerini benden esirgemeyen ve büyük fedakarlık gösteren sevgili eşime, babam Prof. Dr. Mustafa CANBOLAT'a, anneme ve kardeşime sonsuz teşekkürlerimi sunuyorum.

# İÇİNDEKİLER

ÖNSÖZ .....	ii
İÇİNDEKİLER.....	iii
KISALTMALAR LİSTESİ.....	v
ŞEKİLLER LİSTESİ .....	vii
TABLolar LİSTESİ.....	ix
ÖZET .....	x
ABSTRACT .....	xi
GİRİŞ .....	1
I. BÖLÜM .....	4
BİLİŞİM SİSTEMLERİ VE KARAR VERME.....	4
1.1. Bilişim Sistemlerinin Türleri.....	8
1.2. Karar Destek Sistemlerinin Gelişimi ve Kullanım Alanları .....	13
1.3. Klinik Karar Destek Sistemleri .....	18
1.3.1. Klinik Karar Destek Sistemleri Türleri.....	20
II. BÖLÜM.....	23
YAPAY ZEKA VE MAKİNE ÖĞRENMESİ.....	23
2.1. Yapay Zeka .....	23
2.2. Makine Öğrenmesi.....	27
2.2.1. Regresyon.....	35
2.2.2. Sınıflandırma .....	36
2.2.3. Kümeleme .....	38
2.3. Derin Öğrenme .....	41
2.4. Sağlıkta Yapay Zeka ve Makine Öğrenmesi Uygulamaları.....	46
2.5. Veri Ambarı ve OLAP .....	54
2.5.1. Veri Ön İşlemleri.....	57
2.5.2. Dengesiz Veri Setleri.....	64
III. BÖLÜM.....	68
YAPAY ZEKA İLE DÖNÜŞEN SAĞLIK YÖNETİMİ VE KARAR VERME.....	68
3.1. Yönetim ve Stratejik Yönetim.....	68
3.1.1. Stratejik Yönetim Alanındaki Yaklaşımlar .....	71
3.1.1.1. Pozisyon Okulu Yaklaşımı.....	72
3.1.1.2. Kaynaklara Dayalı Yaklaşım .....	74

3.2.	Sağlık Hizmetlerinde Stratejik Yönetim ve Önemi .....	85
3.3.	Sağlık Hizmetlerinde Karar Verme .....	88
3.4.	Sağlık Sektöründe Dijitalleşme ve Dönüşüm.....	91
3.5.	Sağlık Hizmetlerinde Yapay Zeka Uygulamaları.....	98
IV.	BÖLÜM.....	105
	YOĞUN BAKIM ÜNİTELERİNDE SEPSİS ENFEKSİYONU VE YAPAY ZEKA ALGORİTMALARI İLE MODELLENMESİ .....	105
4.1.	Sepsis Enfeksiyonu ve Önemi .....	105
4.1.1.	Sepsis Enfeksiyonunda Geleneksel Skorum Sistemleri .....	107
4.2.	Sepsis Enfeksiyonu Tanısında Yapay Zeka Algoritmalarının Kullanımı ..	110
4.3.	Tezin Genel Kapsamı.....	114
4.3.1.	Tez Kapsamında Kullanılan Veri Seti .....	115
4.3.2.	Veri Ambarının Hazırlanması ve Modelde Kullanılan Değişkenler ..	116
4.3.2.1.	Veri Ön İşlemleri .....	118
4.4.	Uygulama1: Denetimsiz Öğrenme: Bulanık C- Ortalamalar Algoritması.	121
4.4.1.	Araştırmanın Amacı.....	121
4.4.2.	Denetimsiz Öğrenme Modelinde Veri Ön İşlemleri.....	122
4.5.	Bulanık C -Ortalamlar (Fuzzy C-Means) Algoritması.....	124
4.5.1.	Temel Bileşen Analizi .....	127
4.6.	Model Mimarisi ve Bulgular .....	130
4.6.1.	Sonuç .....	135
4.7.	Uygulama2: Uzun Kısa Süreli Bellek (LSTM) Algoritması ile Sepsis Enfeksiyonu Tahmini .....	137
4.7.1.	Araştırmanın Amacı.....	137
4.7.2.	Zaman Serisi Veri Ön İşlemleri.....	138
4.8.	LSTM Tabanlı Derin Öğrenme Algoritması.....	140
4.8.1.	Yapay Zeka Algoritmalarında Model Performansının Değerlendirilmesi 144	
4.9.1.	Sonuç .....	155
V.	BÖLÜM .....	159
	TARTIŞMA VE SONUÇ .....	159
	KAYNAKÇA.....	173

## KISALTMALAR LİSTESİ

ANN: Artificial Neural Network / Yapay Sinir Ağları

BS: Bilişim Sistemleri

BTG: Bilgi Temelli Görüş

DYG: Dinamik Yetenekler Görüşü

DTG: Dikkat Temelli Görüş

FCM: Bulanık C-Ortalamalar / Fuzzy C-Means

FTG: Faaliyet Temelli Görüş

HIMSS: Healthcare Information and Management Systems Society / Sağlık Bilişimi ve Yönetim Sistemleri Topluluğu

IoT: Internet of Things / Nesnelerin İnterneti

KATG: Kaynak Temelli Görüş

KDS: Karar Destek Sistemleri

KKDS: Klinik Karar Destek Sistemleri

KTG: Kurum Temelli Strateji Görüş

LSTM: Long Short-Term Memory/ Uzun Kısa Süreli Bellek

MIMIC-III: Medical Information Mart for Intensive Care

MİS: Muamele/Faaliyet İşleme Sistemleri

OLAP: Online Analytical Processing/ Çevrimiçi Analitik İşlemler

PCA: Principal Component Analysis/ Temel Bileşenler Analizi

PCI: Partition Coefficient Index/ Ayırma Katsayısı

PEI: Partition Entropy Index/ Ayrırma entropisi

ROS: Oversampling/ Aşırı Örnekleme

RUS: Undersampling/ Az Örnekleme

SMOTE: Synthetic Minority Oversampling Technique / Sentetik Azınlık Aşırı Örnekleme Tekniği

SOFA: Sequential Organ Failure Assessment Score / Ardışık Organ Yetmezliği Değerlendirme

SP: Sepsis Pozitif

SN: Sepsis Negatif

YBS: Yönetim Bilişim Sistemleri

YBÜ: Yoğun Bakım Ünitesi

YDP: Yapı-Davranış-Performans

YKDS: Yönetici Karar Destek Sistemleri

YZ: Yapay Zeka

qSOFA: quick Sequential Organ Failure Assesment / Hızlı Ardışık Organ Yetmezliği Değerlendirme

XB: Xie Beni

## ŞEKİLLER LİSTESİ

Şekil 1. WOS “information system” yıllara göre yayınların dağılımı .....	5
Şekil 2. Bilişim sistemleri gelişiminin aşamaları .....	7
Şekil 3. Bilişim sistemlerinin türleri .....	9
Şekil 4. Karar destek sistemleri ve teknolojisindeki gelişmeler.....	14
Şekil 5. Klinik karar destek bileşenleri ve çıktıları.....	19
Şekil 6. Makine öğrenmesi algoritmalarının sınıflandırılması.....	30
Şekil 7. Denetimli makine öğrenmesi süreci.....	31
Şekil 8. Denetimsiz makine öğrenmesi süreci.....	33
Şekil 9. Gözlem, ödül, eylem döngüsü .....	34
Şekil 10. Sınıflandırma modeli temsilleri .....	37
Şekil 11. Kümeleme örneği.....	38
Şekil 12. Sert ve yumuşak kümeleme .....	41
Şekil 13. Klasik yapay sinir ağ yapısı.....	42
Şekil 14. Yapay sinir ağı modeli .....	44
Şekil 15. Sağlıkta yapay zeka uygulamaları.....	48
Şekil 16. Veri ambarı ve veri martı.....	56
Şekil 17. Veri ön işlemleri.....	58
Şekil 18. Dengesiz veri sınıflandırıcı probleminin genel gösterimi .....	65
Şekil 19. Dijitalleştirme, dijitalleşme ve dijital dönüşüm kavramları .....	92
Şekil 20. Sağlık hizmetlerinde dijitalleşmenin odak alanları.....	96
Şekil 21. Sağlık sisteminin evrimi .....	97
Şekil 22. Tıpta yapay zekanın gelişimi ve kullanımının zaman çizelgesi. ....	99
Şekil 23. Sağlıkta yapay zekanın 2026 yılına kadar tahmini maliyet faydası.....	101
Şekil 24: “Yapay zeka” ve “sepsis” çalışmalarının WOS veri tabanında tarandığı yıllar .....	111
Şekil 25. MIMIC-III yoğun bakım veri tabanının genel çerçevesi.....	116
Şekil 26. Sepsisin erken teşhisinde kullanılan değişkenler .....	118
Şekil 28. Eksik verilerin giderilme süreci .....	120
Şekil 29. Eksik verilerden arındırılmış veri seti .....	121
Şekil 30. Veri ön işlemleri sonrası veri kesitinden örnek .....	123
Şekil 31. Temel bileşen analizi (PCA) projeksiyonları .....	127
Şekil 32. Hasta değerlerinin İndirgenmesi .....	131
Şekil 33. Sepsis Pozitif hastaların kümelere yerleşim yüzdeleri .....	132



Şekil 34. Sepsis Negatif hastaların kümelere yerleşim yüzdeleri.....	133
Şekil 35. Küme merkezlerinin monitörize edilmesi .....	134
Şekil 36. Değişkenler arası korelasyon ısı haritası .....	140
Şekil 37: Tahmin için LSTM Model Mimarisi.....	141
Şekil 38: LSTM algoritmasının hücre mimarisi .....	142
Şekil 39. ROC eğrisi. ....	148
Şekil 40. LSTM modeli.....	149
Şekil 41. LSTM model çıktısı .....	152
Şekil 42. Test veri seti ROC- AUC eğrisi .....	154
Şekil 43. Doğrulama veri seti ROC- AUC eğrisi .....	154



## TABLULAR LİSTESİ

Tablo 1. Kaynaklara dayalı yaklaşım görüşleri.....	75
Tablo 2. SOFA kriterleri .....	108
Tablo 3. Quick SOFA kriterleri.....	109
Tablo 4. Optimum küme sayısının belirlenmesinde kullanılan indeksler .....	127
Tablo 5. Sepsis Pozitif hastaların küme indeksleri .....	131
Tablo 6. Sepsis Negatif hastaların küme indeksleri.....	131
Tablo 7. FCM Algoritması sonucu öğrenilen küme merkezleri.....	133
Tablo 8. Karışıklık matrisi .....	145
Tablo 9. LSTM ağında eğitim parametreleri.....	153

## ÖZET

### SAĞLIK HİZMETLERİNDE YAPAY ZEKA UYGULAMALARI:

#### YOĞUN BAKIM ÖRNEĞİ

Sepsis, vücutta gelişen enfeksiyona neden olan bakterilerin kana karışması ile bağışıklık sisteminin bu bakterilere karşı büyük bir savunma göstermesi; bu nedenle vücutta organ yetmezliğinin gerçekleşmesi olarak bilinmektedir. Sepsis enfeksiyonunun erken teşhisi yapılamaz ve hızla tedaviye başlanamaz ise çoklu organ yetmezliği sonucu ölüme neden olabilmektedir. Sepsis tanısının konulması amacıyla Ardışık Organ Yetmezliği Değerlendirme (Sequential Organ Failure Assessment Score: SOFA) ve Hızlı Ardışık Organ Yetmezliği Değerlendirme (quick Sequential Organ Failure Assessment: qSOFA) skorlama sistemleri kullanılmaktadır. SOFA skorlamasının zaman alıcı olması, qSOFA'nın ise düşük performans göstermesi nedeniyle bu denli kritik bir hastalığın erken teşhisi için daha doğru klinik tahmin modellerine gereksinim duyulmaktadır. Bu tez çalışması kapsamında sepsis enfeksiyonunun gelişimini erken tahmin etmeye yönelik bir yapay zeka çalışması gerçekleştirilmiştir. Çalışmada, Beth Israel Deaconess Tıp Merkezi'nin yoğun bakım ünitelerinde kalan hastaların klinik verilerinden oluşan MIMIC-III veri tabanı kullanılmıştır. Öncelikle veriler üzerinde denetimsiz makine öğrenmesi gerçekleştirilmiştir. FCM algoritması kullanılarak gerçekleştirilen öğrenme sonunda, küme geçerlilik indeksleri dikkate alınarak optimum kümeler elde edilmiştir. Küme temsilcileri PCA yöntemi ile iki boyuta indirgenerek hekimlerin sepsis örüntüsünü takip edebileceği bir model geliştirilmiştir. Derin öğrenme algoritması LSTM kullanılarak hastanın sonraki saat içinde sepsis olup olmayacağı %82 başarı ile tahmin edilmiştir. Araştırmada gerçekleştirilen yapay zeka modelinin, kritik hastalıkların öngörülerek hekimlerin karar verme sürecine yardımcı olabileceği, sağlık merkezinin rekabet avantajı sağlayan dinamik yeteneklerini geliştirebileceği ve tüm bunlar sayesinde, sağlıkta inovatif stratejilerin geliştirilmesinde rol oynayabileceği vurgulanmıştır.

**Anahtar Kelimeler:** Sağlıkta yapay zeka, sepsis, dinamik yetenekler, karar verme.

## ABSTRACT

### **ARTIFICIAL INTELLIGENCE IN HEALTHCARE: AN IMPLEMENTATION EXAMPLE FOR INTENSIVE CARE UNITS**

Sepsis infection, which is one of the most important causes of death in intensive care services, is one of as a serious global health crisis. Sepsis infection can cause death because of multiple organ failure. Early diagnosis and rapid treatment process are crucial. Sepsis can be diagnosed along with clinical findings, laboratory results, SOFA and qSOFA scoring systems. Sophistication and time consuming of the SOFA scoring system and poor performance of the qSOFA scoring system are the main disadvantages for sepsis where early diagnosis is essential. Therefore, more accurate clinical prediction models are needed. Within the scope of the thesis, an artificial intelligence study was employed to predict sepsis infection earlier. The MIMIC-III database, which consists of detailed clinical data of patients treated in the intensive care units of Beth Israel Deaconess Medical Center, was used in the study. In the beginning of the study, unsupervised machine learning was performed using the data obtained from the patients using the FCM algorithm. Optimum clusters were obtained by considering the cluster validity indices. Cluster representatives were reduced to two dimensions with Principal Component Analysis method and a model was developed in which doctors could follow the sepsis pattern. It is predicted 82% accuracy whether the patient would have sepsis within the next hour by using the deep learning algorithm LSTM.

This research emphasizes the artificial intelligence model implemented and critical diseases can be predicted, and doctors can help the decision-making process. Therefore, health centers can improve their dynamic capabilities which provide competitive advantages. In the lights of all these advantages, artificial intelligence can play a essential role in the development of innovative strategies in health centers.

**Keywords:** Artificial intelligence in health, sepsis, dynamic capabilities, decision making.

## GİRİŞ

Dijital hizmetlerin önümüzdeki on yılda sağlık hizmetlerini dönüştürmede kritik faktörlerden biri olacağı düşünülmektedir. Sağlık bilişimi alanında artan yapay zeka uygulamaları, sağlık alanındaki potansiyel faydaları artırmaktadır. Yapay zeka, hekimlerin hastalıkları teşhis etmesine, kanser bölgelerini belirlemesine, her hasta için ilaç etkilerini belirlemesine, genotipler ve fenotipler arasındaki ilişkiyi anlamasına ve bulaşıcı hastalık salgınlarını yüksek doğrulukla tahmin etmesine yardımcı olabilmektedir (Fogel vd., 2018).

Küresel toplumlarda kronik rahatsızlık yaşayan hastaların artan prevalansı ve nüfusun yaşlanmasının sonucu, kaliteli sağlık hizmetlerine yönelik talepte artış yaşanmaktadır (Kingston vd., 2018). Konsültasyon süresi ile yapılan çalışmada daha yaşlı hastaların daha uzun konsültasyon süresine ihtiyaç duyduğu ifade edilmiştir (Bener vd., 2019). Artan yaşlı nüfus ile tedavi, muayene ve cerrahi operasyonlardaki artan talebin aksine, sağlık personelleri ve hekim sayısında ise azalma yaşanmaktadır. Sağlık personelleri hasta güvenliğine odaklanmak yerine, sürekli gelişen iş akışı gereksinimleri ve protokollerini süreçlere uygulama iş yükünü ve var olan günlük iş streslerini yaşamakta ve bu durum sağlık personelindeki memnuniyetsizliği artırmaktadır. Yapay zeka bu zorlukları giderebilecek, sağlık hizmetlerinde yeniliği hızlandırmak için katalizör görevi görebilecek potansiyele sahip güçlü bir teknolojidir. Sağlık sistemleri üzerindeki bu yüklerin, yapay zeka teknolojileri kullanılarak azaltılması, prosedürleri hızlandırarak ve daha fazla doğruluk sağlayarak hasta bakımını iyileştirmek, risk ve belirsizlik altında karar alan sağlık personelinin kararlarına yardımcı olabilmek için sağlık hizmetlerinde yapay zeka kullanımı yaygınlaşmaktadır. Sağlık hizmetleri, veri açısından zengin süreçlerle donatılmış, bilgisayar gücünün ve yapay zeka tekniklerinin gelişmesiyle birlikte büyük veriye erişilebilirlik, muazzam fırsatlar yaratmıştır (Jiang vd., 2017).

Bu tez kapsamında, hem hekimlerin karar verme etkinliği açısından hem de sağlık kurumunun yoğun bakım özelinde sürdürülebilir rekabet üstünlüğü kazanmasında kendi kaynaklarını ve yeteneklerini kullanarak yapay zeka teknolojilerinden yararlanmasına yönelik bir çalışma gerçekleştirilmesi amaçlanmıştır. Yoğun bakım

hekimlerinin belirsizlik ve risk ortamında aldığı kararları verimli kılmayı amaçlayan ve sürekli öğrenen yardımcı bir asistan gibi hekime öngörülerini sunan bir model geliştirilmiştir. Bu sayede kritik hastalık olarak nitelendirilen sepsis enfeksiyonunun hastada gelişimine erkenden müdahale edilerek ölümlerle sonuçlanmasının önüne geçilebilecektir. Yoğun bakım hastaları özelinde Bulanık C-Ortalamalar algoritması kullanılarak sepsis enfeksiyonu hastalarının oluşturduğu örüntü monitörize edilmiştir. Derin öğrenme algoritması olan Uzun Kısa Süreli Bellek (LSTM) kullanılarak hastanın önümüzdeki bir saat içinde sepsis enfeksiyonu olup olmayacağı tahmin edilmiştir. Hekim için erken uyarı sistemi amacıyla geliştirilmiş olan bu sistem, ölümlerle sonuçlanan ciddi bir enfeksiyonun önüne geçerek hekimin hastaya erken müdahale etmesini sağlayarak hastanın sağlığına geri kavuşması sağlanabilecektir. Bu durum hem hasta hayatını kurtarıırken hem de hekim için artan bir iş motivasyonu sağlayabilecektir. Aynı zamanda sağlık kurumu kendi verilerini depolama ve modelleme yönünde bir adım ileriye giderek, sürdürülebilir stratejileri kendi sahip olduğu kaynaklarla geliştirmiş olacaktır. Bu kapsamda gerçekleştirilen tez araştırması toplamda beş bölümden oluşmaktadır.

Bölüm 1’de bilişim sistemlerinin gelişimi ve bilişim sistemlerinin organizasyonlarda karar alma sürecine nasıl katkı sağladığına dair bilgilere yer verilmiştir. Ardından çalışmanın temelinde yer alan sağlık sektörü için kullanılan klinik karar destek sistemlerinin sağlık hizmeti sağlayıcılarının karar vermelerine ve karmaşık sorunları çözmeye yardımcı kullanımlarına yönelik alan yazın araştırmalarına değinilmiştir.

Bölüm 2’de uygulama metodolojisinde kullanılan yapay zeka ve makine öğrenmesi süreçleri anlatılmıştır. Makine öğrenmesi sürecinin nasıl gerçekleştiği ve sağlık alanında yapay zeka uygulamalarına yer verilmiştir. Etkili ve başarılı bir yapay zeka modelinin geliştirilebilmesi ve veriden öğrenmenin sorunsuz gerçekleşmesi, doğru kurgulanacak olan bir veri ambarı mimarisine ve bu mimaride verilere uygulanan veri ön işlemlerinden geçmektedir. Bu nedenle bölümde veri ambarı ve OLAP mimarisi vurgulanmış ve veri ön işlemleri anlatılmıştır.

Bölüm 3’te stratejik yönetim ve stratejik yönetimin alt kavramlarına değinilmiştir. Sağlıkta stratejik yönetim ve karar vermenin önemi hakkında literatür çalışmalarına yer verilmiştir. Ardından, gerçekleşen dijitalizasyon ile bu kavramlarda yaşanan dönüşüm tartışılmıştır. Dijital hastane kavramı ele alınmış ve sağlıkta güncel yapay zeka uygulamalarına yer verilmiştir.

Bölüm 4’te tez kapsamında yapılan iki farklı yapay zeka uygulaması anlatılmıştır. Sepsis hastalarının geliştirdiği örüntüyü anlamak ve hastaları gruplamak amacıyla Bulank C-Ortalamalar algoritması kullanılmıştır. Bu uygulamada KNIME platformundan (versiyon 4.4.2) yararlanılmıştır. Bu hastaların çizmiş olduğu örüntünün görselleştirerek, takip edilmesi amacıyla kümeler iki boyuta indirgenmiş bunun için PCA algoritması kullanılmıştır. Bu uygulama sayesinde hekim, hastaların anlık verilerini monitörde izleyerek, hastanın hangi bölgeye doğru yönelim gösterdiğini daha hızlı görebilecektir. Yapılan diğer uygulamada yoğun bakımda yatan hastanın bir sonraki saatte sepsis enfeksiyonuna yakalanıp yakalanmayacağını ön görmek amacıyla derin öğrenme metodu LSTM algoritması kullanılmıştır. Bu uygulama Anaconda (versiyon 2.1.1) Python Notebook üzerinde geliştirilmiş, tensorflow (versiyon:2.3.0) üzerinde çalışan keras kütüphanesinden faydalanılmıştır.

Son bölümde yapay zeka teknolojisinin endüstrinin farklı kollarında stratejik açıdan kullanımının iş dönüşümüne kattığı değerle ilgili literatür yazını kapsamında tartışılarak sağlık alanında bu değer yaratımının nasıl olması ile ilgili bilgilere yer verilmiştir. Aynı zamanda sağlıkta yapay zeka modellerinin gelişimi sürecinde yaşanan zorluklar da son bölümde ele alınmıştır. Tezde ele alınan yapay zeka modelinin, karar verme sürecine karar desteği perspektifinde yardımcı olması, rekabet avantajı sağlayan ve yeni yetenekler geliştirmesinin önünü açan dinamik yeteneklerin geliştirilmesi ve yapay zeka teknolojileri ile kritik hastalıkların öngörülebilmesi ve müdahale edilmesi ile önlenebilir teknolojilerin gelişimi bu bölümde tartışılmıştır.

# I. BÖLÜM

## BİLİŞİM SİSTEMLERİ VE KARAR VERME


Bilişim Sistemleri (BS) kavramının hala tam olarak anlaşılmaması nedeniyle öncelikle "bilişim" ve "sistem" terimlerinin anlaşılması önem arz etmektedir. Bilişim sözlük anlamıyla, Osmanlıca “Malumat”, İngilizce “Information” ve Almanca “die Informatik” kelimelerine karşılık gelmektedir. Bilişim kelimesi, “*teknik, ekonomik ve toplumsal alanlardaki iletişimde kullanılan ve bilimin dayanağı olan bilginin elektronik makineler aracılığıyla düzenli ve akla uygun bir biçimde işlenmesi bilimi*” olarak ifade edilmiştir. Fransızcadan dilimize girmiş olan sistem kelimesi ise “*sonuç elde etmeye yarayan yöntemler düzeni*” olarak tanımlanmıştır (TDK, 2022). BS ise bir organizasyonda karar verme, koordinasyon, kontrol, analiz ve görselleştirmeyi desteklemek amacıyla bilgi toplayan, işleyen, depolayan ve kullanmak için birlikte çalışan, birbirleriyle ilişkili bileşenler olarak ifade edilmiştir (Laudon ve Laudon, 2018:44).

BS, verileri işlemek ve bilgi üretmek için birlikte çalışan bileşenlerin tamamından oluşmaktadır. Neredeyse tüm işletme tabanlı BS, işletmenin ana hedefine katkıda bulunan birçok alt sistemden oluşmaktadır (J.Sousa, Kenneth, 2014, s.12). Modern işletmeler artık problem çözmek ve karar vermek için daha fazla bilgiye ihtiyaç duymaktadır. Doğru bilgileri verimli bir şekilde toplamak ve gerektiğinde kuruluşun iş hedeflerine ulaşmasına yardımcı olmak amacıyla kullanmak, bugün iş dünyasında başarının anahtarıdır (J.Sousa ve Oz, 2014). Bu nedenle BS’ni etkin kullanabilmek ve gelişimine hızla ayak uydurmak, rekabetin yoğun olduğu günümüzde, sürdürülebilir işletme olabilme açısından önem arz etmektedir.

Tez kapsamında işletmeler için bu denli kabul gören ve sürekli gelişim gösteren BS disiplini, akademik literatür açısından da değerlendirilmiştir. “Information System” anahtar kelimesi Web of Science (WOS) veri tabanında 1976-2021 yılları arasında, başlık alanı özelinde aratıldığında yaklaşık 16 bin akademik araştırmanın olduğu ve



ilk çalışmanın 1976 yılında yapıldığı sonucuna ulaşılmıştır. 1980 yılında konu ile ilgili çalışmalar artış göstererek 103 akademik makale yayınlanırken; 2006 ve takip eden yıllarda ise çalışmalar dört katına çıkmıştır. BS konusunda yapılan bilimsel çalışmaların 2017 yılında ise en yüksek seviyeye (884) ulaştığı görülmüştür (Şekil 1).




Şekil 1. WOS "information system" yıllara göre yayınların dağılımı

BS'nin kullanımı kurumların ve işletmelerin çalışma şeklini değiştirmiş ve karar verme süreçlerinde dönüşüme neden olmuştur. Bilişim sistemleri hem işletmelerin ana işini desteklemekte hem de şirket içindeki işlemlerde çeşitli amaçlara (finans, pazarlama, insan kaynakları vb.) hizmet etmektedir (J.Sousa ve Oz, 2014, s.82). Büyük şirketlerin temeli tamamen BS dayanmaktadır. Açık artırma pazarı olan eBay; büyüyen bir elektronik alışveriş merkezi ve bulut bilişim hizmetleri sağlayıcısı olan Amazon; işletmeler arası e-ticaret sitesi olan Alibaba ve gelirinin çoğunu internet aramalarındaki anahtar kelime reklamcılığından sağlayan Google bu şirketlerin önde gelenleri arasındadır. Yalnızca şirketler değil hükümetler de hizmetlerini vatandaşlara uygun maliyetli bir şekilde sağlamak için BS'lerini kullanmaktadır. Bireyler,

sosyalleşme, eğitim, alışveriş, bankacılık ve eğlence gibi kişisel yaşamlarının çoğunu yürütmek amacıyla yine internet tabanlı BS uygulamalarından yararlanmaktadır (Zwass, 2020).

BS yıllar içinde birçok iş akışında yer alarak önemli ölçüde gelişmiştir. BS'nin işletmedeki en önemli görevlerinden biri, veriyi elde edip bunu önce bilgiye ve sonrasında bunu örgütsel bilgiye dönüştürmek olduğunu söyleyebiliriz. Teknoloji geliştikçe, bu rol kurumun omurgasına dönüşmüştür. BS'nin gelişim ve değişimini tam olarak anlamak için, yıllar içinde kaydettiği ilerlemeyi anlamak önem arz etmektedir.

BS'nde yaşanan dönüşüm neredeyse 50 yıldan fazla bir süredir devam eden bir evrimin sonucudur. Kenneth C. ve Jane P. Laudon, yaşanan bu evrim süresince geliştirilen teknolojilerin her birinin, hesaplama gücünün ve altyapı öğelerinin farklı konfigürasyonunu temsil eden beş aşamada (Şekil 2) gerçekleştiğini ifade etmişlerdir (Laudon ve Laudon, 2018, s.198). 1960'lı yıllarda sıcaklık kontrollü odalarda barındırılan ve yalnızca bilgisayar teknisyenleri tarafından çalıştırılması gereken devasa bilgisayarlar ile, ilk dönem olan Ana Bilgisayar Çağı başlamıştır (Laudon ve Laudon, 2018, s.199). Bu bilgisayarların birincil işi, elle yönetilmesi sıkıcı olan büyük hacimli bilgileri organize edebilmek ve depolayabilmektir. Aynı zamanda ilk bilgisayarlar, hesaplamaları daha verimli bir şekilde yapmanın bir yolu olarak da görülmekteydi (Bourgeois, 2014;8). Bilgisayar devrimi 1975 yılında, ilk mikro bilgisayar Popular Mechanics'in kapağında Altair 8800'in duyurulmasıyla başlamıştır. Başlangıçta sadece niş bir ürün olan mikroişlemciler, kullanılabilirlikteki olumlu gelişmeler neticesinde üretimi artmış ve böylece kişisel bilgisayar dönemi başlamıştır (Bourgeois, 2014;8). 1980'lere gelindiğinde ise düşük maliyetli Apple ve IBM bilgisayarlar ile PC'ler yaygınlaşmaya başlamış, bu durum fiyatların düşmesine, inovasyonların hızlanmasına neden olmuştur (Laudon ve Laudon, 2018, s.199).



Şekil 2. Bilişim sistemleri gelişiminin aşamaları

Bu yaşanan gelişme sürecinde bilgisayarlar herhangi bir ağa bağlı olmayan, büyük bir işletme içinde her biri birbirinden bağımsız hareket eden makinelerdi. Bu dönem boyunca bilgisayarın yaygın kullanımları arasında kelime işlem, elektronik tablolar ve veri tabanları bulunmaktaydı (Bourgeois, 2014:9).

1980'lerin ortalarında başlayan ve günümüze kadar devam eden üçüncü dönem ise, intranetin geliştirilmesine ve çalışanların sunucu ağları tarafından işlenen verilere erişmesine olanak tanımıştır (Shook, 2019). Geliştirilen bu ağ mimarisine "istemci-sunucu" adı verilmiştir. Kullanıcılar yerel alan ağından (LAN), "sunucu" adı verilen güçlü bir bilgisayara bağlanarak kendi bilgisayarlarından ("istemci") oturum açabilmiş ve daha sonra ağ üzerindeki farklı kaynaklara (paylaşılan dosyalar veya bir yazıcı) erişim imkanı doğmuştur. Bir diğer yönüyle bu sistem, bugün sıkça kullandığımız elektronik postanın ilk gerçek popüler kullanım örneği olmuştur. Bilgisayarlar artık bir organizasyon içinde dahili olarak iş birliği yapmak için kullanılabilen araçlara dönüşmüştür. Bu durum, bilgisayar ağlarını güçlendirmiş ve öncesinde daha büyük ana bilgisayarların gerçekleştirdiği işlevlerin çoğunun, maliyetinin çok altında gerçekleştirilebilmesi sağlanmıştır. İlk Kurumsal Kaynak Planlama sistemleri bu dönemde geliştirilmiş ve istemci-sunucu mimarisi üzerinde çalıştırılmıştır (Bourgeois, 2014:8-11). İşletmelerin, şirket genelindeki farklı ağları ve uygulamaları, kurumsal çapta bir altyapıya entegre edebilen ağ standartlarına ve yazılım araçlarına yönelmeye başlamalarıyla Kurumsal Bilgi İşlem olarak adlandırılan dördüncü dönem başlamıştı. İnternet, 1995'ten sonra güvenilir bir iletişim ortamına dönüşürken, firmalar, farklı ağları birbirine bağlamak için İletim Kontrol Protokolü / İnternet Protokolü (TCP / IP) ağ standardını kullanmaya başlamıştır. Ortaya çıkan BS altyapısı, farklı bilgisayar donanımı parçalarını ve daha küçük ağları kurumsal çapta bir ağa bağlamakta, bu

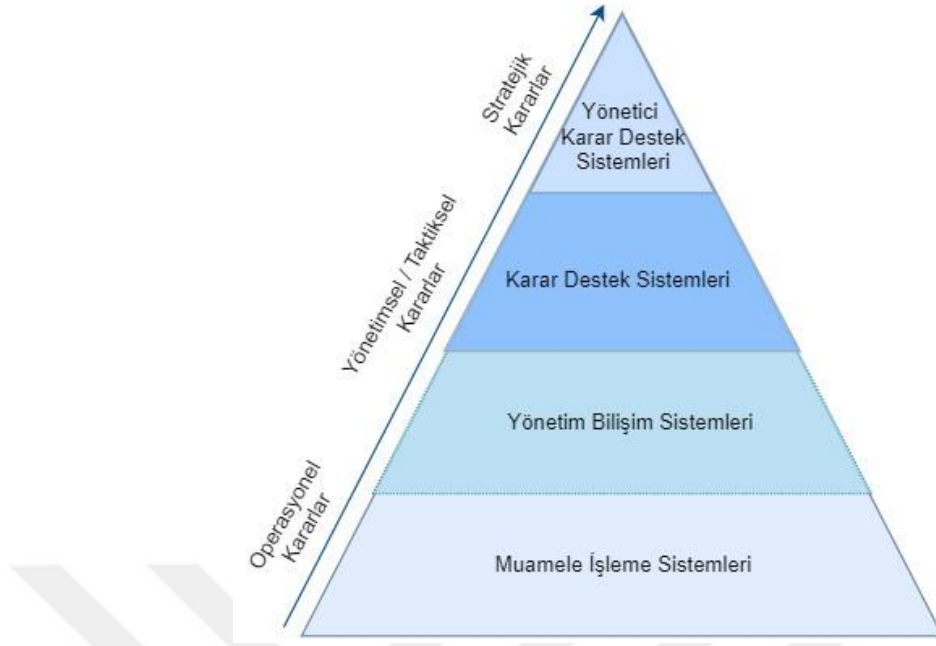
sayede bilgi kurum içinde ve kurum ile diğer kuruluşlar arasında serbestçe dolaşabilme imkanı bulmuştur. İnternetin artan bant genişliği gücü, istemci / sunucu modelinin bir adım ileriye taşınması bulut bilişimin gelişmesine neden olmuştur. Bulut bilişim, ağ üzerinden ya da internet üzerinden paylaşılan bilgi işlem kaynakları havuzuna erişim sağlayan ve kullandığın kadar öde mantığını güden bir bilişim modelini ifade etmektedir (Laudon ve Laudon, 2018:201). International Data Corporation (IDC) raporunda bulut bilişimin, 2024’de 1 Trilyon dolarlık bir pazar ile büyümeye devam edeceği ifade edilmiştir (Mediacenter, 2020).

BS, bir işletmenin rekabet avantajı elde etmesine yardımcı olan iş süreçlerinin, ürünlerin ve hizmetlerin ayrılmaz bir parçası haline gelmiştir. Özellikle, ticari firmalar operasyonel mükemmellik, yeni ürün ve iş modelleri, müşteri ve tedarikçi yakınlığı, karar verme, rekabet avantajı ve sürdürülebilirlik olarak belirlenen stratejik iş hedeflerine ulaşmak için BS’ne ciddi yatırımlar yapmaktadır (Laudon ve Laudon, 2018:42). Bu stratejik iş hedeflerine ulaşabilmek için farklı BS’leri geliştirilmiştir.

### **1.1. Bilişim Sistemlerinin Türleri**

İşletmelerde süreçlerin yönetilebilmesi ve kararların desteklenebilmesi amacıyla farklı düzeylerde kurgulanmış olan dört tür BS bulunmaktadır (Laudon ve Laudon, 2017). Bunlar Şekil 3’de gösterildiği üzere Muamele/Faaliyet İşleme Sistemleri (MİS), Yönetim Bilişim Sistemleri (YBS), Karar Destek Sistemleri (KDS) ve Yönetici Karar Destek Sistemleri olarak sıralanmaktadır (YKDS) (Berisha- Namani ve Qehaja, 2013).

Bir bilişim sisteminin temel amacı, verileri bilgiye dönüştürmektir. Bilgi, bir katma değer sürecinden geçerek işlenmiş veri olarak belirtilmektedir. Diğer taraftan BS, karar verme ve yönetim kontrolünü desteklemek için bilgi toplayan, işleyen, depolayan ve yayan bir grup ilişkili bileşen olarak tanımlanmaktadır (El-Ebiary vd., 2017).



Şekil 3. Bilişim sistemlerinin türleri

#### - Muamele İşleme Sistemleri

İşletmede operasyonel işlemleri yürüten personeller, satış, makbuz, nakit mevduat, bordrolama, işletmedeki malzemelerin akışı gibi temel faaliyetleri ve işlemleri takip eden sistemlere ihtiyaç duymaktadır. Muamele ya da faaliyet işleme sistemleri (Transaction Processing System) işletmenin sürdürülebilirliğini sağlamak için gerekli, günlük rutin işlemleri gerçekleştiren (müşteri siparişi girişi, otel rezervasyonları, bordro, çalışan kayıtlarının tutulması ve sevkiyat) ve kaydeden bilgisayarlı sistemlerdir; bunlar işletmenin operasyonel düzeyine hizmet etmektedir. Örgütsel hiyerarşinin en alt düzeyinde bulunan MİS'nin temel amacı, rutin soruları yanıtlamak ve işletmenin iş akışını takip etmektir (Belle, Nash ve Eccles, 2010). MİS, diğer bilişim sistemleri ve işletme işlevleri için önemli bilgi üreticilerdir. Bu sistemler genellikle işletmedeki iş akışlarının yapı taşlarıdır. Örneğin, birkaç saat boyunca havayolları bilgisayarlı rezervasyon sistemlerinin çalışmadığı düşünüldüğünde bu durum bir firmanın ve belki de ona bağlı diğer firmaların ciddi sıkıntıya düşmesine neden olacaktır.

## - Yönetim Bilişim Sistemleri

Yönetim Bilişim Sistemleri, işletmenin yönetsel verimliliğini artırmak için operasyonel sistemlerde mevcut olan verilerin işlenmesi ile ilgilenmektedir. YBS işletmenin yönetim düzeyine hizmet etmekte ve yöneticilere detaylı raporlama yapmaktadır. Bunları yaparken genellikle işletmenin mevcut performansına, muamele işleme sistemlerine ve veri tabanı kayıtlarına çevrimiçi erişim sağlamaktadır (Berisha-Namani ve Qehaja, 2013). YBS, yöneticilerin ve diğer kullanıcıların karar verebilmeleri, sorunları çözebilmeleri, etkinlikleri denetleyebilmeleri ve bilgi üretilmesini sağlayan bilişim sistemleridir. YBS yapılandırılmış kararları ve bazı yarı yapılandırılmış kararları desteklemektedir (Laudon ve Laudon, 2018). YBS işletmedeki operasyonları, yönetimi ve karar alma işlevini destekleyen ve bilgi sağlamak amacıyla entegre çalışan, insan ve makine sistemi olarak tanımlanmaktadır (Bendoly, 2013). Giderek daha fazla kurum, bilgi yönetimini geliştirmek ve kolaylaştırmak için teknolojiye yöneldiğinden, YBS bu süreçlerin daha efektif ve basit yürütülmesini sağlamaktadır. YBS'nin faydaları arasında, organizasyonel etkinliği artırma, kaynakların verimli ve etkili kullanımını sağlama, iş yönetiminin desteklenmesi ve öğrenen bir organizasyonun geliştirilmesi yer almaktadır (El-Ebiary, vd., 2017). Malezya'da 1990 yılından bu yana yükseköğretim kurumlarında öğrenci kaydında önemli bir artış yaşanmış ve bu hızlı büyümeyi karşılamak için YBS'ni üniversitelere dahil etme ihtiyacı doğmuştur. Bu kapsamda Malezya'da bir yükseköğretim kurumunda YBS uygulamalarının etkinliğini keşfetmek ve kurum tarafından kullanılmakta olan yönetim sisteminin faydalarını ve zorluklarını araştırmak üzerine bir çalışma yapılmıştır. Çalışma sonunda YBS uygulamalarının genel olarak, görevlerin verimliliğini ve performansını artırmayı başardığı, idari hataları azalttığı ve karar alma prosedürlerine yardımcı olduğu, sistem kullanıcıları tarafından ifade edilmiştir (El-Ebiary vd., 2017). YBS kullanımı aynı zamanda işletmelere etkili maliyet avantajları ve zaman tasarrufu da sağlamaktadır (El-Ebiary vd., 2017). Nisan 1964'e kadar, IBM System 360 ve diğer daha güçlü ana bilgisayar sistemlerinin geliştirilmesi, büyük şirketler için YBS geliştirmeyi pratik ve uygun maliyetli hale getirmiştir (Davis, 1974). YBS yöneticilere yapılandırılmış,

periyodik raporlar sunmaya odaklanmıştır ve bilgiler genel olarak muhasebe ve muamele işleme sistemlerinden alınmaktadır. Ancak, bu sistemler yöneticilere karar vermede yardımcı olmak için etkileşimli destek sağlamamaktadır. 1960'ların ortalarında, BT tabanlı veri işleyebilme olanağı ve bilgisayar bellek kapasitesi teknolojisindeki ilerlemeler nedeniyle bilgisayar tabanlı karar destek sistemlerinin geliştirilmesi daha uygun hale gelmeye başlamıştır.

#### - **Karar Destek Sistemleri**

Karar destek sistemleri, bilgileri yöneterek, hatırlatıcılar, uyarılar göndererek veya önerilerde bulunarak kullanıcıların karar vermelerine yardımcı olmak için tasarlanmış sistemlerdir (Shortliffe, 2001). KDS, bilişim sistemleri disiplininin yönetsel karar almayı desteklemeye ve geliştirmeye odaklanan alanı olarak bilinmektedir. Mesleki uygulama açısından KDS'ler, kişisel karar destek sistemleri, grup destek sistemleri, yönetici destek sistemleri, çevrimiçi analitik işleme sistemleri, veri ambarı ve iş zekasını içermektedir (Arnott, Pervan ve Dodson, 2005:1).

Holsapple ve Whinston (1996) karar destek sistemlerini ana amaçları bakımından birbirinden ayrı tutmuş ve altı tip KDS tanımlamışlardır: metin odaklı, veri tabanı odaklı, elektronik tablo odaklı, kural odaklı ve bileşik karar destek sistemleridir. Örneğin, metin yönelimli sistemler kitapların, süreli yayınların, raporların, notların ve diğer yazılı belgelerin, içeriklerinin karar vericilere sunulabilmesi için kataloglanmaktadır. Akıllı sistemler metinlerin içerik analizlerini yapabilmekte ve karar vericinin başka türlü düşünemeyeceği bölümleri (ve dolayısıyla bilgileri) önerebilmektedir. Veri tabanı yönelimli KDS'ler ise veri tabanında depolanan verilere odaklanmaktadır. Bu veri tabanlarını kontrol eden sistem, verilerin manipüle edilmesine, birleştirilmesine ve bu verilerin karar vericilere fayda sağlayacak şekilde sunulmasına olanak sağlamaktadır (Sauter, 2011).

Piramitte (Şekil 3) yönetsel kararların alınmasını sağlayan YBS ve KDS işleyişleri açısından birbirleri ile karıştırılabilmektedir. YBS ve KDS arasındaki en büyük

farklardan biri, YBS operasyonel verimliliğe odaklanırken, KDS daha etkili karar vermeye başka bir ifade ile şirketin doğru zamanda doğru aksiyonu alabilmesine odaklanmaktadır. YBS, büyük hacimli veri girişi, özet raporların çıktısı ve basit bir modelle karakterize edilebilen süreçlerin tamamıdır. KDS'leri ise düşük hacimli veri girişi, karar analizi çıktısı ve etkileşimli bir model ile karakterize edilen bir süreçtir. Ayrıca YBS, karar verme sürecinin birincil seviyesi iken, KDS kararın nihai ve son aşamasını etkilemektedir (Ada ve Ghaffarzadeh, 2015).

#### - **Yönetici Destek Sistemleri**

Stratejik bağlamda, yöneticilerin sahip oldukları ve gelecekteki performansların öngörülebilmesi ile ilgili bilgiler ve gelecekteki fırsatlar ve tehditler hakkında uzun vadeli stratejilerin nasıl geliştirildiğinin anlaşılması önem arz etmektedir. Bu amaçla, yöneticilerin gerekli bilgileri alabilmesi, üstünlük sağlayan organizasyonların temel yetkinliği olarak görülmektedir. Bu nedenle, yönetici bilgi sistemleri, üst yönetime stratejik karar vermeyi (görevi) desteklemek, bir yöneticinin bilgisini güncellemek ve uzun süredir devam eden bakış açılarına ve varsayımlara meydan okumak için stratejik olarak önemli bilgiler (yapı) sağlamak için çekirdek sistem (teknoloji) haline gelmiştir (Luftman ve Kempaiah, 2007). YDS, yöneticilerin stratejik bilgi ihtiyaçlarına göre uyarlanmış ve karar vermelerine yardımcı olma amacı güden sistemlerdir. Bu sistemler, rutin olmayan kararları ele alan ve özellikle işletmenin harici çevresindeki verileri içerecek şekilde tasarlanmışlardır. Aynı zamanda YDS'leri YBS'nin ve KDS'nin ürettiği özetlenmiş bilgileri de kullanmaktadır (Berisha- Namani ve Qehaja, 2013). YDS, dahili ve harici kaynaklardan gelen verileri birleştirerek üst düzey yöneticilere, özellikle yapılandırılmamış sorunlarda yardımcı olmaktadır (Laudon ve Laudon, 2017:379). Bu sorunlarda bir çözüme varmak için üzerinde anlaşmaya varılmış bir prosedür olmadığından yargı, değerlendirme ve öngörü gerektiren stratejik kararların alınmasına olanak sağlamaktadır.

YDS gelişmiş grafikler ve iletişim yoluyla, yapılandırılmamış karar verme sürecini ele almak üzere tasarlanmış, kuruluşun stratejik düzeyinde karar vericileri desteklemek amacıyla kullanılan bilişim sistemleridir (Laudon ve Laudon, 2017:78). YDS, dahili ve harici verilere erişim, geçmiş ve son verileri içeren veri ambarı sistemine erişim



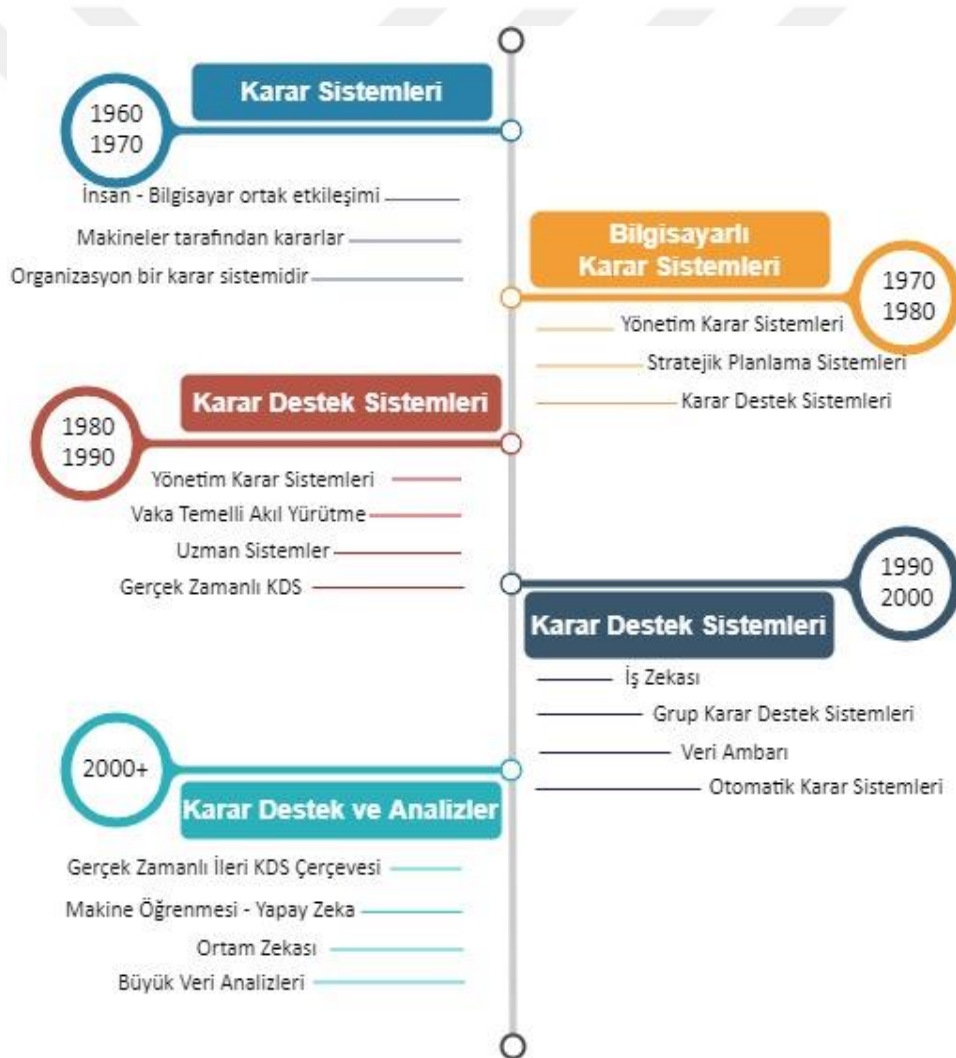
sağlamaktadır. Ayrıca elde edilen verilerden eğilimleri analiz etmek, tahmin etmek ve yöneticilere rekabet avantajı sağlayacak ortamlar oluşturabilmek amacıyla veri madenciliği teknikleri ve iş zekası araçlarını da kullanabilmektedir. Örneğin, bir genel müdür şirket için genel satışların yanı sıra her departman için ayrı ayrı satışlar ve yıl içi genel ekonomik verileri isteyebilir. YDS, tüm bu verileri ve analiz sonuçlarını hem grafik hem de metin araçları kullanarak dijital bir ara yüz üzerinden yöneticilere anlık olarak aktarabilmektedir (Hasan, 2018:17). Ayrıca YDS, üst düzey yöneticilere tahmin ve öngörü hizmeti de sunarak, gelecekle ilgili kararlarına destek olabilmektedir. Bu çerçevede, makine öğrenmesi ve yapay zeka sistemleriyle donatılmış veya onlarla bütünleşmiş çalışma kabiliyetine sahiptirler.

YBS, KDS ve YDS gibi herhangi bir bilişim sistem seviyesi, yöneticilere rekabet avantajı ve/veya karar vermek için kullanılacak derin bilgiler sağlayan araçları içermektedir. Bu sistemler, yöneticilerin ihtiyaçlarını karşılamak ve onları stratejik karar verme prosedürleri ve faaliyetleri ile desteklemek için oluşturulmuş sistemlerdir (Yu, Chen, Klein ve Jiang, 2015). Sürdürülebilir rekabet için işletmeler/organizasyonlar bilişim sistemlerinden yararlanmalı ve bu sistemlerden doğru bilgiyi almak ve yüksek performans elde edebilmek için sistemi sürekli veri ile beslemelidirler.

## **1.2. Karar Destek Sistemlerinin Gelişimi ve Kullanım Alanları**

Karar Destek Sistemleri, insan – bilgisayar ortak iş süreçleri yoluyla başlayan gelişim sürecini stratejik planlama, iş zekası, makine öğrenmesi ve yapay zeka temelli sistemler ile sürdürmektedir. Licklider (1960) karar sistemlerini ele aldığı kavramsal makalesinde, “*insanların ve bilgisayarların karar vermede iş birliği yapmalarını sağlayan*” insan-bilgisayar ortak yaşamını benimseyen bir sistem öngörmüştür (Licklider, 1960:4). Bonini (1963) varsayımsal bir işletme firması üzerinde yaptığı çalışmada karar merkezleri, bilgi merkezleri ve karar kurallarını içeren bir simülasyon geliştirmiştir. Bonini çalışmada, “bir karar sisteminin, kurumdaki tüm karar kurallarının toplamı” olduğunu ifade etmiştir. Bu nedenle, bir karar sisteminin belirli bir dizi karar kuralları anlamına geldiğini belirtmiştir (Bonini, 1963:18).

Gorry ve Scott-Morton (1971) çalışmalarında, YBS'nin öncelikle yapılandırılmış kararlara odaklandığını ifade etmişlerdir. Bu nedenle yarı yapılandırılmış ve yapılandırılmamış kararlarda destekleyici bilişim sistemleri için ilk kez "Karar Destek Sistemleri" terimini önermişlerdir (Gorry ve Morton, 1971). KDS yarı yapılandırılmış karar durumlarında yönetimsel karar almaya yardımcı ve destek olmayı amaçlayan sistemleri karakterize etmektedir. Bu sistemler, karar vericilere eşlik edecek şekilde tasarlanmış, yeteneklerinin artırılması amaçlanmıştır (Daniel J. Power, Heavin ve Keenan, 2019). Şekil 4'te KDS'nin tarihsel gelişim süreci ifade edilmiştir (D. J. Power, Heavin ve Keenan, 2019).



Şekil 4. Karar destek sistemleri ve teknolojisindeki gelişmeler.

Karar Destek Sistemlerinin gelişimine devam etmesiyle son dönemde gerçek zamanlı karar sistemleri, büyük veri analizi, iş zekası, makine öğrenmesi ve ortam zekası karar sistemlerinde uygulanabilir hale gelmiştir. Mevcut çalışmalar, gerçek zamanlı karar sistemlerinin, karar desteğinin ve veri analizinin bazı operasyonel kararlar için kritik önem taşıdığını göstermektedir. Gerçek zamanlı karar desteği büyük miktarlarda gerçek zamanlı veri akışı, hızlı işleme ve mükemmel iletişim gerektirmektedir. Gerçek zamanlı karar sistemleri; ortak büyük veri kaynakları, sosyal medya verileri, mobil cihaz dosyaları, makine/cihaz günlükleri ve sensör verilerinin analizlerini içermektedir. Mobil cihazlar, giyilebilir teknoloji, bağlı cihazlar, sensörler, sosyal medya, sadakat kartı programları ve web sitesi tarama geçmişi, çok sayıda yararlı yapılandırılmış ve yapılandırılmamış veri üretmektedir (Power vd., 2019). Gerçek zamanlı karar sistemleri özellikle sağlık ve enerji sektörlerinde kullanılmaktadır. Literatürde geçmişte yaşanan salgın hastalıkların hem salgının nasıl ortaya çıktığı, hem de enfekte olmuş ancak fark edilmemiş hastaları tespit etmek için gerçek zamanlı karar destek sistemlerinin kullanıldığı çalışmalar (Probert vd., 2018); (Boon Som Ong vd., 2010); (Shaman ve Karspeck, 2012) yer almaktadır. Gerçek zamanlı sistemler belirli bir zaman kısıtlaması içinde yanıt vermesiyle farklılaşan karar destek sistemleri olarak karşımıza çıkmaktadır. Gerçek zamanlı sistemler rekabet ve maliyet açısından avantajlı sistemler olabilmektedir. Hem karar verici hem de işletmeye fayda sağlayabilmekte, gerçek zamanlı alınan veriler daha hızlı işlenerek karar vermede fark yaratabilmekte ve bu da genellikle zamanında ve etkin sonuçların alınmasına olanak sağlamaktadır (Power vd., 2019).

Teknolojinin ilerlemesi, daha sofistike karar sistemlerinin geliştirilmesinin önünü açmıştır. Makine öğrenmesi ve yapay zeka disiplinlerinin ortaya çıkmasıyla, nicel veriler içeren önceki kayıtlardan karar kurallarının belirlenmesine olanak tanınmıştır. Karar destek sistemlerine entegre edilen makine öğrenmesi, arzu edilen ve istenmeyen sonuçlar için ortak örüntülerin tanımlanabildiği bir örüntü tanıma imkânı sağlamaktadır. Bu durumda arzu edilen sonuçları daha iyi elde etmek için bu örüntülere dayalı makine kuralları türetebilmektedir. Örneğin, makine öğrenmesi, iyi müşterilerin ortak özelliklerini belirleyebilmekte ve indirim alması gereken müşteriler

için karar kuralları oluşturabilmektedir. Ayrıca hileli işlemlerin oranını azaltabilecek kurallar çıkarabilen sahtecilik tespitinde de yaygın olarak kullanılmaktadır.

Makine öğrenmesinin, uzmanların emek yoğun katılımı olmadan karar kuralları oluşturma yeteneği, onu birçok modern karar sisteminin temeli haline gelmesini sağlamıştır (Daniel J. Power vd., 2019). Bu durum hızlı, etkin ve stratejik karar almak isteyen tüm sektörlerde karar sistemlerinin daha hızlı gelişimine neden olacaktır.

### Karar Destek Sistemleri Uygulama Örnekleri

Karar destek sistemleri; finans (Serrano-Cinca ve Gutiérrez-Nieto, 2013), pazarlama (Figuerola-Perez, vd., 2019), tahmin (Bucholc vd., 2019), ulaşım (Abou El Assad, Mousannif ve Al Moatassime, 2020), stratejik yönetim (Cebeci, 2009), eğitim (Zhu, 2018), sağlık hizmetleri (Mazo, Kearns, Mooney ve Gallagher, 2020) ve askeriye (Song, Ryu ve Kim, 2010) gibi birçok farklı alanda uygulamaları bulunmaktadır. Kararların sınıflandırılması ve doğru kararlar için bilgisayar tabanlı sistemlerin, yöneticilerin hem kararlarında hem de karar süreçlerinde önemli faydaları bulunmaktadır (Morton, 2007). Vazsonyi, insan-makine sisteminin yardımıyla bir yöneticinin geniş kapsamlı alternatiflerin geniş bir panoramasını inceleyebileceği ve bugün mümkün olandan daha iyi bir karara varabileceğini ifade etmiştir (Vazsonyi, 1963, s.156).

Araştırmanın ana konusunu oluşturan makine öğrenmesi/yapay zeka destekli karar sistemleri, insan kararlarını desteklemek amacıyla birçok farklı alanda uygulanmıştır. KDS'nin, karar vericinin yarı yapılandırılmış ve yapılandırılmamış kararlar vermede yararlı bilgileri almak için doğrudan bilgisayarla etkileşime girmesini sağlayan entegre bir bilgisayar sistemi olduğu belirtilmiştir (Uma, 2009). Bu kararlara örnek olarak birleşme ve devralma kararları, fabrika genişlemesi, yeni ürün kararları, portföy yönetimi ve pazarlama kararları verilebilmektedir. Nokhbatolfoghahaayee ve ark. (2010) yeni bir karar verme yapısına sahip, çok parametrelili büyük ölçekli bir sistemdeki kriz koşullarını yönetmek için uygulanabilecek bulanık karar destek sistemi geliştirmişlerdir (Nokhbatolfoghahaayee, Menhaj ve Shafiee, 2010). Ouammi vd.

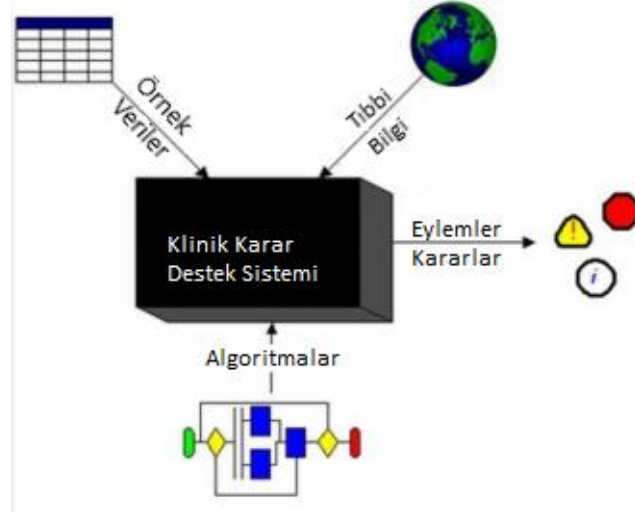
(2012) karar destek sistemleri konusunu yenilenebilir enerji alanında, rüzgar enerjisi kapsamında ele almıştır (Ouammi, Ghigliotti, Robba, Mimet ve Sacile, 2012). Çalışmada hazırlanması amaçlanan çevresel karar destek sisteminde; bir bölgedeki yer seçimi ve kurulumu yapılacak optimal teknolojilerin tespiti yer almaktadır. Enerji alanındaki bir başka çalışmada, Phdungsilp (2010) Bangkok'ta entegre bir enerji ve karbon modelleme karar destek sistemi üzerine çalışmıştır. Uzun dönemli enerji alternatifleri planlama sistemi modeli kullanılarak bir dizi politika müdahalesi simüle edilmiştir. Bu politikaların 2000 yılından 2025'e kadar enerji ve karbonu nasıl değiştireceği tahmin edilmiştir (Phdungsilp, 2010). New York City Transit'in metro ağı, yüksek kapasiteyle çalışan metro ağı olması nedeniyle yaşanan aksamalar son derece önemli görülmektedir. Bu amaçla, tren görevlileri ağı sürekli olarak izlemekte ve gecikmelere yanıt verecek şekilde ulaşım hizmeti ayarlamaktadırlar. Herhangi bir aksama yaşanmaması amacıyla gerçek zamanlı tren hareketleri ve geçmiş yolcu bilgileri kullanılarak gerçek zamanlı öneriler sağlayan bir karar destek sistemi çalışması gerçekleştirilmiştir. İlk gözlemlerde, tren hizmetini daha etkili bir şekilde yönetmelerine yardımcı olarak yolcuya büyük zaman tasarrufu sağladığı vurgulanmışlardır (Wood, Stasko, Tarte, Jefferson ve Reddy, 2018).

Lim vd. (2011) sağlık alanında yaptığı çalışmalarında H1N1-2009 virüsünün gerçek zamanlı olarak incelenmesi ve tahmini üzerine çalışmıştır. Gelişmekte olan ülke bağlamında Singapur'un incelendiği çalışmada, bahsi geçen gerçek zamanlı gözetim sistemi hastalığın gelişimini ve tepe noktasını gösterebilmiştir (Lim vd., 2011). Hava kalitesi hakkında yapılan bir uygulamada, ozon konsantrasyon seviyesini tahmin etmek için hava kalitesi özelliklerini (NO, NO<sub>2</sub>, NO<sub>x</sub>, O<sub>3</sub> vb.) izleyen sensörlerden gelen verileri kullanmış ve seviyenin zararlı olduğu tahmin edildiğinde, karar önerisi hava kirliliği alarmlarını tetiklemiştir. Büyük miktarda tarımsal veriyi işleme ve karmaşık ortamı işleme yeteneği nedeniyle kullanılan tarım karar destek sistemleri çiftçilere çeşitli tarım faaliyetlerini gerçekleştirmede yardımcı olmak için oldukça yararlı olduğu belirtilmiştir (Athanasiadis, Kaburlasos, Mitkas ve Petridis, 2003). Bu amaçla yapılan çalışmada tarım alanında kullanılan KDS'lerinin faydaları ve zorlukları tartışılmış ancak gelecekteki tarımsal karar destek sistemlerinin bu zorlukların üstesinden gelerek Tarım 4.0'a daha iyi hizmet edebileceği ifade edilmiştir.

Görüldüğü üzere neredeyse tüm sektörlerin içinde karar destek sistemleri kullanılmaktadır. Çağımızdaki bilişim teknolojisindeki gelişmeler ve kullanımdaki üstel büyüme nedeniyle kurumlar ve işletmelerin ihtiyaçları önemli ölçüde değişmiştir. Kurumlar bugün karar alma sürecini desteklemek için bilişim sistemlerini kullanmak zorundadırlar. Karar almada bilişim sistemlerinin önemini bilmeyen kurumlar kısa vadede başarılı olabilseler de bilişim sistemleri ve kullanımlarındaki stratejik faydayı elde edemeyecek ve uzun süreli varlıklarını sürdüremeyeceklerdir.

### **1.3. Klinik Karar Destek Sistemleri**

Karar destek sistemlerinin uygulandığı önemli alanlardan biri de klinik karar destek sistemleridir. Klinik karar destek sistemleri (KKDS), “hastalara özgü değerlendirmeler veya öneriler oluşturmak için bireysel hastaların özelliklerinin kullanıldığı ve daha sonra değerlendirilmek üzere hekimlere sunulan karar vermede doğrudan yardımcı olmak üzere tasarlanmış elektronik sistemler” olarak tanımlanmaktadır (Kawamoto, Houlihan, Balas ve Lobach, 2005). Bu, bir KKDS’nin, bazı hasta verilerine dayalı olarak hasta bakımı için klinik tavsiye elde edecek şekilde bilgi yönetimini kullanmaya odaklanan bir karar destek sistemi olduğu anlamına gelmektedir (Mangano, 2004). KKDS araçları, doktor-hasta iletişimini güçlendirmeye yardımcı olabilmekte ve potansiyel olarak iş akışını, verimliliği ve hasta sonuçlarını iyileştirebilmektedir. KKDS tıbbi bilgi tabanını, hasta verilerini ve vakaya özel tavsiyeler oluşturmak için bir çıkarım motorunu entegre (Şekil 5.) etmek üzere tasarlanmıştır (Rafiei, 2013).



Şekil 5. Klinik karar destek bileşenleri ve çıktıları

KKDS’de hasta verileri tıbbi bilgi tabanı ile eşleştirilirken algoritmalar her hasta için özel bir tedavi önerisi üretmektedir. KKDS önleyici muayeneler veya aşılarda ilgili hatırlatmalar sağlamakta (Souza vd., 2011), reçetelere yardımcı olabilmekte veya bunları kontrol edebilmekte (Hemens vd., 2011), akut (Sahota vd., 2011) ve kronik hastalıkların (Roshanov vd., 2011) yönetimini destekleyebilme yeteneklerini barındırmaktadır. KKDS’ler hakkında yapılan yapısal araştırmada 100 çalışmanın 64’ünde uygulayıcı performansını iyileştirdiği sonucuna varılmıştır (Garg vd., 2005). KKDS’nin olumlu etkileri: a) klinik iş akışında otomatik karar desteği sağlanması, (b) sadece bir değerlendirmeden ziyade bir tavsiye sağlanması, (c) bilgisayar tarafından karar desteği ve (d) zaman tasarrufu olarak dört kriter özelinde ele alınmıştır (Kawamoto vd., 2005).

KKDS makine öğrenmesiyle desteklenmiş, yapay zeka uygulamalarıyla entegre çalışabilen ve günümüzde büyük veriyi kullanan sistemler olarak görülmektedir. Son yıllarda karar destek sistemleri ile klinik karar verme alanında; hasta verilerinin yönetimi (Razmak, Bélanger ve Farhan, 2018); hemşirelik (Ahamed vd., 2016), mobil sağlık yenilikleri (Nguyen ve Poo, 2016) gibi farklı alanlarda çalışılmıştır. Tıp ve bilişim alanında çalışan bilim insanlarının yürüttüğü proje ve akademik çalışmalar, bu sistemlerin gelişmesini sağlamaktadır.

Yapılan arařtırmalarda sanayileřmiř ũlkelerde sunulan saęlık hizmetlerinin çoęu zaman, kanıta dayalı bakımın yetersiz olduęu grlmüřtr. Amerika Birleřik Devletlerinde (ABD) ũlke apında 439 kalite gstergesini deęerlendiren bir denetim řirketi, ABD'li yetiřkinlerin nerilen bakımın sadece yarısını aldıęını belirtmiřtir (McGlynn vd., 2003, s.2637). ABD Tıp Enstits, her yıl nlenebilir tıbbi hataların sonucu olarak 98.000 ABD vatandařının ldęn tahmin ettikleri bir rapor yayınlamıřlardır (Kohn, Corrigan ve Donaldson, 2004). Farklı iki Londra hastanesinde yapılan benzer bir arařtırmada, merkezlere kabul edilen hastaların %8'inin lmlle sonulandıęı olumsuz olayların (yanlıř teřhis, yanlıř ila tedavisi, tıbbi hatalar vb.) meydana geldięi ifade edilmiřtir (C. Vincent, Neale ve Woloshynowych, 2001). Bakımdaki bu eksikliklerin giderilmesi iin saęlık kuruluřları giderek daha fazla klinik karar desteklerine ynelme gstermiřlerdir. ABD Tıp Enstits tarafından "To err is human" raporunun yayınlanmasının ardından, zellikle geliřme gsteren klinik karar destek sistemleri tıbbi hataların nlenmesine, hasta gvenlięi ve bakım kalitesini iyileřtirmeye ynelik yaklařımların kilit unsurlarından biri olmuřtur (Berner ve La Lande, 2007).

KKDS saęlık hizmeti saęlayıcılarının karar vermelerine ve karmařık sorunları zmelerine yardımcı olan deęerli bir ara olarak grlmektedir (Paydar vd., 2017) (Berner ve La Lande, 2007). KKDS doęru tanı koymaya yardımcı olmak, bir hasta iin daha bilinli saęlık hizmeti kararları almak ve hastaların saęlıęa iliřkin yařam kalitesini iyileřtirmek amacıyla kullanılmaktadır (Bright vd., 2012). Bu tr sistemler hem saęlık bakım maliyetlerini (Bellodi vd., 2017) hem de tıbbi hata oranlarını dřrmeye yardımcı olurken verimlilięi de artırmaktadırlar (Owens vd., 2010).

### **1.3.1. Klinik Karar Destek Sistemleri Trleri**

Klinik karar destek sistemleri; bilgiye dayalı ve bilgiye dayalı olmayan řeklinde iki boyutta ele alınmaktadır (Metzger vd., 2002; Osheroﬀ, 2012). Bilgiye dayalı veya bilgi tabanlı sistem sonuları retmek iin kurallar, kanıtlar ve ıkarım motoru kullanırken, bilgi tabanlı olmayanlar makine ęrenmesi olarak da bilinen yapay zeka teknolojilerini kullanmaktadır (Berner ve La Lande, 2007). Bilgiye dayalı KKDS, bir ıkarsama



motoru kullanarak hasta verilerine kurallar uygulamakta ve ardından çıktı üretmektedir. Bilgi tabanlı KKDS'leri bir veri havuzu, çıkarım ya da akıl yürütme motoru ve kullanıcıyla iletişim kurmak için bir mekanizmadan oluşmaktadır. Bilgi tabanlı sistemlerde kurallar (IF-THEN-ELSE ifadeleri ile) oluşturulmakta, sistem kuralı değerlendirmek için veri almakta ve bir eylem veya çıktı üretmektedir (Berner ve La Lande, 2007). Kurallar, literatüre dayalı, uygulamaya dayalı veya hastaya yönelik kanıtlar kullanılarak çıkarılmaktadır. Klinik sistemin veri havuzu, hastanın klinisyen tarafından doğrudan girilen ve elektronik sağlık hizmetlerinden gelen verilerle birlikte, hastalıklar ve bunların belirti ve bulguları hakkındaki verileri içermektedir. Çıkarım motoru, hastanın belirti ve semptomlarını hastalıklarla eşleştirmekte ve hekimlere uyarı veren bir iletişim mekanizmasıyla dikkate alması gereken bazı teşhisler önerebilmektedir. Bu sistemler genellikle sadece tek bir tanı oluşturmak yerine mevcut bilgilere dayanarak bir dizi tanı oluşturabilmektedirler (Alther ve Reddy, 2015; Sherimon ve Krishnan, 2016). Hekimler ya da sağlık personelleri genellikle hasta hakkında bilgisayarın sunduğundan daha fazlasını bildiklerinden, bazı seçenekleri ortadan kaldıracaktır.

Bilgiye dayalı karar destek sistemlerinin aksine, bilgiye dayalı olmayan KKDS'leri ise klinik verileri analiz etmek için makine öğrenmesi ve yapay zekaya dayanan sürekli öğrenen modeller geliştirebilmektedir. Bilgiye dayalı olmayan KKDS'ler bilgisayarın geçmiş deneyimlerden öğrenmesini ve / veya klinik verilerdeki örüntüleri tanımasını sağlayan makine öğrenmesi ve yapay zeka modellemeleridir (Marakas, 2003) . Makine öğrenmesi, geliştirilmiş doğrulukla akıllı davranışların otomasyonu, hastalığın erken tahmin edilmesine yardımcı olabilmekte ve acil tedavi planlamasında klinik uzmanlarına yardımcı olabilmektedir. Bilgi tabanlı olmayan KKDS, belirli örnekleri dikkate alarak belirli görevlerin nasıl gerçekleştirileceğini öğrenen yapay sinir ağları ve genetik algoritmaları içermektedir. Yapay sinir ağı, semptomlar ve tanı arasındaki ilişkileri belirlemek için hasta verilerinde bulunan modelleri analiz edebilmektedir (Berner ve La Lande, 2007). Veri analitiği ve büyük veri uygulamaları sağlık hizmetlerinde yaygın olarak kullanıldığından, bu tür sistemler gün geçtikçe önem kazanmaktadır. Yapılan çalışmalarda makine öğrenmesi ve desen tanıma

yaklaşımlarına dayanan KKDS'nin, hedeflenen hastalıkları teşhis etmede ortalama klinisyenden daha doğru olabileceği ifade edilmiştir (Ozaydin vd., 2016) .

Coiera dijital KKDS'lerin faydalarını; (i) hasta güvenliği, (ii) bakım kalitesi ve (iii) sağlık hizmeti sunumunun verimliliği olarak üçe ayırmıştır (Coiera, 2003). Bu faydaların ilki, KKDS'ler istenmeyen olayları azaltarak, kişiye özgü ilaçlar, reçeteler ve testler önererek verimli bir şekilde hasta güvenliğini artırabilir. Diğer bir fayda, KKDS'leri klinisyenin iş yükünü azaltarak bakım kalitesini artırabilir, bu sayede doğrudan hasta bakımı için daha fazla zaman imkanı sağlanabilir. Klinik kılavuzların uygulanmasını hızlandırabilmekte ve klinik dokümantasyonun iyileştirilmesi sayesinde karar verme sırasında hataları en aza indirme ve hasta memnuniyetini en üst düzeye çıkarma açısından önemli bir avantaj sağlanabileceği vurgulanmaktadır. Son olarak belirtilen fayda ise test sayısını azaltılarak ve daha az maliyetli fakat aynı derecede etkili jenerik markaları tercih ederek sağlık hizmetlerinde sunum verimliliğini artırabilmekte ve maliyetlerin azalabilmesini sağlayabileceği belirtilmektedir (Bright vd., 2012; Coiera, 2003).

KKDS'leri bazı hastalıklar için erken tanıyı kolaylaştırabilmekte; bu erken tanımlama yaşam ve ölüm arasındaki ince farkı yaratacak güçte olabilmektedir. Örneğin, sepsis tedavisinin her saat geciktirilmesi mortalitede %7,6 oranında artışa neden olmaktadır (Henry vd., 2015). Erken teşhis sadece zamansız ölümleri önlemekle kalmamakta, aynı zamanda sağlık hizmetlerinde tasarruf sağlanabilmektedir. Alzheimer Derneği (2018), erken Alzheimer tespiti sayesinde 7 trilyon dolar tasarruf sağlandığını belirtmiştir (Thies ve Bleiler, 2012). Etkili, doğru ve verimli KKDS'lerin geliştirilmesi tıbbi verilerin kalitesi ile ilişkilidir. Hastaneler hem yapılandırılmış hem de yapılandırılmamış verileri kullanarak KKDS'lerini güçlendirebilmektedir. Farklı kaynaklardan elde edilen sağlık verileri, içinde bilgi zenginliğini barındırmaktadır. Bu bilgi zenginliğini açığa çıkarmak, sağlık verilerini bilgiye dönüştürmek için istatistiksel ve makine öğrenmesi yöntemlerinin kullanılması tercih edilmektedir. Bu nedenle, yapılan bu çalışmada da klinik karar destek sistemlerinin bir adım ötesine geçilerek kritik hastalık tespitinde makine öğrenmesi ve yapay zeka algoritmaları kullanılması amaçlanmıştır.

## II. BÖLÜM

### YAPAY ZEKA VE MAKİNE ÖĞRENMESİ

*Güçlü yapay zekanın yükselişi, insanlığın başına gelen ya en iyi ya da en kötü şey olacak.*

*Hangisi olduğunu henüz bilmiyoruz.*

*Stephen Hawking*

#### 2.1. Yapay Zeka

Yapay Zeka (YZ), bilgisayarların insan beynini nasıl taklit ettiğini konu alan bilim dalıdır. Makine öğrenmesi, derin öğrenme ve doğal dil işleme ise bu bilimin nasıl uygulanacağını gösteren yöntemlerdir (Poole, vd., 1998:32). Son zamanlarda adını sıkça duyduğumuz YZ araştırma alanı yeni değildir. Bu kara kutuyu açmak gerekirse, “Yapay Zeka” terimi, 1956'da Dartmouth Koleji'nde düzenlenen konferansta beyin fizyolojisi araştırmacılarının, önerme mantığının analistleri ve bilgisayar mühendislerini bir araya getiren bir araştırma alanı olarak ortaya çıkmıştır (Russell ve Norvig, 2022:36). 1961'de “Yapay zekaya doğru adımlar” başlıklı bir makalede Marvin Minsky, “akıllı problem çözme makinelerinin güçlü bir şekilde etkileneceği ve büyük olasılıkla egemen olacağı bir çağın eşiğinde olduğumuzu” ilan etmiştir (Minsky, 1961). YZ araştırmasının gelişimi, inişler ve çıkışlar ile karakterize edilmiştir. 1950'lerin sonunda yaşanan coşku, bazı matematiksel teoremleri kanıtlayabilen programlar oluşturma veya dama gibi basit oyunlar oynama yeteneğiyle bağlantılı olarak ortaya çıkmıştır. Bu coşkuyu, yapay zeka sistemlerinin insanlara benzer veya hatta daha yüksek zeka seviyeleri gösterebileceğine dair vaatlerine karşın, başarısızlıklarla sonuçlanan bir hayal kırıklığı dönemi izlemiştir (Russell ve Norvig, 2022:37). Bu başarısızlık kısmen o yıllarda bilgisayar teknolojisinin donanımsal anlamda yeterince olgunlaşmamış olmasından ve kısmen de bağlamsal bilginin nasıl haritalanıp birleştirileceği sorununa bir çözüm bulunmamasından kaynaklanmaktaydı. Sonuçta yapay zeka çalışmalarına 1990'ların sonlarına kadar ara verilmiş ve ara verilen dönem "YZ kışı" olarak adlandırılmıştır (Perez vd., 2018).

Sanayi devrimine ve dijital devrime benzer şekilde, YZ devrimi, şu anda insanlar tarafından gerçekleştirilen tüm görevlerin yerine getirilmesini, tamamlanmasını ve pratik olarak

güçlendirmesini sağlamaktadır (Makridakis, 2017). Yapay zeka; 1) akıllı makinelerin, insan benzeri davranışlar sergileyerek görevleri yerine getirme yeteneği, 2) makinelerin çevreyi algılayarak ve bazı hedeflere ulaşmak için eylemlerde bulunarak rasyonel davranması (yani akıllı ajanlar) olarak tanımlanmıştır (Russell ve Norvig, 2022:31). YZ, insan zekası süreçlerinin makineler ve bilgisayar sistemleri tarafından simüle edilmesidir. Bu süreçler, öğrenme (bilgi edinme ve bilgiyi kullanma kuralları), akıl yürütme (kesin sonuçlara yaklaşık olarak ulaşmak için kuralları kullanma) ve kendi kendini düzeltmeyi içermektedir. Yapay zeka üç farklı kategoride incelenmektedir:

- **Zayıf/Dar YZ:** Dar YZ, özel bir görevi yerine getirebilen ve şu an mevcutta en yaygın kullanılan YZ türüdür. Dar YZ, yalnızca belirli bir görev için eğitildiğinden, alanının veya sınırlamalarının ötesinde performans gösterememektedir. Bu nedenle zayıf YZ olarak da adlandırılmaktadır. Apple Siri, önceden tanımlanmış sınırlı bir işlev yelpazesıyla çalıştığından ya da IBM'in Watson süper bilgisayarı, makine öğrenmesi ve doğal dil işleme ile birleştirilmiş bir uzman sistem yaklaşımı kullandığından, dar YZ kapsamına girmektedir. Dar YZ'nin diğer örnekleri arasında satranç oynamak, e-ticaret sitesinde satın alma önerileri, sürücüsüz arabalar, konuşma tanıma ve görüntü tanıma sayılabilir.
- **Genel YZ:** Herhangi bir entelektüel görevi bir insan gibi verimlilikle gerçekleştirebilen bir zeka türüdür. Genel YZ'nin arkasındaki fikir, daha akıllı olabilecek ve kendi başına bir insan gibi düşünebilecek bir sistem geliştirilmesini içermektedir. Dünya çapındaki araştırmacılar tarafından şu an genel YZ özellikli sistemler geliştirmeye odaklanılmıştır (Cao, 2021:28).
- **Süper/Güçlü YZ:** Güçlü YZ, makinelerin insan zekasını aşabileceği ve bilişsel özelliklere sahip herhangi bir görevi insandan daha iyi yerine getirebileceği bir zeka düzeyine ulaşılmasıdır. Süper YZ, genel yapay zekanın bir sonucudur. Kendi başına düşünebilen bir makine oluşturmak için geliştirilmesi planlanmaktadır (Hermes vd., 2020). Süper YZ, henüz yapay zekanın varsayımsal bir kavramıdır.

Mevcut YZ teknolojileri dar yapay zeka kapsamında gelişme göstermektedir. Örneğin, yapay zekanın bir sınırlaması "sağduyu" eksikliğidir; bilgiyi edindiği bilginin ötesinde yargılama yeteneği bulunmamaktadır. Microsoft tarafından geliştirilen ve sosyal

ağlarda sohbet etmek için tasarlanan YZ robotu Tay, piyasaya sürüldükten kısa bir süre sonra bağlantısı kesilmiştir. Çünkü olumlu ve olumsuz insan etkileşimi arasında ayrım yapamadığı tespit edilmiştir. Yapay zeka, duygusal zeka açısından da sınırlıdır. YZ, öfke, neşe, üzüntü, korku, acı, stres ve tarafsızlık gibi temel insani duygusal durumlarını tespit edebilir ancak kendisi bu duygusal durumları barındırmaz. Bu seviyede bir YZ insan bilişini hayal etme, düşünme, duyguları hissetme ve kendi hedeflerine sahip olma yeteneğini sağlayacak bir noktaya kadar taklit edecektir. Henüz bu tür bir gerçek yapay zekanın 2050'den önce var olabileceğine dair bir kanıt olmamasına rağmen, yine de yapay zekayı ileriye götüren bilgisayar bilimi hızla ilerlemekte ve etkisini sadece teknolojik açıdan değil, aynı zamanda sosyal açıdan da göstermektedir (Perez vd., 2018). Tüm bu teoriler, tıp, bankacılık ve finans, oyun, arabalar, cep telefonları ve sistemleri ve devlet denetimi gibi çeşitli alanlarda ve ayrıca insan çabalarını kolaylaştırmak için gelişen teknolojilere uygulanmaktadır (Saxena vd., 2021). YZ, mevcut otomasyon teknolojilerinden farklıdır, çünkü aynı giriş talimatlarının tam olarak aynı sonuçları ürettiği önceden programlanmış eğer-o zaman (IF-ELSE-THEN) mantığına göre kararlar almamaktadır. Bunun yerine, YZ bazı öğrenme yetenekleri sergileyerek bir adım daha ileri gitmektedir (Russell ve Norvig, 2022:44).

Gelişme, büyüme ve karar stratejilerinde YZ teknolojilerini kullanan şirketler için, veri ihtiyacı, verileri değerli (maddi olmayan) bir kaynağa dönüştürmüştür. 2017'de The Economist Magazine, "dünyanın en değerli kaynağının artık petrol değil, veri olduğunu" iddia eden bir makale yayınlamıştır. Veriye dayalı ekonomide, büyük firmalar ürettikleri veri nedeniyle önemli bir avantaja sahiptir (Farboodi vd., 2019). Yaşadığımız zamanda yapay zekanın bu denli önem kazanmasının temelinde ABD, Çin ve AB (WIPO 2019) ve bu ülkelerdeki yüksek teknolojlili yapay zeka şirketleri neden olmuştur. Bu ilerlemeler ile Netflix, Google, Airbnb, Amazon ve Uber gibi şirketler, yapay zeka ile büyük miktarda veriyi işleyebilmekte ve sonuçları yeni ürünler, pazarlar ve hizmetlerle kapsamalarını genişletmek için kullanabilmektedir (Lansiti ve Review, 2020). İş dünyasının rekabet senaryosunda yüksek hacimli veriler, kıt kaynaklar ve karar vermede hız ihtiyacı göz önüne alındığında, birçok kuruluş, başta en iyi dijital şirketler yıkıcı potansiyelleri nedeniyle YZ teknolojilerini benimsemeye motive olmaktadır (T. Davenport ve Review, 2018). Ayrıca şirketler,

farklı iş boyutlarında değer yaratmak için karar vermede veriler aracılığıyla öngörü kazanmak, müşterileri ve çalışanları süreçlerine dahil etmek, yeni ürün ve hizmetler tasarlamak ve sunmak gibi imkanlar nedeniyle neredeyse tüm sektörler yapay zekadan yararlanmaktadır (Kiron ve Review, 2019) (Davenport, 2018). Robotiğin arkasındaki itici güç yapay zeka teknolojisidir, otonom araçların gelişimi ve Tesla gibi şirketlerin tasarladığı araçlar ile artık ehliyete ya da bir sürücü ihtiyacına gerek kalmayacak yapay zeka sayesinde istenilen rotaya otomatik pilot ile gidilebilecektir. Eğitim sektöründe kişiselleştirilmiş bir plan oluşturulması ve buna göre ders programı, ders içerikleri, önemli notlar gibi içeriklerin yapay zeka tarafından öğrenciye sunulması, akıllı içeriklerin oluşturularak aynı sınıftaki öğrencilerin kişiselleştirme yoluyla animasyonlar ve öğrenme içeriğinde farklı ara yüzler görmesi yapay zeka tabanlı bir eğitim sürecinin getirdiği olanaklardır. Sağlık sektöründe yapay zeka uygulamaları olan Fitbit veya iWatch ile bireyin uyku düzeni, yaktığı kalori, kalp atış hızı ve daha pek çok veri toplanmakta ve bunlar erken teşhis, sağlık ve ilaç sektöründe kişiselleştirme ve hastanın takibine yardımcı olmaktadır. Yoğun bakım ünitesi transferlerini tahmin etmek, klinik iş akışlarını iyileştirmek ve hatta bir hastanın hastane kaynaklı enfeksiyon riskini saptamak için yapay zeka kullanılmaktadır. Sosyal medya uygulamaları YZ algoritmaları sayesinde, kişilerin ayrıntılı demografik özelliklerini çıkarabilmekte ve davranışsal hedeflemeye dayalı olarak kullanıcılarına hedefli reklam yayınlamakta üstün bir yetenek sergilemektedir (TechVidvan , 2021).

Yapay zeka alanının günümüzde müthiş bir momentum kazandığı su götürmez bir gerçektir. Özellikle Google, Facebook ve Amazon gibi şirketlerin yapay zekayı kendi iş modellerinin merkezine almış olmaları rekabetin merkezine yapay zekayı koymuştur. Buna benzer bir rekabet dinamiği ülkeler arasında da yaşanmaktadır. Yapay zeka askeriye, istihbarat şirketleri ve otoriter devletlerde gözetim ve denetim sistemleri için olmazsa olmaz bir teknoloji haline gelmiştir (Ford, 2020:264). Günümüzde, sadece dünya devi şirketler değil dünyanın dört bir yanındaki ülkeler de yapay zekada lider olmak istemekte ve avantaj elde etmek için gelişmiş bilgi ekonomilerinden yararlanmak istemektedirler. ABD ve Çin yapay zekada küresel liderler olsa da diğer ülkeler de yapay zeka teknolojisine büyük yatırımlar yapmaktadır. Türkiye Yapay Zeka İnisyatifi'nin yayınladığı girişim haritasında

Türkiye’de 2017 yılında 24 olan yapay zeka girişim sayısının 4 yılda 8 kattan fazla artarak, 200’ü aştığı belirtilmiştir (Türkiye Yapay Zeka İnsiyatifi, 2021) İsrail hem askeri hem de ticari amaçlarla YZ teknolojilerine yoğun bir şekilde yatırım yapmasının yanı sıra robotiğe de yatırım yapmaya başlamıştır. Bu hamleler, Rus yatırımlarının Vladimir Putin'in 2017'deki “yapay zeka sadece Rusya için değil, tüm insanlık için gelecek” şeklindeki açıklamasını takip ettiğini göstermektedir. Singapur, yatırımları çekmek için bir teknoloji merkezi olarak rolünü güçlendirerek, YZ yatırımlarında Güneydoğu Asya'ya liderlik etmekte, Güney Kore ise yalnızca yapay zekanın ticari uygulamalarına yatırım yapmakla kalmazken, aynı zamanda askerden arındırılmış bölgenin izlenmesine yardımcı olmak için algoritma tabanlı sistemler kullanmaktadır. Bu yatırım kalıpları, özellikle yapay zekanın sermaye yoğun ülkelere fayda sağlayabileceğini de göstermektedir (Horowitz vd., 2018:8). 2011 yılında, California'daki Santa Cruz Polis Departmanı, suçların yoğun olduğu noktaları tahmin etmek için yapay zeka tabanlı bir analitik aracı pilot olarak çalıştırmış ve mülkiyet suçlarında %27'lik bir azalma sağlanmıştır (Goldsmith ve Crawford, 2014). 2016 yılında, Avustralya Vergi Dairesi, vergilerle ilgili soruları olan vatandaşlara yardımcı olmak amacıyla bir sohbet robotu geliştirmiş ve bu, ilk temasta çözüm oranının %80'e yükseldiği belirtilmiştir (Sun ve Medaglia, 2019a).

Yapay zekanın alt bileşenleri olan makine öğrenmesi ve derin öğrenme, en sık kullanılan yöntemlerdendir. Bu yöntemler, verileri belirli bir mantıksal yapıya göre sürekli analiz ederek, araştırmacılar, işletmeler ve devlet kurumları tarafından öncelikle öngörü çıkarmak için kullanılmaktadır.

## **2.2. Makine Öğrenmesi**

Makine Öğrenmesi terimi, 1959'da bilgisayar oyunları ve YZ alanlarında Amerikalı öncü olan Arthur Samuel tarafından kullanılmıştır. Samuel makine öğrenmesini “bilgisayarların açıkça programlanmadan öğrenme yeteneği sunan çalışma alanı” şeklinde ifade etmiştir (McCarthy ve Feigenbaum, 1990). Yarım asırdan fazla bir süre önce formüle edilen bu tanımdan, makine öğrenmesinin yeni bir alan olmadığı açıktır. Ancak o zamanlar bilgisayarlar, önerilen teknikleri uygulamak için yeterince hıza ve

hafızaya sahip olmadığından bu alanda istenen gelişmeler yaşanmamıştır. Makine öğrenmesi, büyük depolama alanına ve işleme gücüne sahip bilgisayarların kullanılabilirliği nedeniyle 1990'ların başında tekrar popülerlik kazanmıştır. 1998'de Tom Mitchell, makine öğrenmesi kavramını şu şekilde yeniden tanımlamıştır: “*Bir bilgisayar programının, G görevlerindeki P ile ölçülen performans, deneyim D ile iyileşiyorsa, o bilgisayar programının bazı G görevlerinin sınıflarına ve performans ölçüsü P ile deneyim D'den öğrenmesidir*”. Örneğin, bir kişinin spam olan ya da olmayan e-postaları belirttiği ve buna bağlı olarak istenmeyen postaların nasıl daha iyi filtrelenebileceğini öğrenen bir e-posta programı olduğunu varsayalım. Bu nedenle, e-postaların spam veya spam olmayan olarak sınıflandırılması Görev G, kullanıcıyı izlemek ve e-postaları işaretlemek ise Deneyim D olmaktadır. Spam olan ve spam olmayan şeklinde doğru sınıflandırılan e-postaların tüm e-postalara oranı ise Performans P olarak ifade edilmektedir (Bhatia, 2019b:5).

Makine öğrenmesi ve yapay zeka terimleri genellikle birbirinin yerine kullanılmaktadır. Bu kavramlar bağlantılı olsa da bazı farklılıklar bulunmaktadır. Yapay zekanın amacı, insan zihnini taklit edebilen bir makine yaratmaktır. Bunu yapmak için, öğrenme yeteneklerine sahip bir makineye ihtiyaç duyulmaktadır. Yapay zeka ayrıca bilgi temsili, soyut düşünmeyi ve akıl yürütmeyi de kapsamaktadır. Makine öğrenmesinin odak noktası ise, geçmiş deneyimlerden öğrenebilen yazılımlar üretebilmektir. Bu nedenle, yapay zeka bir makinede insan özelliklerinin yeniden yaratılmasının somutlaşmış hali iken, makine öğrenmesinin odak noktası yalnızca yeni veri sunulması durumunda kaldığında değişebilen ve öğrenebilen bilgisayar programlarıdır (Kelleher vd., 2020). Nasıl ki bir çocuk dünyada kendi başına doğru ile yanlış ayırt etmeyi öğrenemezse, makine öğrenmesi algoritmalarının da başarılı bir şekilde verilerden öğrenmesi, modelin inşa edilmesi ve modelin performansının geliştirilmesi için insana ihtiyaç duymaktadır.

Makine öğrenmesinin gerçek dünya uygulamalarında farklı kullanım alanları ve kullanım amaçları bulunmaktadır. Makine öğrenmesi, Google ve Bing gibi arama motorları tarafından web sayfalarını sıralamak veya hangi kullanıcıya hangi reklamın gösterileceğine karar vermek için de kullanılmaktadır. Facebook ve Instagram gibi



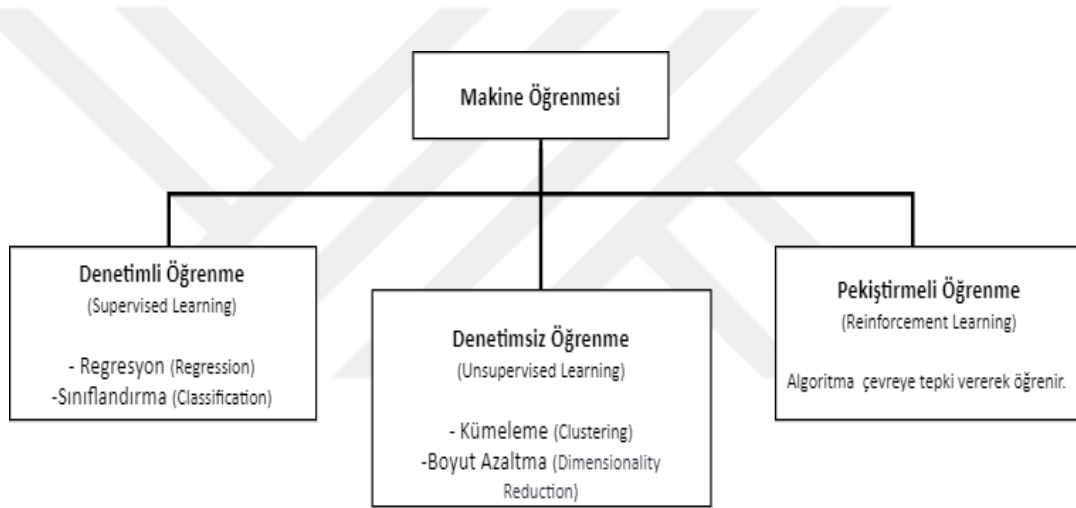
sosyal ağlar tarafından her kullanıcı için özel bir besleme oluşturmak veya kullanıcıyı yüklenen resme göre etiketlemek için makine öğrenmesi algoritmaları kullanılmaktadır. Ayrıca bankalar tarafından çevrimiçi bir işlemin gerçek mi yoksa sahte mi olduğunu tespit etmek için ya da Amazon ve Flipkart gibi e-ticaret siteleri tarafından satın alınma olasılığı en yüksek olan ürünleri önermek için yine makine öğrenmesi algoritmaları kullanılmaktadır. Bunlar, makine öğrenmesinin popüler uygulamalarından bazılarıdır (Bhatia, 2019a:1).

Makine öğrenmesi algoritmalarında eğitimin başlayabilmesi için modele girdi verilmektedir. Girdi verileri, gen dizilerini içeren biyolojik veriler, bir hastalığın çeşitli özelliklerinin ölçümleri, görüntüleri veya farklı kimyasal reaksiyonların nasıl meydana geldiğine ilişkin veriler ya da ses dosyalarını içeren farklı türde veriler olabilmektedir. Veriler ayrıca finans veya bankacılık, perakende, devlet verileri, ulaşım ve eğlence gibi çeşitli alanlardan da olabilmektedir. Tüm bu alanlarda, belirli bir örüntüye ilişkin eğilim bulunabilmekte ve bu tür bir eğilim daha fazla araştırmaya yardımcı olabilmektedir. Bu eğilimlerin tespiti sayesinde işletmelerin yanı sıra hükümetler de harcamalardan tasarruf edebilmekte, hükümetin kamu hizmetlerini sağlamada iyileştirmeler yapabilmekte ve kural ve düzenlemelerde değişiklik yapmasına olanak sağlamaktadır (örn. Trafik kuralları düzenlemeleri) (Saxena vd., 2021:24).

Makine öğrenmesi algoritmaları, geçmiş deneyimlerden öğrenmek ve büyük, yapılandırılmamış ve karmaşık veri kümelerinden faydalı kalıpları tespit etmek için çeşitli istatistiksel ve optimizasyon yöntemlerini kullanmaktadırlar (Uddin vd., 2019). Bu algoritmalar, otomatik metin kategorizasyonu (Sebastiani, 2002), ağa izinsiz giriş tespiti (Sultana vd., 2018), önemsiz e-posta filtreleme (Almomani vd., 2013), kredi kartı sahtekarlığının tespiti (Awoyemi vd., 2017), müşteri satın alma davranışı tespiti (Madani, 2009), üretim sürecini optimize etme (Syafudin vd., 2018) ve hastalık modelleme (Sajda, 2006) olmak üzere çok çeşitli uygulamaların geliştirilmesine yardımcı olmaktadır.

Makine öğrenmesinin ana fikri, algoritmanın daha önceden bilmediği, fakat bazı verileri gördükten sonra tahmin edebileceği matematiksel işlevleri kullanarak

gerçekliğin temsil edilebilmesidir. Makine öğrenmesinde gerçekleşen öğrenme süreci matematiksel ve belirli girdilerin belirli çıktılarla ilişkilendirilmesiyle gerçekleşmektedir. Öğrenme süreci genellikle eğitim olarak tanımlanmakta, algoritma, sunulan her soruya doğru yanıtı (çıktıyı) eşleştirmek üzere eğitilmektedir (girdi) (Mueller ve Massaron, 2016:20). Öğrenme, bilgi edinme süreci olarak ifade edilmektedir. İnsanlar, akıl yürütme yetenekleri nedeniyle deneyimlerden öğrenmektedir. Buna karşılık, bilgisayarlar ise akıl yürüterek değil algoritmalarla öğrenebilmektedirler. Günümüzde literatürde önerilen çok sayıda makine öğrenmesi algoritması bulunmakta (Portugal vd., 2018) ve bunlar öğrenme süreci için kullanılan yaklaşıma göre sınıflandırılmaktadır (Bhatia, 2019b:5).



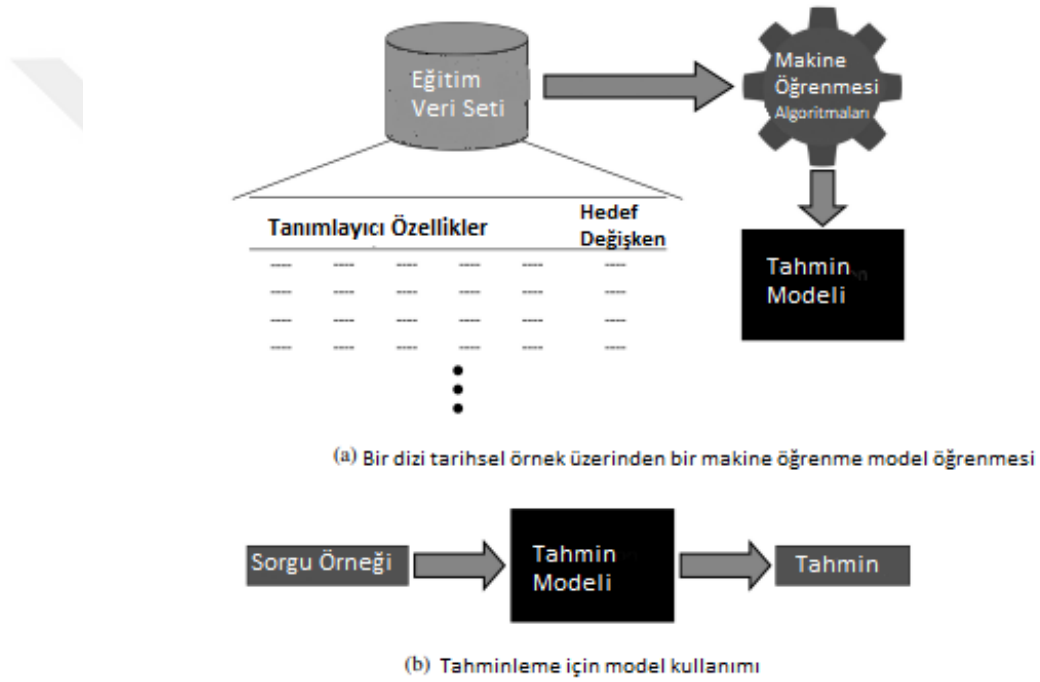
Şekil 6. Makine öğrenmesi algoritmalarının sınıflandırılması

Makine öğrenmesi teknikleri:

- 1) girdi ve çıktı sağlayan veri örneklerinin mevcut olduğu denetimli öğrenme,
- 2) yalnızca girdi verilerinin mevcut olduğu denetimsiz öğrenme ve
- 3) yalnızca girdi verilerinin mevcut olduğu ve tahminin kalitesini gösteren bir geri besleme döngüsünün olduğu pekiştirmeli öğrenme olarak üç ana senaryo ile özetlenmektedir (Lison, 2015).

## - Denetimli Öğrenme

Makine öğrenmesi, verilerden kalıpları çıkaran otomatik bir süreç olarak tanımlanmaktadır. Tahmine dayalı veri analizi uygulamalarında kullanılan modelleri oluşturmak için denetimli makine öğrenmesi kullanılmaktadır. Denetimli makine öğrenmesi teknikleri, bir dizi tarihsel örnek veya örneğe dayalı olarak bir dizi tanımlayıcı nitelik ile hedef nitelik arasındaki ilişkinin modelini otomatik olarak öğrenmektedir. Daha sonra bu model yeni örneklerde tahminler yapabilmek amacıyla kullanılabilir (Kelleher vd., 2020:5). Bu iki ayrı adım, Şekil 7'de gösterilmiştir.



Şekil 7. Denetimli makine öğrenmesi süreci

(a) öğrenme ve (b) tahmin etme.

Denetimli öğrenme algoritmaları, sınıflandırma ve tahmin yapan gerçek zamanlı uygulamalarda ve pratik yaklaşımlarda kullanılmaktadır. Denetimli öğrenmede, ilgilenilen sonucun değerini içeren (örneğin, satın alma veya satın almama) verinin mevcut olması gerekmektedir. Bu tür veriler, her kayıt için etiket (yani sonuç değeri) içerdikleri için "etiketli veriler" olarak da adlandırılmaktadır. Öğrenmedeki denetim, eğitim veri setindeki etiketli örneklerden gelmektedir. Makinenin asıl amacı, bu

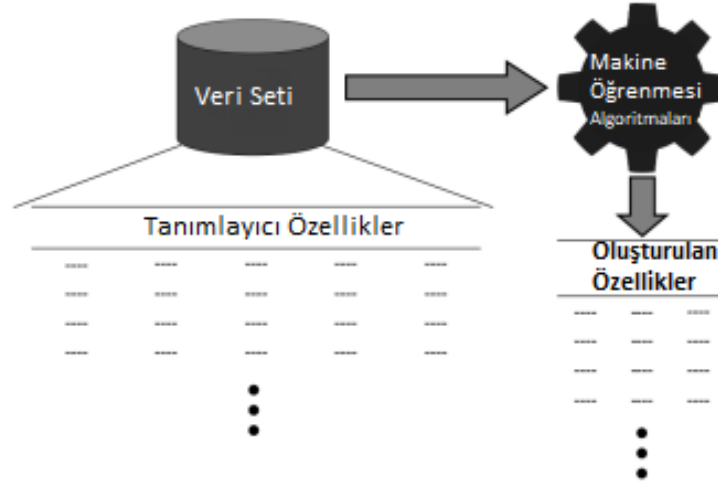
etiketin altında yatan örüntüyü veya matematiksel denklemi ortaya koymak ve nihayetinde bu etiketi tahmin edebilecek noktaya gelmektir. İngilizce olarak Supervised Learning şeklinde ifade edilen bu model için ‘danışmanlı öğrenme’ tabiri de kullanılmaktadır. Danışman sözcüğü bir insanı işaret ettiği için bu tez kapsamında tercih edilmemiştir. Etiketli öğrenme veya etiketten öğrenme ifadeleri supervised learning ile söylenmek istenen modeli daha iyi tanımlamaktadır.

Algoritma eğitim verilerinden öğrenme aşamasını tamamladıktan sonra, diğer modellere kıyasla ne kadar iyi olduğunu görmek için sonucun bilindiği ancak başlangıçta modele gösterilmeyen başka bir etiketli veri örneği ile (doğrulama verileri) test edilmektedir (Shmueli, vd., 2017:36).

Sınıflandırma ve regresyon problemleri, denetimli öğrenmenin kullanıldığı alanlardan bazılarıdır. Regresyon yaklaşımları, sürekli bir değişkeninin değerini tahmin etmeyi amaçlamaktadır. Regresyon örnekleri arasında hisse senedi fiyatı, bir evin değeri ya da bir kişinin gelirini tahmin edebilme yer almaktadır. Sınıflandırma yaklaşımları, gizli çıktı değişkenlerinin değerlerini tahmin etmeyi amaçlamaktadır. Sınıflandırma değişkenlerinin örnekleri arasında e-posta türü (istenmeyen e-posta veya istenmeyen posta değil), bir kişiye kredi verilip verilmeyeceği (evet veya hayır), hastanın kanser olup olmadığı (evet veya hayır) ya da uygulamanın kötü amaçlı yazılım olup olmadığı gibi örnekler gösterilebilir (Fred Guyton, 2021). Denetimli öğrenmeye bir diğer örnek ise bir Chihuahua türünü gösteren görüntüler ile bir çörek gösteren görüntüleri ayırmak için etiketlenmiş büyük bir görüntü veri tabanı kullanılması gerektiğidir (Kaplan ve Haenlein, 2019). Denetimli öğrenme, girdi değişkenlerine (X) ve bununla birlikte bir çıktı değişkenine (y) sahip olan ve girdiden çıktıya eşleme işlevini öğrenmek için ( $y = f(X)$ ) kullanılan öğrenmedir. Denetimli öğrenme için geliştirilmiş algoritmaların (Naive Bayes, Lojistik Regresyon, Destek Vektör Makineleri, Rastgele Orman Algoritması, Yapay Sinir Ağları) her biri çıktının değerini tahmin etmek için farklı metodolojiler kullanılmaktadır (Shaikh vd., 2021, s.38).

## - Denetimsiz Öğrenme

Denetimsiz öğrenmede, algoritmalar önceki deneyimlerden haberdar olmadan benzersiz bir model veya özellik keşfetmeye çalışmaktadır. Matematiksel olarak, bu tür öğrenme, modelin girdisi (X) olduğu, ancak karşılık gelen bir çıktıya sahip olmadığı durumdur. Bu tür öğrenme denetimsiz öğrenme olarak adlandırılmakta çünkü makine veya sistem kendisi girdinin cevabını bulmaktadır (Shaikh vd., 2021). Denetimsiz öğrenme algoritmalarında, tahmin edilecek veya sınıflandırılacak çıktı değişkeninin olmamasından ötürü aslında tam olarak bir öğrenme söz konusu olmamaktadır (Shmueli vd., 2017:35). Denetimli öğrenme, bir dizi tanımlayıcı nitelik ile bir hedef nitelik arasındaki ilişkinin modelini otomatik olarak öğrenmesi iken hedef niteliğin olmadığı durumlarda denetimsiz öğrenme teknikleri kullanılmaktadır (Şekil 8).



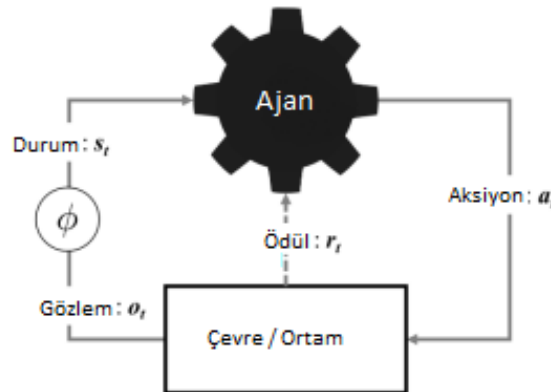
Şekil 8. Denetimsiz makine öğrenmesi süreci

Büyük miktarda veri göz önüne alındığında makine, veri seti içindeki veriler ya da gözlemler arasındaki benzerlik eğilimlerini ayırt edebilmektedir. Denetimsiz öğrenme algoritmaları kullanılarak orijinal verilerin alt kümeleri tespit edilebilmekte, verilerdeki aykırı değerler belirlenebilmekte veya verilerin düşük boyutlu temsilleri üretilebilmektedir (Yu vd., 2018). Birliktelik kuralları, boyut indirgeme yöntemleri ve

kümeleme algoritmaları denetimsiz öğrenme yöntemleri arasındadır. Günlük teknolojik gelişmeler kapsamında Apple'ın Siri ve Amazon'un Alexa uygulaması konuşma tanıma, denetimsiz öğrenme kullanılarak gerçekleştirilmiş uygulamalardan bazılarıdır (Kaplan ve Haenlein, 2019). Denetimli ve denetimsiz öğrenme bazı durumlarda birlikte de kullanılabilir. Örneğin, kredi başvuru sahiplerini çeşitli risk seviyesi gruplarına ayırmak için denetimsiz kümeleme yöntemleri kullanılmaktadır. Daha sonra, denetimli algoritmalar, kredi temerrüt eğilimini tahmin etmek için her bir risk seviyesi grubuna ayrı ayrı uygulanabilmektedir (Shmueli vd., 2017:36).

### - Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, denetimli ve denetimsiz öğrenme süreçlerinden farklılık göstermektedir. Pekiştirmeli öğrenme ödül-ceza sistemi süreci ile ilerlemektedir. Bu öğrenmede, makine veya sistem, belirli bir girdi için çıktıyı maksimize edecek belirli eylemlerde bulunmaktadır. Pekiştirmeli öğrenme, ödülü maksimize etmek ve cezayı en aza indirmek için parametrelerin güncellendiği öğrenme türü olarak tanımlanmaktadır. Pekiştirmeli öğrenmede girdi dış ortamdan alınmakta ve çıktı eylem olarak üretilmektedir. Bu öğrenmedeki amaç makinenin ya da sistemin çevreyle etkileşime girmesi ve çevreden geri bildirim alarak, ödülleri maksimuma çıkartabilecek hareket tarzını bulabilmesidir. Ödül veya ceza, çevreden verilmekte ve mümkün olduğunca fazla ödülün alınması ve cezadan kaçınılması için parametreler güncellenmektedir (Jo, 2021:16).



Şekil 9. Gözlem, ödül, eylem döngüsü

Pekiştirmeli öğrenmenin açıklandığı Şekil 9’da ajan, bir ortam içinde bir görevi tamamlamaya çalışan akıllı bir etmen (araç) olarak düşünülebilir. Ajanın amacı, görevi mümkün olduğunca başarılı bir şekilde tamamlamaktır. Görevdeki her deneme bölüm olarak ifade edilmektedir. Zamanın herhangi bir noktasında ( $t$ ), ajan çevresinin mevcut durumunu gözlemlemekte,  $o_t$ ; bir eylem seçmek için bu gözlemleri dikkate almakta ve bu eylemi gerçekleştirmektedir. Eylemin iyi mi yoksa kötü bir eylem mi olduğu konusunda çevreden anında geri bildirim almaktadır ( $r_t$ ). Pekiştirmeli öğrenmede geri bildirim yaygın olarak ödül (ödülün olumlu veya olumsuz olabileceği) adı verildiğinden, geri bildirim atıfta bulunmak için  $r_t$  kullanılmaktadır. Bu, ( $o_1, a_1, r_1$ ), ( $o_2, a_2, r_2$ ),..... ( $o_e, a_e, r_e$ ) bölümü oluşturan bir dizi ayrık adım oluşmaktadır. Her zaman adımında ajan, çevrenin bir gözlemini yapmakta ( $o_t$ ) ardından bir eylemde bulunmakta ve bu eyleme dayalı olarak bir ödül/ceza,  $r_t$  almaktadır (Kelleher vd., 2020:639). Bebeğin ateşe dokunup elinin yanması ve sonrasında ateşi görünce çekinmesi pekiştirmeli öğrenmeye verilebilecek örneklerdendir. Bu örnekte bebek çevreyle etkileşiminden negatif geri bildirim almıştır. Denetimli öğrenmede ve denetimsiz öğrenmede, eğitim örneklerinin sabit olduğu varsayılırken bu öğrenme türünde eğitim örnekleri değişken olmaktadır. Zaman geçtikçe, aynı girdinin ödülü ve cezası bile değişkenlik gösterebilmektedir. Pac-Man’ın yukarı, aşağı, sola ve sağa hareket edebildiğini ve amacın oyunda elde edilen puanı en üst düzeye çıkarmak olduğunu bilerek Pac-Man oynamayı öğrenmeyi amaçlayan bir YZ sistemi pekiştirmeli öğrenme için verilen örneklerden bir diğeridir (Kaplan ve Haenlein, 2019).

Makine öğrenmesi temelinde kullanılan regresyon, sınıflandırma ve kümeleme algoritmaları aşağıdaki başlıklarda incelenmiştir. Ancak tez kapsamındaki araştırma konusu kümeleme algoritmaları kapsamında olduğundan bu başlık daha detaylı şekilde ele alınmıştır.

### **2.2.1. Regresyon**

Regresyon analizi, herhangi bir değişkenin bir veya daha fazla değişken ile arasındaki ilişkinin matematiksel denklem şeklinde ifade edilmesidir. Regresyon analizi, başka

yöntemler de mevcut olmasına rağmen, sayısal tahmin için en sık kullanılan istatistiksel metodolojidir. Ayrıca mevcut verilere dayalı olarak dağılım eğilimlerinin tanımlanmasını da kapsamaktadır. Girdiler ile çıktı parametresi arasındaki ilişkiyi denklem şeklinde ifade eden klasik bir tahmin modeli regresyon olarak ifade edilmektedir (Nasrabadi, 2007; Huang vd., 2012). Regresyon, sınıflandırmada iki yaklaşım çerçevesinde kullanılmaktadır: (Dunham, 2003)

□ **Bölme** : Veriler sınıfa bağlı olarak çeşitli bölgelere ayrılır.

□ **Tahmin** : Çıktı değerinin hesaplanması için formüller üretilir.

Bağımlı değişkenin tek bir bağımsız değişkenle açıklanabildiği durumlarda kullanılan regresyon "*basit regresyon*", bağımlı değişkenin birden fazla bağımsız değişkenle açıklandığı durumlarda kullanılan regresyon ise "*çoklu regresyon*" olarak ifade edilmektedir. Bunun dışında kullanılan fonksiyonun, yani oluşturulan denklemin türüne göre de "*doğrusal*" ve "*doğrusal olmayan*" regresyon analizi olarak ikiye ayrılmıştır. Bu kapsamda en küçük kareler yöntemiyle elde edilen doğrusal bir regresyon denklemi:  $y = a + b x + e$  şeklinde ifade edilmektedir. Burada  $a$  doğrusal fonksiyonun sabitidir;  $b$  ise doğrusal fonksiyonun eğimidir.  $y$  bağımlı değişkeni yani tahmin edilecek değişkeni temsil etmektedir (Shmueli vd., 2017:15) (Silahtaroglu, 2020:104). Yaygın olarak kullanılan regresyon modellerinden bazıları lineer regresyon, lojistik regresyon ve polinom regresyondur. Regresyon analizi, sayısal tahminde en sık kullanılan istatistiksel metodolojidir. Regresyon ayrıca mevcut verilere dayalı olarak dağılım eğilimlerinin tanımlanmasını da kapsamaktadır (King, 2016:38).

### 2.2.2. Sınıflandırma

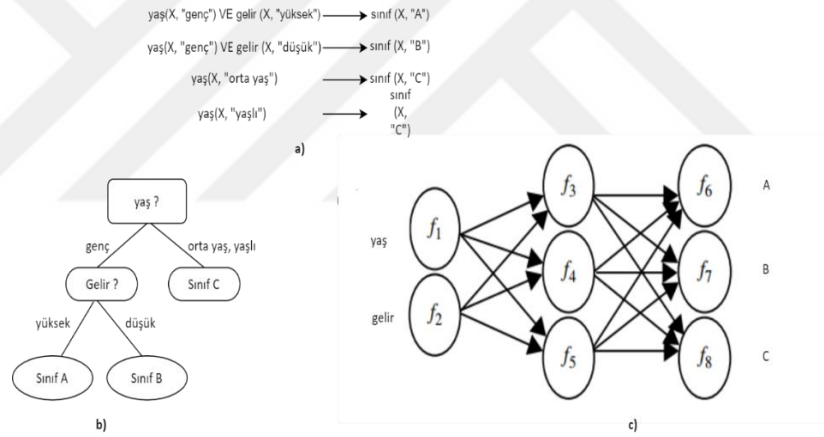
Sınıflandırma, veri sınıflarını veya kavramlarını tanımlayan ve ayırt eden bir model (veya işlev) bulma sürecidir. Sınıflandırma algoritmaları olarak adlandırılan bu tür modeller, kategorik (ayrık, sıralı, sırasız) sınıf etiketlerini tahmin edebilmektedir.



Temel olarak tahmin, yeni verilerin hangi mevcut kategoriye yerleştirileceğine karar vermek için kullanılır. Sınıflandırmayı tanımlamanın bir yolu şudur:

*Sınıflandırma = ayrık ve nominal ve ordinal değerler için tahmin,*

Genel olarak doğru bir şekilde sınıflandırmak için model inşası, model değerlendirmesi ve model uygulaması süreçleri yürütülmektedir. Modeli geliştirmek için belirli gereksinimlerin desteklenmesi gerekmektedir (King, 2016:149). Model, bir dizi eğitim verisinin (yani, sınıf etiketlerinin bilindiği veri nesnelere) analizine dayalı olarak geliştirilmektedir. Geliştirilen model, sınıflandırma kuralları (yani, IF -ELSE / Eğer- Değilse kuralları), karar ağaçları, matematiksel formüller, sinir ağları gibi çeşitli biçimlerde (Şekil 10) temsil edilebilmektedir (Jiawei Han vd., 2012:18).



Şekil 10. Sınıflandırma modeli temsilleri

**(a)eğer kuralları, (b) karar ağacı veya (c) bir sinir ağı**


Sınıflandırma, sahtekarlık tespiti, hedef pazarlama, performans tahmini, üretim ve tıbbi teşhis olmak üzere çok sayıda uygulamaya sahiptir. Bir banka kredisi memuru, hangi kredi başvuru sahiplerinin banka için "güvenli" ve hangilerinin "riskli" olduğunu öğrenmek için verilerin analizine ihtiyaç duymaktadır. Bir tıp araştırmacısı, hastanın üç özel tedaviden hangisini alması gerektiğini tahmin etmek için meme kanseri verilerini analiz etmek istediğinde sınıflandırma analizine gereksinim duymaktadır. Bu

iki örnekteki veriler için "güvenli" veya "riskli" ya da tıbbi veriler için "tedavi A", "tedavi B" veya "tedavi C" gibi sınıf (kategorik) etiketlerini tahmin etmek için bir model veya sınıflandırıcı oluşturulur (Han, vd., 2012:327).

Sınıflandırma öğreniminin başarısı, gerçek sınıflandırmaların bilindiği ancak makine tarafından kullanıma sunulmadığı bağımsız bir test veri setinde öğrenilen kavram açıklamasını deneyerek değerlendirilmektedir. Test verilerindeki başarı oranı, verinin ne kadar iyi öğrenildiğine dair objektif bir ölçü vermektedir. Pek çok pratik uygulamada başarı, öğrenilen açıklamanın (kurallar veya karar ağacı gibi) kullanıcı için ne kadar kabul edilebilir olduğu açısından öznel olarak ölçülmektedir (Witten, 2016:88).

### 2.2.3. Kümeleme

Kümeleme analizi olarak da bilinen veri kümelemenin amacı, bir dizi örüntü, nokta veya nesnenin doğal gruplaşmasını ya da gruplarını keşfetmektir. Webster (Merriam-Webster Online Dictionary, 2008) küme analizini "bir popülasyondaki bireylerin birden fazla özelliğinin nicel karşılaştırmalarını yaparak farklı gruplara ayrılıp ayrılmadığını keşfetmeye yönelik istatistiksel bir sınıflandırma tekniği" olarak tanımlamıştır.



(a) Giriş verileri

(b) İstenen kümeleme

Şekil 11. Kümeleme örneği

Şekil 11'de bir kümeleme örneği gösterilmektedir. Amaç, etiketlenmemiş verilerdeki (Şekil 11a) doğal gruplaşmaları (Şekil 11b) keşfedecek otomatik bir algoritma geliştirilmesidir. Kümelemenin diğer bir tanımı:  $n$  nesnenin bir temsili verildiğinde, aynı gruptaki nesnelere arasındaki benzerlikler yüksek iken farklı gruplardaki nesnelere arasındaki benzerlikler düşük olacak şekilde, benzerlik ölçüsüne dayanan  $K$  adet grupların keşfedilmesi olarak tanımlanmaktadır. Şekil 11 aynı zamanda kümelerin şekil, boyut ve yoğunluk açısından farklılık gösterebileceğini de ifade etmektedir (Jain, 2010).

Kümeleme kapsamında gerçek hayattan örnek olarak; bir kır yürüyüşünde daha önce hiç görmediğiniz bir bitkiye rastladığınızda etrafa bakıp farklı bitkiden birkaç tane daha olduğunu fark edebiliriz. Aslında bu bitkiler aynı değiller, fakat büyük olasılıkla aynı cinsine ait olacak kadar birbirlerine benziyorlardır. Bitkinin türünü anlamak için bir botanik uzmanına ihtiyaç duyabiliriz ancak benzer görünümlü nesne gruplarını belirlemek için bir uzmana ihtiyaç duymamaktayız. Bu durumda yaptığımız işlem yani benzer örnekleri tanımlama ve bunları kümelere veya benzer örnek gruplarına atama görevi bir kümelemedir (Géron, 2019:236). Kümeleme algoritmalarının veri madenciliği, istatistik, makine öğrenmesi, mekansal veri tabanı teknolojisi, web araması, biyoloji, pazarlama, iş zekası gibi farklı birçok uygulama alanı bulunmaktadır (Nasraoui vd., 2019:26). Kümeleme algoritmalarının müşteri segmentasyonu için kullanımında müşteriler, satın almalarına ve web sitesindeki etkinliklerine göre kümelenebilmektedir. Bu, müşterilerinin kim olduğunu ve neye ihtiyaç duyduğunu anlamak için işletmelere fayda sağlamaktadır. Ayrıca müşteri segmentasyonu yaparak aynı kümedeki farklı kullanıcıların beğendiği içeriği kullanmak öneri sistemleri için yararlı bir uygulama olarak görülmektedir (Géron, 2019:236). Bilgisayarlı görüde önemli bir problem olan görüntü bölümlenme, bir kümeleme problemi olarak formüle edilmektedir (Jain vd., 1996; Frigui ve Krishnapuram, 1999; Shi ve Malik, 2000). Belgeler ya da dokümanlar, verimli bilgi erişimini sağlamak (Janani ve Vijayarani, 2019) ve güncel hiyerarşiler oluşturmak üzere kümelenebilmektedir (Mokris ve Skovajsova, 2008). Kümeleme aynı zamanda verimli pazarlama için müşterileri farklı türlerde gruplandırmak (Kansal vd., 2018), iş gücü yönetimi ve planlaması görevlerini gruplamak (Hu vd., 2007) ya da biyolojide genom verilerini incelemek (Baldi ve Hatfield, 2002) için de uygulanabilmektedir.

Veri kümeleme, temelde üç ana amaç için kullanılmaktadır (Jain, 2010):

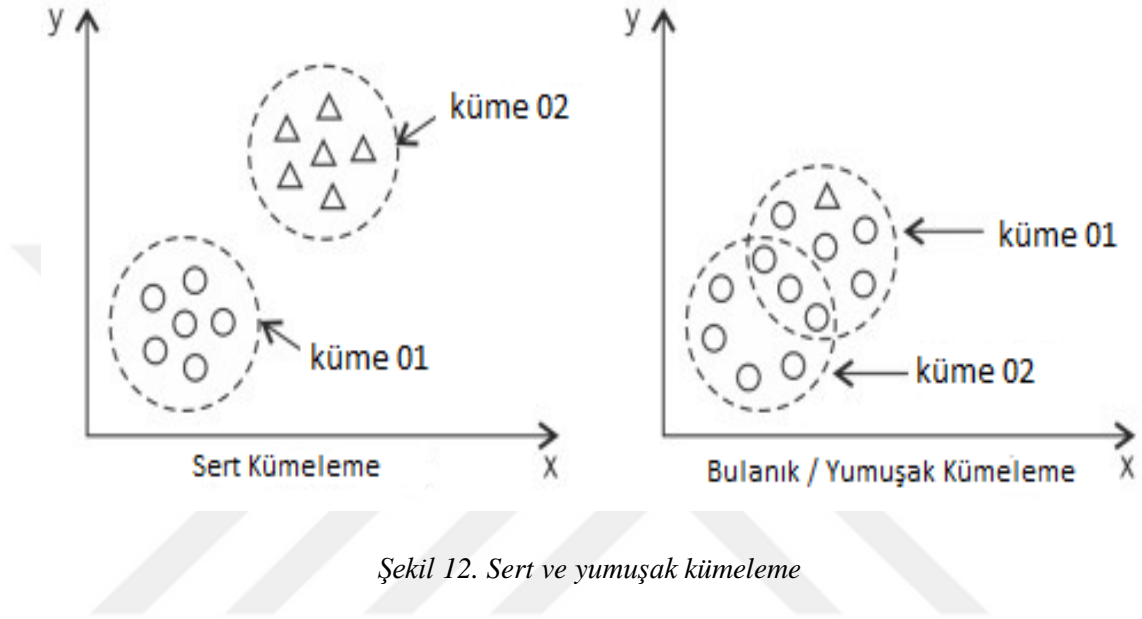
- Temel yapı: verilere ilişkin öngörü kazanmak, anormalileri tespit etmek ve göze çarpan özellikleri belirlemek.
- Doğal sınıflandırma: formlar veya organizmalar arasındaki benzerlik derecesini belirlemek (filogenetik ilişki).
- Sıkıştırma: verileri organize etmek ve küme prototipleri aracılığıyla özetlemek

Kümeleme süreci özellik seçimi, bir benzerlik ya da mesafe ölçüsünün seçimi, verilerin gruplandırılması ve çıktının değerlendirilmesi adımlarını içermektedir. Verileri kümelemek için verinin yapısını, veri miktarını ve diğer girdi parametrelerini dikkate alan farklı algoritmalar önerilmiştir. En yaygın kullanılan ve geleneksel kümeleme yaklaşımlarından ikisi, bölüm tabanlı ve hiyerarşi tabanlı kümelemedir.

Bölüm tabanlı kümeleme (centroid tabanlı kümeleme,) veri öğeleri arasındaki benzerlik ve farklılıklara göre verileri farklı gruplara ayırmayı amaçlamaktadır. Benzerlik ölçüleri uygulamadan uygulamaya farklılık göstermekte, ancak en yaygın ölçüler mesafeye, örüntüye ve yoğunluğa dayalı benzerlik ölçüleri olarak bilinmektedir. Mesafeye dayalı benzerlik ölçümlerinde, bir nesnenin küme içindeki görelî konumu, kümenin merkezi, yani ağırlık merkezi ile karşılaştırılarak hesaplamak için bir mesafe işlevi kullanılmaktadır (Aliguliyev, 2009). Merkez, küme içi ve kümeler arası mesafeler açısından kümelerin kalitesini iyileştirmek için farklı yinelemeler sırasında konumunu değiştirmektedir. Bir kümenin kalitesinin hesaplanmasında, küme içi mesafeyi en aza indiren, kümeler arası mesafeyi en üst düzeye çıkararak, benzerlikleri artıran ve veri öğeleri arasındaki farklılıkları en aza indiren amaç fonksiyonu kullanılmaktadır (Alam vd., 2014). Bölüm tabanlı kümeleme yaklaşım tekniklerinden en sık kullanılanı K-ortalamlar kümeleme tekniğidir (Jain vd., 1999).

Hiyerarşik kümeleme, veri kümesini bir hiyerarşi biçiminde kümeler arasındaki benzerlik veya farklılıklara göre iç içe geçmiş bir ağaç yapısına dönüştürmektedir. Hiyerarşik bir yaklaşım toplayıcı ya da bölümleyici olabilmektedir. Bölümleyici algoritmalarda n adet nesneden meydana gelen bir veri dizisi verildiğinde, bu veri dizisinde yer alan nesnelerin başlangıçta tanımlanan k adet alt kümeyle bölünmesi hedeflenmektedir. Hiyerarşik kümelemenin görselleştirilmesi, bir dendrogram kullanılarak ifade edilmektedir. Bölüm tabanlı kümelemenin aksine, hiyerarşik

kümelemede, önceden küme sayısının belirlenmesi gerekmemektedir. Hiyerarşik kümelemede, bir kümeye atanan bir öge, ardışık geçişlerde başka bir kümeye yeniden atanmamaktadır. Bölüm tabanlı kümelemede, nesnelere ardışık geçişlerde farklı kümelere geçebilmektedir (Alam vd., 2014).




Şekil 12. Sert ve yumuşak kümeleme

Kümeleme aynı zamanda sert (özel) veya bulanık kümeleme olarak kategorize edilmektedir. Sert kümeleme yaklaşımında, her bir girdi sadece tek bir kümeye atanırken, bulanık / yumuşak kümeleme yaklaşımında ise her bir girdi örüntüsü farklı üyelik derecesine sahip iki veya daha fazla kümeye (Şekil 12) ait olabilmektedir (Bora ve Gupta, 2014; Mesci, 2020).

### 2.3. Derin Öğrenme

Mevcut verilerdeki olağanüstü büyüme ve azalan hesaplama maliyetleriyle ortaya çıkan Derin Öğrenme (Deep Learning), makine öğrenmesi ve yapay zekada bir dönüşüme yol açmakta (Franceschetti, 2018: 476); bilgisayar görüşü (Krizhevsky vd., 2012), konuşma tanıma (Hinton vd., 2012), doğal dil işleme (Collobert ve Weston, 2008) ve öneri sistemleri (Quadrana vd., 2017) gibi çeşitli uygulama alanlarında çarpıcı bir etki yaratmaktadır. Derin öğrenme modelleri, doğrudan ham verilerden

dođru modeller oluřturmak iin tasarlanmıř, karmařık yapay nron ađlarıdır (Beam ve Kohane, 2017). Derin ğrenme, ok katmanlı ađlardaki yapay nronlardan oluřmakta ve makine ğrenmesinin bir alt kmesi olarak deđerlendirilmektedir. Derin ğrenme metodolojisi bir makinenin programlama yerine, deneyimle "ğrenme" yeteneđidir (Franceschetti, 2018:97). ođu derin ğrenme yntemi, sinir ađı mimarilerini kullanmaktadır. Bu nedenle derin sinir ađları olarak da adlandırılır. Derin ğrenmedeki "derin", aslında bir sinir ađındaki katmanların derinliđine atıfta bulunmaktadır (Goodfellow, 2016:186). Geleneksel makine ğrenmesi ile karřılařtırıldıđında, derin ğrenme, ham verilerden ğrenebildiđinden daha stndr ve girdilere dayalı zellikleri ğrenmesine izin veren birden fazla gizli katmana sahiptir (řekil 13).



řekil 13. Klasik yapay sinir ađ yapısı

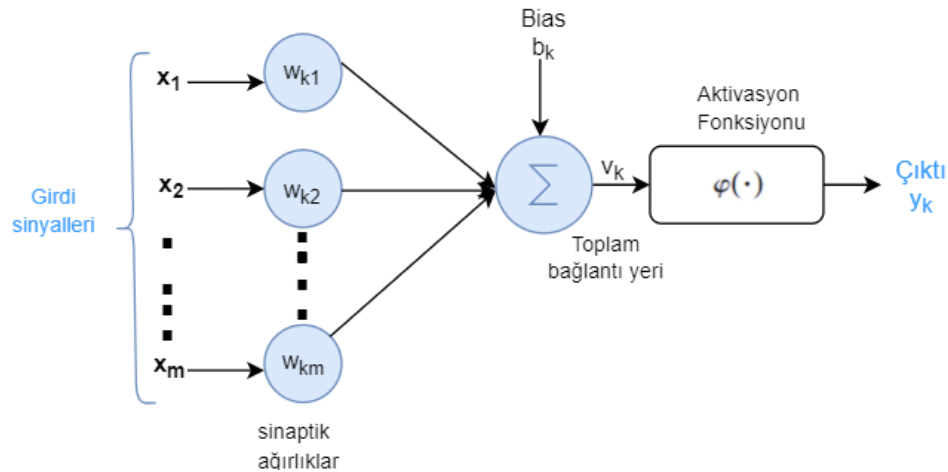
Teorik olarak, giriř ve ıkıř gibi ikiden fazla katmanı olan bir sinir ađı, derin bir mimari olarak sınıflandırılabilir. Ancak bu durum sadece katman sayısı ile ilgili deđil, daha ok her adımda daha karmařık zelliklerin otomatik olarak oluřturulması ile ilgilidir. Derin ğrenme ok sayıda veri giriřiyle ayırt edici zellikleri kendisi ğrenen bir yapıya sahiptir. ğrenme iřlemi iin ne kadar ok veri giriři olursa o kadar ok bařarı elde edilmektedir. Veriler birden ok katmandan gemekte, st katmanlar daha ok ayrıntı ıkaran katmanlar olarak belirtilmektedir. Derin ğrenme, 2011'den beri yapay zeka alanında ilerlemelerin yařanmasını nclk etmiřtir. Google, Facebook, Microsoft ve inli web hizmetleri řirketi Baidu gibi teknoloji devleri, byk miktarda

veriye erişmek için derin öğrenme uygulamaları kullanmaktadır. Microsoft ve Google, sesle etkinleştirilen aramaları, çeviri araçları ve fotoğraf aramaları dahil olmak üzere konuşma ve görüntü tanıma ürünlerini güçlendirmek için derin öğrenme algoritmaları kullanmaktadır. Facebook, insanları tanımlamak veya etiketlemek için uygulamaya bir fotoğraf yüklendiğinde yüz tanıma yazılımında derin öğrenme algoritmalarından yararlanmaktadır. Bunlardan farklı olarak derin öğrenme algoritmaları otonom araçların geliştirilmesinde de kullanılmaktadır (Franceschetti, 2018: 2). En sık kullanılan derin öğrenme algoritmaları:

- Evrişimli Sinir Ağları (Convolutional Neural Networks, CNNs),
- Uzun Kısa Süreli Bellek (Long Short-Term Memory Networks, LSTM),
- Tekrarlayan Sinir Ağları (Recurrent Neural Networks, RNN),
- Çekişmeli Üretici Ağ (Generative Adversarial Networks, GAN),
- Yarıçap Temelli Ağ (Radial Basis Function Networks, RBFN),
- Çok Katmanlı Algılayıcılar (Multilayer Perceptrons, MLP),
- Öz Düzenleyici Haritalar (Self Organizing Maps, SOM),
- Derin İnanç Ağı (Deep Belief Networks, DBNs),
- Boltzman Makinesi (Restricted Boltzman Machines, RBMs),
- Oto Kodlayıcı (Autoencoders) olarak sıralanabilir (Biswal, 2022).

Derin öğrenmede önceden eğitilmiş çoğu modelin temelini oluşturan Yapay Sinir Ağları (Artificial Neural Network, ANN), Tekrarlayan Sinir Ağları ve Evrişimli Sinir

Ağları algoritmalarıdır (Shinde ve Shah, 2018). ANN, temel ögenin yapay bir nöron olduğu, insan beyninin çalışmasını taklit etmek amacıyla önerilmiştir. ANN yaygın olarak paralel dağılım gösteren ve nöron adı verilen basit işlem birimlerinden oluşan bir işlemcidir (Haykin,2009). ANN, yüksek hızlı bilgi işleme, haritalama yetenekleri, hata toleransı, uyarlanabilirlik ve genelleme gibi özellikler sergilemektedir. Bu özellikler ANNı, farklı mühendislik sistemlerinin performansının modellenmesi, tahmini ve optimizasyonu için güçlü ve akıllı bir araca dönüştürmüştür (Elsheikh vd., 2019). Matematiksel olarak, yapay bir nöron, tüm girdilerin ağırlıklı toplamını alan ve sonucu sigmoid, doğrultucu (doğrusal birim [ReLU]) veya hiperbolik tanjant gibi bir etkinleştirme fonksiyonu ile besleyen doğrusal olmayan bir dönüşüm birimidir. En basit ANN mimarisi, bitişik katmanlardaki nöronların birbirine tamamen bağlı olduğu ileri beslemeli bir şekilde katmanları istifleyen sinir ağı olarak bilinmektedir (Elsheikh vd., 2019). Genel olarak, ANN işlem yürütürken girdiler ve ağırlıklar prensibiyle çalışmaktadır. Birçok ANN modelinin tasarımında kullanılan nöron modeli, her birinin kendi ağırlığı  $w_{km}$  olan sinaps adı verilen bir grup bağlantı linkinden oluşmaktadır. Şekil 14.'de üç girdi ve o girdilere ait üç ağırlık verilmiştir (Elsheikh vd., 2019). Yapay sinir ağları çalışırken doğrusal bir fonksiyon kurmakta ve çıktıda bu üç ağırlık ve girdiler çarpanlarıyla beraber toplanarak sonuç elde edilmektedir. Bu sürecin matematiksel gösterimi  $y_k = \varphi \left( \sum_{j=1}^m (W_{kj}) + b_k \right)$  şeklinde ifade edilmektedir.



Şekil 14. Yapay sinir ağı modeli



ANN tıpkı insan beyni gibi nöronlardan oluşmakta ve tüm nöronlar birbirine bağlı olması nedeniyle çıktıyı etkilemektedir. Nöronlar Giriş Katmanı, Gizli Katman(lar), Çıkış Katmanı olarak üç farklı katmandan oluşmaktadır. Derin öğrenme, çoklu doğrusal olmayan dönüşümlerden oluşan yapıları kullanarak hiyerarşik bir öğrenme süreciyle verilerden üst düzey temsiller çıkaran birkaç makine öğrenmesi algoritması içeren bir süreci kapsamaktadır (Khan ve Yairi, 2018).

Evrişimli sinir ağları (Convolution Neural Network) derin öğrenme alanında, en ünlü ve yaygın olarak kullanılan algoritmalarından biridir (Krizhevsky vd., 2012; Zhou, 2018). Evrişimli ağın en büyük yararı, herhangi bir insan denetimi olmaksızın ilgili özellikleri otomatik olarak tanımlamasıdır (Gu vd., 2018). Evrişimli sinir ağları, bilgisayarlı görme (Fang vd., 2020), konuşma işleme (Palaz vd., 2019), yüz tanıma (Li vd., 2020) dahil olmak üzere bir dizi farklı alanda kapsamlı bir şekilde uygulanmıştır. Evrişimli sinir ağları, bir girdi görüntüsünü alabilen, görüntüdeki çeşitli yönlere/nesnelere önem atayan ve birini diğerinden ayırt edebilen bir Derin Öğrenme algoritmasıdır. Evrişimli sinir ağlarında gereken ön işleme, diğer sınıflandırma algoritmalarına kıyasla daha az yapılmaktadır. İlkel yöntemlerde filtreler elle tasarlanırken, yeterli eğitimle evrişimli ağlar bu filtreleri/özellikleri öğrenme yeteneğine sahiptir. Evrişimli sinir ağları mimarisi, insan beyindeki nöronların bağlantı modeline benzediğinden görsel korteksin yapısından ilham alınmıştır (Barzegar vd., 2020).

Geleneksel ileri beslemeli sinir ağları, tüm girdilerin (ve çıktılarının) birbirinden bağımsız olduğunu varsaymaktadır. Bu durum aslında birçok görev için kötü bir fikir olabilmektedir. Örneğin, bir cümlede bir sonraki kelimeyi tahmin etmek için, hangi kelimelerin ondan önce geldiği bilinmesi önemli olabilmektedir ya da bir filmin bir sonraki noktasında ne tür bir olayın olduğunu sınıflandırmak için önceki olayların bilinmesi gerekli olabilmektedir. Tekrarlayan sinir ağları (Recurrent Neural Network), sıralı bilgileri kullanarak bu konuyu ele alan önemli ve popüler bir derin öğrenme sınıfıdır (Zhang vd., 2018). Apple'ın Siri ve Google'ın sesli araması tarafından kullanılan tekrarlayan sinir ağları, sıralı verileri içeren makine öğrenmesi sorunları için dahili belleği sayesinde girdisini hatırlayan ilk algoritma özelliğini taşımaktadır.

Tekrarlayan sinir ağıları, önceki hesaplamaya bağlı olarak dizideki her öge için aynı görevi gerçekleştirmektedir. Tıpkı insanın öğrenmesi gibi, bir belgeyi anlamak için kelime kelime, cümle cümle okurken bilgiyi hafızamıza kaydedilmektedir. Tekrarlayan sinir ağıları da tıpkı insan gibi öğrendiği veriyi hafızasında tutmakta ve bir karar verirken mevcut girdiyi ve daha önce aldığı girdilerden ne öğrendiğini de göz önünde bulundurmaktadır (Zhang vd., 2018). Tekrarlayan sinir ağı, kendi kendine bağlanan tekrarlayan birimler içermektedir. Her zaman adımında, bir sinir ağı, mevcut gizli durumu hesaplamak için hem son gizli durumu hem de mevcut girişi almaktadır. Mevcut gizli durum daha sonra mevcut çıktıyı hesaplamak için kullanılmaktadır. Uzun Kısa Süreli Bellek algoritması, tekrarlayan sinir ağlarının bir varyasyonudur (Tai vd., 2015).

Derin öğrenme genellikle doğrusal olmayan bir analizdir ve birçok parametreye ve birden çok katmana sahiptir; bu nedenle, aşırı öğrenme, zayıf tahmin performansına yol açabilecek büyük bir zorluk olabilmektedir. Eğitim veri kümesinin boyutunu artırmak veya gizli katmanların sayısını azaltmak, aşırı öğrenmeyi önlemeye yardımcı olabilmektedir. Derin öğrenme ayrıca kurumlar arasında iş birliği gerektiren büyük bir eğitim veri kümesine gereksinim duymaktadır (Krittanawong vd., 2017). Tez kapsamında derin öğrenme algoritması olan uzun kısa süreli bellek metodolojisi kullanılmış olup, tezin dördüncü bölümünde bu algoritmanın çalışma prensibi ele alınmıştır.

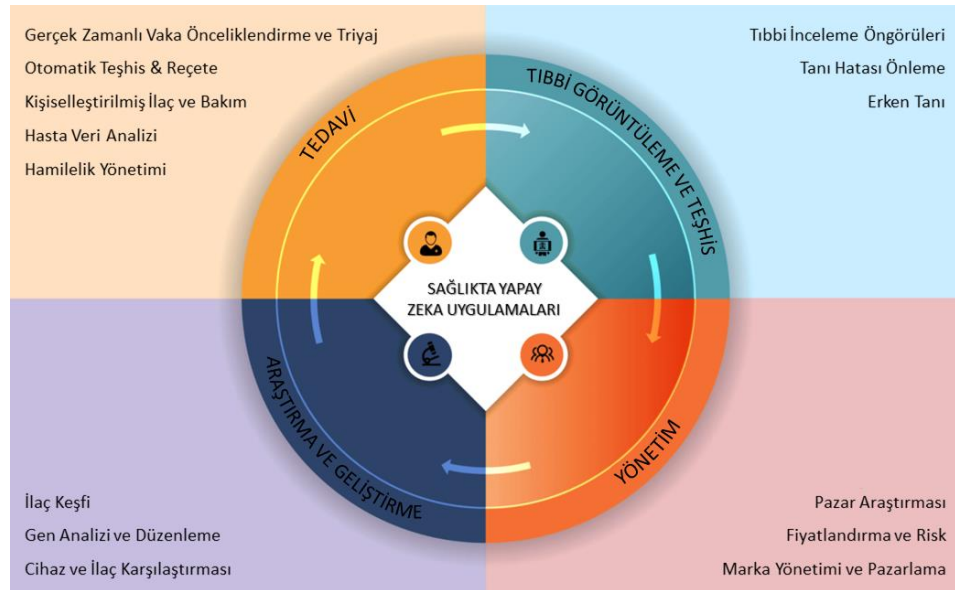
#### **2.4. Sağlıkta Yapay Zeka ve Makine Öğrenmesi Uygulamaları**

YZ ve modern sağlık hizmetlerindeki uygulamalar, bilim ve teknolojinin gelişimi ile birlikte oldukça ilerleme kaydetmiştir. Endüstri 4.0'ın gelişini ve gelişimini destekleyen kritik bir itici güç olan YZ, sağlık hizmetleri ve tıbbi teşhis alanındaki ilerleme ve yeniliklerin vazgeçilmez bir bileşeni haline gelmiştir. Sağlık hizmetleri alanında, YZ teknolojilerinin uygulanması hem hastalara hem de sağlık hizmeti sağlayıcılarına fayda sağlayan, hastalıkların tahminini, teşhisini ve tedavisini sağlarken aynı zamanda sağlık hizmetlerindeki harcamaların da azalmasını desteklemektedir (Guo vd., 2020). YZ'nin teşhis doğruluğunu iyileştirme vaadi,

heyecan verici sağlık uygulamalarından biridir. YZ hasta semptomlarını işleyerek hastalığı, çoğu tıp uzmanından daha hızlı teşhis etme konusunda etkili bir şekilde yardımcı olabildiği belirtilmektedir (Saifi vd., 2013). YZ, hastaların elektronik sağlık kayıtlarını kısa bir süre içinde yatay ve dikey olarak değerlendirerek teşhisin doğruluğunu artırmak için hekimlerin tahmin gücünü taklit edebilmektedir (Edward vd., 2016). Kanıta dayalı tıbbın özü, geçmiş verilerden elde edilen öngörüler yoluyla klinik karar verme sürecini bilgilendirmektir. Geleneksel olarak, istatistiksel yöntemler bu göreve, verilerdeki kalıpları matematiksel denklemler olarak karakterize ederek yaklaşmıştır; örneğin, doğrusal regresyon "en uygun çizgiyi" önermektedir. YZ ise makine öğrenmesi algoritmaları aracılığıyla bir denkleme indirgenemeyecek karmaşık ilişkileri ortaya çıkaran teknikler sağlamaktadır. Örneğin, sinir ağları, insan beynine benzer şekilde çok sayıda birbirine bağlı nöron aracılığıyla verileri temsil etmektedir. Bu, makine öğrenmesi sistemlerinin, mantıklı sonuçlara ulaşmak için kanıtları dikkatlice tartarak, tıpkı bir hekimin yaptığı gibi karmaşık problem çözümüne yaklaşmasını sağlamaktadır. Ancak, tek bir hekimin yapabileceklerinin aksine, bu sistemler neredeyse sınırsız sayıda girdiyi aynı anda gözlemleyebilmekte ve hızla işleyebilmektedir (Buch vd., 2018).

Sağlık hizmeti sağlayıcıları, yapay zekayı araştırma, sağlık yönetimi, teşhis ve tedavi alanlarında kullanmakta (Şekil 15.); erken teşhis ve daha iyi tedavi için mevcut hasta verilerini analiz ederek yorumlanabilmesini sağlamaktadır. Bugün, bir kişinin gözün beyaz kısmı olan skleradaki artan bilirubin seviyelerini tespit etmek için bilgisayarlı görme ve makine öğrenmesi kullanılabilir. Pankreas kanserinin ve diğer hastalıkların en erken semptomlarından biri, kanda bilirubin birikmesinin neden olduğu cilt ve gözlerde meydana gelen sarılıktır. Sarılık belirtilerini, bilirubin seviyeleri minimum düzeyde yükseldiğinde (çıplak gözle görülmeden önce) tespit etme yeteneği, risk altındaki bireyler için önemli bir gelişmedir. BiliScreen uygulaması ile kişinin çektiği öz çekim fotoğrafı bilgisayarlı görme ile işlenebilmekte ve pankreas kanseri riski yüzde 89,7 oranında tahmin edilebilmektedir (Langston, 2017). Cilt kanseri tespiti için hekimlerle birlikte geliştirilmiş yapay zeka tabanlı bir uygulama olan SkinVision, cilt fotoğraflarını değerlendirerek cilt kanserinin erken teşhis edilmesini %95 hassasiyet (%78 özgüllük) ile teşhis edebilme yeteneğine sahip

bir uygulama geliştirilmiştir (Carvalho vd., 2019). Kuzey Londra'daki 1,2 milyon insan 111 acil hattına alternatif olarak Babylon tarafından oluşturulan yapay zeka tabanlı akıllı telefon uygulaması olan bir sohbet robotu kullanılmıştır (Burgess, 2017). Sağlık hizmetlerinde YZ teknolojisi, ilaç şirketlerinin ilaç keşif sürecini hızlandırmasına yardımcı olmuştur. Pfizer, immüno-onkoloji tedavilerini bulmasına yardımcı olmak için makine öğrenmesi tabanlı bir sistem olan IBM Watson'ı kullanmaktadır (Agrawal, 2018). Sanofi, metabolik hastalık ilaçları aramak için Exscientia'nın YZ platformunu kullanmayı kabul ederken, Roche yan kuruluşu Genentech, kanser tedavileri arayışına yardımcı olmak için GNS Healthcare ile bir yapay zeka sistemi geliştirmiştir (Chan vd., 2019). Yaşanan bir diğer gelişmede sağlık personeline ek olarak, bazı tıbbi robotların hastalara yardımcı olmasına yönelik robot sistemlerin geliştirilmesidir. Örneğin robot teknoloji, felçli hastaların tekrar yürümesine ve kendi kendine yeterli hale gelmesine yardımcı olabilmekte, aynı zamanda akıllı protez, hareketli eklem teknolojisi için önem arz etmektedir (Shi vd., 2019). Robotlar, kesin hareketleri tekrarlamak için insanüstü yeteneğe sahip olmaları nedeniyle rehabilitasyon ve ameliyata da yardımcı olabileceği düşünülmektedir. Örneğin saç ekimi ameliyatlarında robot, saç köklerini toplamakta ve ardından saç derisindeki hedeflenen bölgelere foliküler üniteleri hassas şekilde yerleştirebilmektedir (Cruciger vd., 2016).



Şekil 15. Sağlıkta yapay zeka uygulamaları

YZ destekli sistemler bir hekimin görebileceğinden daha fazla vakaya ulaşip her vakadan bir şeyler öğrenebilmekte ve dakikalar içinde sonucu öngörebilecek yeteneğe ulaşabilmektedirler. Bu nedenle, yapay zeka güdümlü bir uygulama, şüpheli cilt lezyonlarını doğru bir şekilde sınıflandırmada dermatologlardan daha iyi performans gösterebileceği ifade edilmektedir (Esteve vd., 2017). Uzmanların genellikle anlamadığı durumlarda, örneğin göğüs radyografilerinde akciğer tüberkülozunu tanımlama gibi görevlerde YZ teknolojileri hekime hızlıca karar verme olanağı sağlamaktadır (Lakhani ve Sundaram, 2017). Veriye dayalı genom dizilimi, fitness/aktivite izleyicileri, elektronik sağlık kayıtları gibi farklı birçok kaynaktan üretilen veriler, günümüzün sağlık hizmeti sağlayıcıları için akıl almaz bir maden niteliği taşımaktadır. Tüm bu büyük veriler, sağlığımız veya tıbbi durumumuz hakkında daha öngörülü bir tablo oluşturmak için derleniyor ve birbirine bağlanıyor (Buch vd., 2018). Veriye dayalı tıp, yalnızca genetik hastalık tespitinin kesinliğini ve çevikliğini geliştirme potansiyeline sahip olmakla kalmamakta, aynı zamanda kişiselleştirilmiş tıbbi tedavilere kapı açma potansiyeli taşımaktadır (Hummel ve Braun, 2020). Sağlık alanında yapay zeka ve makine öğrenmesi, diyabet (Contreras ve Vehi, 2018), kanser (Bi vd., 2019), kardiyoloji (K. W. Johnson vd., 2018) ve ruh sağlığı (Lovejoy, 2019) dahil olmak üzere birçok hastalığın araştırılmasında uygulanmıştır. Makine öğrenmesine dayalı bilgisayar tabanlı karar destek sistemleri, şu anda uzmanlara atanan karmaşık görevleri yerine getirerek tıpta devrim yaratma potansiyeline sahiptir. Makine öğrenmesi sistemleri tanı doğruluğunu artırabilir, kapsamlı yerleştirmelerin verimliliğini artırabilir, klinik iş akışını daha iyi düzene sokabilir, insan kaynaklı maliyetleri azaltabilir ve tedavi seçeneklerini iyileştirebilir (Goldenberg vd., 2019). Yapılan bir çalışmada diyabetik retinopatiyi belirlemek için diyabetli yetişkin hastalardan alınan 128.000'den fazla retinal fundus görüntüsünden oluşan bir test setine derin CNN yaklaşımı uygulanmıştır. Geliştirilen algoritma, diyabetik retinopati ve makula ödemi saptamak için çok yüksek bir duyarlılık (%96,1) ve özgüllük (%93,9) göstermiştir. Bu çalışma, yapay zekanın doktorların yerini almak için değil, diğer hastalara retinopatinin bulunmadığına dair güvence verirken özel bakım için sevk edilmesi gereken riskli hastaları belirlemeye yardımcı olabilecek basit, uygun maliyetli ve yaygın olarak bulunan muayene ve analizleri gerçekleştirmek için kullanılacağını da vurgulamıştır (Coldiron vd., 2012). Yapılan bir

diğer çalışmada Dong ve arkadaşları (2019), Çinli hastalarda Crohn Hastalığının seyrini tahmin etmek için makine öğrenmesi algoritmalarını kullanmışlardır. Crohn hastalığı karmaşık bir hastalıktır ve seyrini tahmin etmek zordur. Önerilen makine öğrenmesi modelinde beş farklı algoritma kullanılmış en yüksek başarıyı rastgele orman algoritması (RF) göstermiştir. Önerilen makine öğrenmesi modeli, klinik uygulamada Crohn hastaları için tedavi stratejilerini uyarlamak ve değiştirmek için kullanılabilmesi sonucuna ulaşılmıştır (Dong vd., 2019). Mojjada ve arkadaşları (2020), makine öğrenmesi algoritmalarına dayalı yaptıkları çalışmada, Covid-19 salgınından etkilenen bireylerin sayısını tahmin etmeyi amaçlamışlardır. Kullanılan dört farklı makine öğrenmesi algoritmasıyla, yeni enfekte olacak kişi sayısı, ölüm oranları ve önümüzdeki 10 gün içinde iyileşecek olan COVID-19 vaka tahmini yapılmıştır. Çalışmada, yeni korona vakalarını, ölüm sayılarını ve iyileşmeyi tahmin etmede en etkili algoritmanın Lojistik Regresyon olduğu belirtilmiştir (Mojjada vd., 2020). Yapılan bir diğer çalışmada Türkiye’de Covid-19 salgınının resmi kanallar tarafından başladığının açıklandığı 11 Mart 2020 tarihinden itibaren 12 haftalık Twitter verisi çekilmiş (#Evdekal hashtag özelinde) ve bu elde edilen veriler üzerinden toplumun duygularını anlamlandırmaya yönelik bir metin madenciliği çalışması yapılmıştır. Toplumda ilk haftalar genel duygu seyri pozitif giderken yaşanan belirsizlikler, kapanmalar ve ekonomik çalkantılar sebebiyle üçüncü haftadan sonra negatif duyguların öne çıktığı ve belirsizlik kaygı gibi duyguların yükseldiği ifade edilmiştir (Silahtaroglu vd., 2020). Yüz ve ark. (2019), hafif bilişsel bozukluktan (MCI) demansa dönüşümde bilişsel rezervin rolünü araştırmak için çeşitli makine öğrenme algoritmaları (ör. doğrusal regresyon, destek vektör makineleri, Gaussian saf Bayes) kullanmıştır (Qin vd., 2020). Kardiyovasküler hastalık tahminlemede de çeşitli makine öğrenmesi (ML) algoritmaları giderek daha fazla kullanılmaktadır. Kardiyovasküler hastalıklarda makine öğrenmesi algoritmalarının genel tahmin yeteneğinin değerlendirildiği bir çalışmada MEDLINE, Embase ve Scopus veritabanlarında kapsamlı bir araştırma yapılmış ve koroner arter hastalığı, kalp yetmezliği, inme gibi rahatsızlıkların makine öğrenmesi algoritmaları ile tahmin yeteneğinin yüksek olduğu vurgulanmıştır. Toplam 344 çalışma ve yaklaşık 3 milyon bireyden oluşan 103 kohort incelenmiş, koroner arter hastalığın tahmini için, boosting algoritmalarının AUC 0,88 (eğri altında havuzlanmış alan), destek vektör makinesi

(SVM) algoritmalarının AUC değeri 0,92 (%95 CI 0,81–0,97), artırma algoritmalarının AUC değerinin 0,91 olduğu vurgulanmıştır. makine öğrenmesi algoritmalarının kardiyovasküler hastalıklardaki tahmin yeteneğinin SVM ve boosting algoritmalarında özellikle başarılı olduğu ifade edilmiştir (Krittawong vd., 2020). Kronik böbrek rahatsızlığını erken aşamada tahmin etmek için 400 hastadan oluşan bir veri setinde ANN ve destek vektör makineler (SVM) tekniklerini karşılaştıran bir çalışma gerçekleştirilmiştir. Deneylemlerden elde edilen ampirik sonuçlarda, ANN (%99,75) SVM'den (%97,75) daha iyi performans gösterdiği vurgulanmıştır (Yuan vd., 2020). Chen ve arkadaşları (2016), 386 hasta ile kronik böbrek hastalığını tahmin etmek için çok K-en yakın komşu (KNN), SVM kullanmış ve genel doğruluk %93'ün üzerinde bulunmuştur (Chen vd., 2016). Verma ve Srivastava (2015) çalışmalarında, kalp hastalıkları tahminini, ANN uygulayarak gerçekleştirmeyi amaçlamışlardır. ANN, hastanın farklı tarihlerde farklı giriş değişkenleri üzerinde eğitilmiş ve test edilmiştir. Sonuç olarak, bu sistemin tıbbi araştırmacıların ve hekimlerin günlük rutin uygulamasında yararlı olabileceği ve %99,31 oranında doğru tanı başarısının elde edilebildiği ifade edilmiştir. Ayrıca, önerilen yöntemdeki tahmini eğilimler ile doğrusal model, hareketli ortalama, bulanık kümelerin polinomu gibi diğer mevcut yöntemlerdeki tahminler karşılaştırılmış, ANN modelinin diğer yöntemlere göre daha iyi sonuçlar verdiği vurgulanmıştır (Verma ve Srivastava, 2015).

Derin öğrenmenin ana uygulama alanlarından biri tıbbi teşhistir. Teknoloji odaklı girişimci şirketler tıbbi görüntüleri analiz etmek ve ilaç geliştirmeyi desteklemek için gelişmiş görüntü tanımayı kullanmaktadır. Aynı zamanda sağlık bilşimi (Ravi vd., 2016), biyotıp (Mamoshina vd., 2016) ve manyetik rezonans görüntü MRI analizi (Liu vd., 2018) alanlarında da derin öğrenme algoritmaları kullanılmaktadır. Derin öğrenmenin tıp alanında daha spesifik kullanımları; segmentasyon, teşhis, sınıflandırma, tahmin ve çeşitli anatomik ilgi alanlarının tespitidir (Bakator ve Dragica, 2018). Diyabet sınıflandırması için, rastgele orman (RF), çok katmanlı algılayıcı (MLP) ve lojistik regresyon (LR) olmak üzere üç farklı sınıflandırıcı kullanılmıştır. Tahmine dayalı analiz için ise uzun kısa süreli bellek (LSTM), hareketli ortalamalar (MA) ve doğrusal regresyon (LR) kullanılmıştır. Analiz sırasında MLP'nin %86,08 doğrulukla diğer sınıflandırıcılardan daha iyi performans gösterdiği ve

LSTM'in ise diyabeti %87,26 doğruluk ile tahmini iyileştirdiği gözlemlenmiştir (Sherazi, 2021). Choi ve arkadaşları (2017), derin öğrenme yaklaşımının sağlık hizmetlerinde tahmine dayalı modelleme yaparken umut verici sonuçlar verdiğini ancak derin öğrenmede veri yetersizliğinin ve yorum eksikliğinin devam ettiğini ifade etmiştir. Zorlukları ele almak için Grafik Tabanlı Dikkat Modeli (GRAM) önerdikleri çalışmalarında, GRAM'da gerçekleştirilen öngörücü modelleme, tekrarlayan sinir ağları gibi diğer yaklaşımlarla karşılaştırıldığında, GRAM'ın hastalıkların tahmininde %10 daha yüksek doğruluk elde ettiği gözlemlenmiştir (Choi vd., 2017). Fagerström ve arkadaşları (2019), LSTM kullanarak sepsis ile ilgili şokları tespit etmek için derin öğrenme algoritmasına dayanan LiSep LSTM modelini önermişlerdir (Fagerström vd., 2019).

Yakın gelecekte, sağlık ortamlarının IoT (nesnelerin interneti) fırsatları aracılığıyla devrim yaratacağı düşünülmektedir. Bu teknoloji, hastanelerde ve daha da önemlisi evde hastaların tele-izlenmesinde önemli bir rol oynayacaktır. Uzaktan hasta izleme, yalnızca sağlık hizmeti kalitesini artırmakla kalmayıp aynı zamanda hastalıkları ve zararlı durumları belirleyip önleyerek sağlık bakım maliyetlerini azaltmak için muazzam olanaklar sağlayacağı da düşünülmektedir. Günümüzde, sağlık hizmetleri her zamankinden daha pahalıyken, hastaların çoğunun tedavi süreci boyunca hastanede kalması gerekmektedir. Hastaları uzaktan izleme özelliğine sahip cihazları kullanmak, maliyetin de azalmasını sağlayacaktır. IoT teknolojileri, hastanın gerçek zamanlı sağlık verilerini toplayarak hekimlere aktarması ve hasta tedavisinin evden de izlenebilmesi sayesinde sadece sağlık hizmetlerinin maliyetini düşürmekle kalmayacak, aynı zamanda sağlık sorunlarının kritik hale gelmeden tedavi edilmesini de sağlayacaktır (Guo vd., 2020). Yakın zamanda yapay zekanın sağlık alanında getirdiği gelişmelere ek olarak Metaverse ile yaşanan dönüşüm de kendini hissettirecektir. Robot destekli cerrahi sistemiyle ünlü Intuitive Surgical gibi şirketler, sanal gerçekliğe geçme konusunda dijital sağlık hizmetlerine yatırım yapmaktadır. Metaverse ile Cerrahlar sanal bir ameliyathanede buluşabilecek ve diğer uzmanlar yardımıyla ameliyatta birlikte iş birliği yapabilecekleri öngörülmektedir. Ameliyat sırasında, cerrah hastanın hayati bilgilerini, görüntülerini, geçmişini görebilecek ve birden fazla hasta verisi arasında kolayca gezinebilecektir. Gelecekte kişisel



asistanımızla veya sanal hemşiremizle anlık bağlantı kurabilecek, böylece sağlığınıza ilgili her an neler olduğunu anlatabilen ya da bildirimler yoluyla uyarı veren sistemler hayatımızda olacaktır. Covid-19 ile yaşanan pandemide hasta ziyareti kısıtlamaları nedeni ile yakınlarından uzak kalanlar Metaverse dünyasında bu durumu yaşamayacakları sunulan fırsatlar arasında görülmektedir (Ameen, 2022). Artırılmış gerçeklik ve sanal gerçeklik teknolojileri ile tıpta ilk uygulamalar başlamıştır. Johns Hopkins beyin cerrahları, hastalarda kurumun ilk artırılmış gerçeklik ameliyatlarını gerçekleştirerek hastanın kronik sırt ağrısını hafifletmek için üç omurun kaynaşması için spinal füzyon ameliyatı için hastanın omurgasına altı vida yerleştirilen bir ameliyat gerçekleştirildi. Diğer bir ameliyatta cerrahlar, bir hastanın omurgasından kordoma olarak bilinen kanserli bir tümörü çıkardılar. Doktorlar her iki hastanın da durumunun iyi olduğunu bildirmişlerdir (Winter, 2021). Metaverse dünyasında yaşanacak olan en önemli zorluğun meta veri deposundaki hasta verilerinin güvenliğinin olacağı düşünülmektedir (Ameen, 2022). Dünya teknolojiye daha bağımlı hale geldikçe, insanların mahremiyetine ve siber güvenlik şirketlerinin sunduğu çözümlere daha fazla önem verilmesi gerekmektedir. YZ hekimlerin yerini almak için değil onları desteklemek amacıyla gelişimini sürdürmektedir. Şu an geliştirilen dar kapsamlı yapay zeka ile donatılmış ürün ya da teknolojiler empati ve merhamet gibi insani niteliklerden yoksundur ve bu nedenle hastalar, konsültasyonlarını hekimler tarafından yürütülmesini istemektedir. Ayrıca, hastaların yapay zekaya hemen güvenmeleri beklenmemektedir (Oppenheim, 2016). Bu nedenle, YZ genellikle hasta yönetiminin birincil sorumluluğunu bir hekime bırakacak şekilde kapsamı yeterince sınırlı olan görevleri yerine getirmektedir. Bu uygulamalara ek olarak, YZ, personel üzerindeki yükü azaltmak, teşhis doğruluğunu geliştirmek ve hastalık yönetimini kolaylaştırmak için standart karar destek sistemlerine yardımcı olabilmektedir.

Bu tez kapsamında da hekimler için yoğun bakımda kritik hastalıkların erken tespitine yönelik yapay zeka algoritmalarından yararlanılmıştır. Amaç, veriden öğrenen ve hekimin kararlarını hızlandıran yapay zeka tabanlı bir erken teşhis sisteminin geliştirilebilmesidir. Bu sayede hastaya yönelik erken teşhis ve tedavi sağlanabilecek ve hastanın hayati tehlikesi en aza indirgenebilecektir.

## 2.5. Veri Ambarı ve OLAP

Temel olarak veri madenciliği, makine öğrenmesi ve yapay zeka uygulamaları için veri ve veri tabanı gerekmektedir; ancak işletmelerde kullanılan işlemsel veri tabanları (transactional database) doğrudan bu uygulamalarda kullanılamaz. Bu verilerin analitik veri analizi kapsamında kullanılabilmesi için veri ambarı mimarisi kullanılarak uygun hale getirilmelidir (Silahtaroglu, 2008:18).

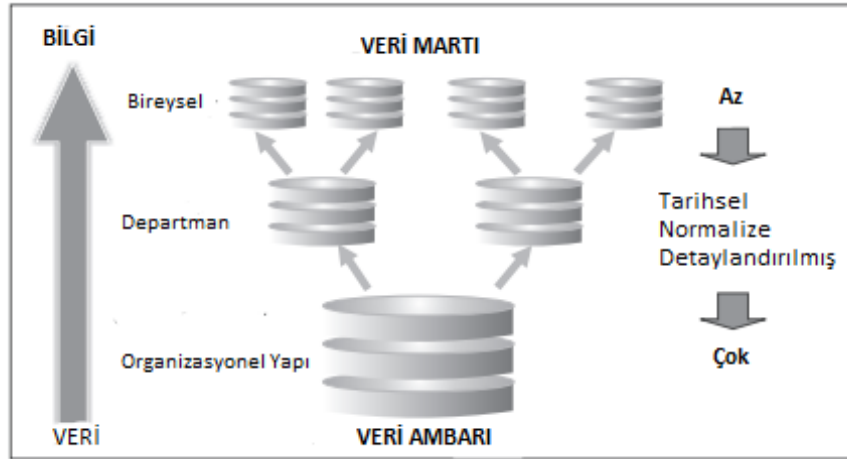
"Veri ambarı" kavramı, büyük bilgi analizi ve yönetim raporlamasını desteklemek amacıyla 1980'lerin ortalarında ortaya çıkmıştır (Wah vd., 2009). Ralph Kimball'a göre "bir veri ambarı, kaynaklardan gelen verileri ayıklayan, temizleyen, uyumlu hale getiren, bir veri deposuna aktaran ardından karar verme amacıyla sorgulama ve analizi destekleyen ve uygulayan bir sistemdir" (Kimball, 2004). Veri ambarında toplanan veriler, işletmelerde esas olarak karar vermek veya geleceği tahmin etmek için kullanıldığından veri analizi yapılmadan önce doğru bir DW mimarisinin inşa edilmesi oldukça önemlidir (Nadikattu, 2019).

Günümüzde veri ambarları yalnızca bankacılık ve finans, tüketim malları ve perakende, talebe dayalı üretim alanlarında kullanılmamakta, aynı zamanda ticari olmayan sektörlerde, özellikle tıbbi alanlarda, devlette, askeri hizmetlerde, eğitim ve araştırma camiasında da yaygın şekilde kullanılmaktadır (Eldeen, 2012). Veri ambarı, tarihsel bir veri tabanıdır ve bir işletme ya da firmanın uzun süreli hafızası olarak görülmektedir. Veri ambarları genellikle yönetim sorgularını desteklemek amacıyla Çevrimiçi Analitik İşlemler (OLAP) için kullanılır (Han vd., 2012:98). En düşük/en yüksek marjlı müşterileriniz kimlerdir, en etkili dağıtım kanalı nedir, satışların en az olduğu zaman dilimi nedir, kalp krizi zamanını tahmin etme, üretim hattındaki sorunları öngörebilme gibi soruların cevabını almak için veri ambarı mimarisi kullanılmalıdır.

Veri ambarı kavramı, Amerikalı bilgisayar bilimcisi Bill Inmon tarafından 'Yönetimin karar verme sürecini destekleyen, konu odaklı, entegre, zamanla değişen ve kalıcı bir veri koleksiyonu' olarak tanımlanmıştır (Bhatia, 2019b:395). Veri ambarı özellikleri:

- *Konu Odaklı:* Veri ambarları konu odaklıdır ve belirli konulara veya ilgi alanlarına göre sunulur; bir organizasyonun temel varlığı veya konuları etrafında inşa edilirler. Örneğin, bir Üniversitede veri konusu (incelenen varlıklar) öğrenciler, öğretmenler ve çeşitli kurslar olabilirken, şirkette konular personeller, stajyerler, hizmetler ve ürünler olmaktadır.
- *Entegre:* Bir veri ambarı, herhangi bir işletmenin verilerinin geniş bir görünümünü sağlamak için birden çok sistemden gelen verileri bütünleştirir (birleştirir), dolayısıyla bunlar entegre edilmiş/bütünleştirilmiş veridir. Temel operasyonel sistemler verileri farklı şekilde depolasa bile, tutarlı adlandırma kuralları, ölçümler, kodlama yapıları ve fiziksel niteliklerle küresel olarak kabul edilebilir bir şekilde saklanan veriler anlamına gelir (Bhatia, 2019b:395).
- *Zaman boyutu:* Veri ambarının güncel bilgilerin yanı sıra konunun geçmişini de içerdiği anlamına gelir. Veri ambarı verileri, 30 ila 60 günlük operasyonel verilerin aksine, beş ila on yıllık uzun vadeli verileri temsil eder.

Veri Ambarı (DW) birden fazla operasyonel veri tabanından, dış veri kaynaklarından ve farklı dosyalardan veri toplayan ve bu verileri temizlemek, dönüştürmek ve entegre etmek için Ayıkla-Dönüştür-Yükleme (ETL) adımlarını izleyen ardından veri ambarı ve veri martlarında bu verileri depolayan mimari bir oluşumdur (El-bastawissy vd., 2020). Veri Ambarı mimarisinde genellikle, birincil DW'de veri martları (DM'ler) vardır. Veri martları, merkezi bir veri ambarından elde edilen verilerin bir alt kümesini içeren küçük birimlerdir. Genellikle işletmedeki bir grup kullanıcının veya bir departmanın ihtiyaçlarını karşılamak için inşa edilmiş ve niş özellikleri barındırmaktadır. Örneğin, bir kuruluşta finans, BT, insan kaynakları dahil olmak üzere birçok farklı departman bulunur ve bu departmanların her birinin kendi veri ambarları olabilir; bunlar aslında söz konusu departmanın veri martıdır. Bir veri ambarı daha fazla veri ile büyüdükçe, herhangi bir işletmenin farklı ihtiyaçlarına hizmet etme yeteneği tehlikeye girmektedir. Bu gibi durumlarda, veri martları sıralı veya aşamalı bir yaklaşımla bir veri ambarı oluşturabilirler. Bir veri ambarı, Şekil 16'da gösterildiği gibi veri martlarının bir alt kümesi olarak görselleştirilebilir (Bhatia, 2019:400).



Şekil 16. Veri ambarı ve veri martı

Veri ambarları üzerinde, çeşitli taktik ve stratejik konular hakkında karar vermeye yardımcı olacak veri analizi ve sorgulama işlemleri OLAP adımı sürecinin son adımını oluşturmaktadır (Nadikattu, 2019). OLAP'ın en büyük gücü, çok boyutlu veri analizi yapabilme yeteneğidir. OLAP araçları, etkileşimli veri analizini basitleştirmeyi ve desteklemeyi hedeflerken, veri madenciliği ya da yapay zeka/makine öğrenmesi algoritmaları sürecin çoğunu otomatikleştirmeyi sağlamaktadır. Bu anlamda bu yöntemler, geleneksel çevrimiçi analitik işleminin bir adım ötesine geçmektedir. Bu yöntemler sayesinde işletme yöneticilerinin daha uygun müşteriler bulmasına ve onlara ulaşmasına ve ayrıca pazar payını artırmaya ve kârı artırmaya yardımcı olabilecek kritik öngörüler elde etmesine yardımcı olabilecektir. Ayrıca yöneticilerin müşteri grubu özelliklerini anlamalarına ve buna göre en uygun fiyatlandırma stratejileri geliştirmelerine yardımcı olunabilecektir. Sezgiye göre değil, müşteri satın alma modellerinden türetilen çıktılara göre pazarlama seçenekleri sunulabilecektir (Han vd., 2012:153)

Veri ambarı, organizasyonların ya da şirketlerin daha iyi operasyonel ve stratejik kararlar almak için biriktirdiği büyük miktardaki veriyi daha iyi analiz etmek için kullanılabilir bir dizi donanım ve yazılım bileşeni gerektiren bir süreçtir. Veri ambarı süreci sadece veri ambarına veri eklemekten ibaret değildir, aynı zamanda bilgi toplamak, sorgulamak, analiz etmek ve sunmak için mimari araçlar gerektirir (Sahama

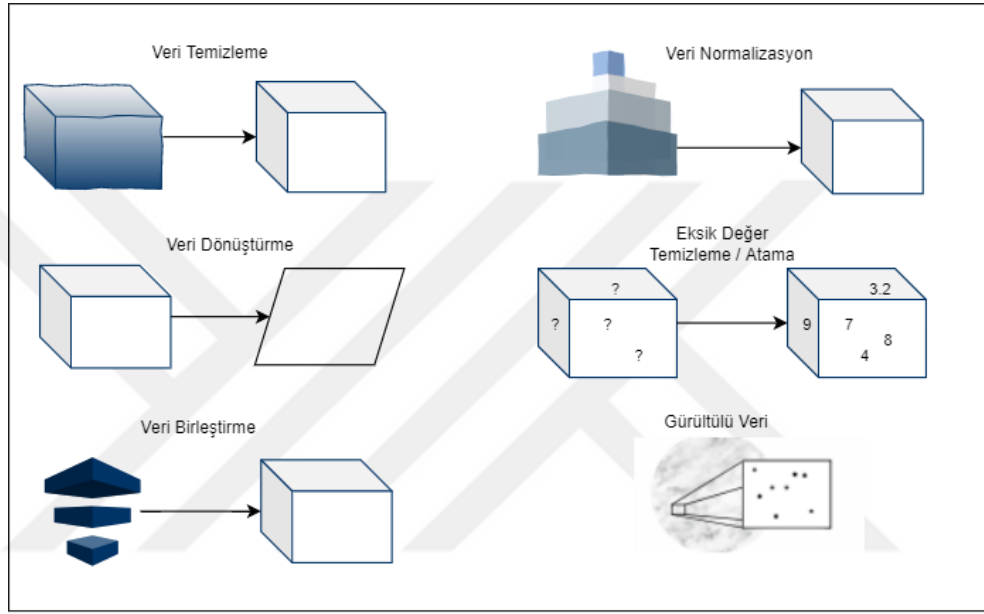
vd., 2007). Son olarak, veri ambarı mimarisi kullanılarak yapay zeka ya da makine öğrenmesi algoritmalarına dayalı tahminler geliştirilebilecek ve bu teknolojilerle işletmenin stratejik kararlar alınması sağlanacaktır. Tüm bu sürecin sonunda analiz çıktılarının kaliteli ve uygulanabilir olması için veriler bir takım veri ön işlemlerinden geçmelidir.

### 2.5.1. Veri Ön İşlemleri

Veri madenciliği ve makine öğrenmesi bağlamında, "Garbage in, Garbage out", büyük miktarlarda veriyle çalışırken popüler bir sözdür. Gerçek verilerin birçoğu insan tarafından üretildiğinden dolayı (sosyal medya verileri, dijital kaynaklara girilen veriler) temiz ya da eksiksiz olmaktan uzak; sahte, kirli, eksik veya tutarsız özelliklere sahip olabilmektedir (Hair vd., 2019:131). Örnek olarak, gelir değişkeninde -400 olarak negatif değer bulunması ya da gerçekçi olmayan veri kombinasyonlarına sahip olabiliriz, örneğin bir hastanın kan grubunda kayıta C RH+ olarak girilmiş değerlerin olması gibi durumlar ortaya çıkabilmektedir. Analizden önce taranmamış bu tür veri setleri üzerinde algoritmaları çalıştırmak yanıltıcı sonuçlara neden olabilmektedir. Bu nedenle, veri ön işleme, herhangi bir yapay zeka ya da makine öğrenmesi sürecinin ilk adımındır. Veri ön işleme, ham verilerin anlaşılabilir bir formata dönüştürülmesini içeren bir ön süreçtir (Bhatia, 2019b: 55).

Veri ön işlemleri, bilgi keşfi sürecindeki en önemli aşamalardan biridir (S García vd., 2015). Veri madenciliği, makine öğrenmesi ve yapay zeka süreçlerinde, veri ön işlemleri tüm veri analizi sürecinde en fazla çaba ve zaman gerektiren önemli bir süreçtir (toplam çabanın %50'si) (Ramírez-Gallego vd., 2017). Ham veriler genellikle tutarsız, eksik değerli, gürültülü ve / veya kirli gibi birçok kusurla birlikte gelir. Bu verilere gereken işlemler yapılmadığında öğrenme algoritmalarının performansı zayıflayacaktır. Bu nedenle, uygun veri ön işleme adımlarının yürütülmesi, sonraki keşiflerin, kararların ve tahminlerin kalitesini ve güvenilirliğini önemli ölçüde etkileyecektir. Ön işlemenin bir parçası olarak veri hazırlığı, ham girdiyi takip edilecek yapay zeka/makine öğrenmesi sürecine uyan, yüksek kaliteli bir girdiye dönüştürmeyi amaçlamaktadır (García vd., 2015). Verilerin bu hazırlık süreci zorunlu bir adım olarak

kabul edilmekte ve Şekil 17’de (García vd., 2016:4) gösterildiği gibi normalleştirme, temizleme, birleştirme ve dönüştürme gibi teknikleri içermektedir (Ramírez-Gallego vd., 2017). Veri ön işlemleri, bilgi keşfi sürecinde önemli bir adımdır, çünkü kaliteli kararlar kaliteli verilere dayanmaktadır. Veri anormalliklerini tespit etmek, bunları düzeltmek ve analiz edilecek eksik ve gürültülü verileri azaltmak, karar vermede büyük kazanımlara yol açmaktadır.



Şekil 17. Veri ön işlemleri

Başarılı bir veri ön işleme aşaması uygulandıktan sonra, elde edilen nihai veri seti, daha sonra uygulanacak yapay zeka / makine öğrenmesi algoritması için güvenilir ve uygun bir kaynak olarak kabul edilebilir (García vd., 2016:5).

- **Veri Temizleme**

Veri temizleme, yanlış verileri veri kümesinden filtreleyen ve verilerin gereksiz ayrıntılarını azaltan işlemleri içerir. Diğer iyi bilinen veri hazırlama tekniklerini içeren veya bunlarla örtüşen genel bir kavramdır (Ramírez-Gallego vd., 2017:4). Veri temizliğinde eksik değerler doldurulur, gürültülü veriler düzeltilir, tutarsızlıklar giderilir ve verileri temizlemek için aykırı değerler belirlenir ve kaldırılır. Veri temizleme süreçlerinin detayları incelenecek olduğunda:

## - Eksik değerlerin ele alınması

Veri tabanı kayıtlarının çoğu, bazı nitelikler için herhangi bir kayıtlı değere sahip olmadığı görülür. Bu tür eksik değer durumlar, farklı yöntemlerle doldurulur.

i. Eksik değerın manuel olarak doldurulması: Veri setindeki her bir eksik değeri manuel olarak doldurmak zahmetli ve zaman alıcıdır ve bu nedenle yalnızca eksik değerlerin az olduğu durumlarda pratiktir. Veri kümesi çok büyük olduğunda veya eksik değerler çok fazla olduğunda, kayıp değerler sorunuyla başa çıkmak için farklı yöntemler bulunmaktadır. ii. Eksik değer yerine bazı global sabitlerin kullanılması: Bu yöntemde, eksik değerler 'Bilinmeyen' veya  $-\infty$  gibi bazı global etiketlerle değiştirilir. iii. Eksik değeri doldurmak için öznitelik ortalamasının kullanılması: Her öznitelik için eksik değerleri aynı özniteliğin diğer veri değerlerinin ortalamasıyla doldurulması yöntemidir. Bu, bir veri kümesindeki eksik değerleri işlemenin etkili yollarından biridir. Normal (simetrik) veri dağılımları için ortalama kullanılabilirken, çarpık veri dağılımını medyanı kullanmalıdır. Örneğin, müşterilerinizin gelirlerine ilişkin veri dağılımının simetrik olduğunu ve ortalama gelirin 6.000 TL olduğunu varsayalım. Gelir için eksik değeri değiştirmek için bu değer kullanılabilir. iv. Eksik değeri, tamamlama olasılığı yüksek olan başka bir değer kullanma: Bir başka etkili yöntem ise, eksik değerleri Bayes veya Karar Ağacı gibi araçlar veya diğer çıkarsama tabanlı araçlar tarafından belirlenen değerlerle doldurmaktır. Bu, mevcut olan bilgilerin çoğunu kullandığından en iyi yöntemlerden biridir. Örneğin, veri kümesindeki diğer müşteri özellikleri kullanılarak, gelir için eksik değerleri tahmin eden bir karar ağacı oluşturulabilir. v. Eksik değer içeren grubun yok sayılması: Grup birden fazla eksik değer içeriyorsa ve diğer tüm yöntemler uygulanamıyorsa, eksik değerlerle başa çıkmak için en iyi strateji tüm grubu yok saymaktır. Öznitelik başına eksik değerlerin yüzdesi önemli ölçüde değişiyorsa bu yöntem kullanılmamalıdır (Han vd., 2012:90).

Zaman serisi verilerinde de eksik veri yaygın bir sorun olarak karşımıza çıkmaktadır. Ayrıca serilerin değerleri bağımsız sensörler tarafından toplandığında zaman içinde senkronize edilemeyebilir. Veri işleme için farklı davranışsal nitelikler arasında eşit aralıklı ve senkronize edilmiş zaman serisi değerlerine sahip olmak, analiz ve model

açısından önemlidir. Zaman serisinde mevsimsellik yok ise, eksik, eşit olmayan aralıklı veya senkronize edilmemiş değerleri işlemek için kullanılan en yaygın metodoloji doğrusal enterpolasyondur (linear interpolation). Bu yöntemde, istenen zaman damgalarında tahmini değerler oluşturulur.  $y_i$  ve  $y_j$ 'nin sırasıyla  $t_i$  ve  $t_j$  zamanlarındaki zaman serilerinin değerleri olduğu,  $i < j$  olduğu senaryoda;  $t$  ( $t_i$ ,  $t_j$ ) aralığında çizilen bir zaman olsun. Ardından, serinin enterpolasyonlu değeri şu şekilde verilir:

$$y = y_i + \frac{t - t_i}{t_j - t_i} * (y_j - y_i)$$

En basit ve sık olarak kullanılan bu doğrusal enterpolasyon, kayıp verilerden önceki değerler ile sonraki değerler arasında bir ortalama hesaplayan enterpolasyondur (Aggarwal, 2015:459).

#### - **Gürültülü verileri işleme**

Veri madenciliği, makine öğrenmesi ve yapay zeka algoritmaları gürültülü verilerden olumsuz etkilenerek yanlış sonuçlar vermektedir. Gürültü, ölçülebilir bir değişkende meydana gelen istenmeyen varyans veya rastgele bir hata olarak tanımlanabilir. Gürültü, “düzeltme” yöntemiyle verilerden kaldırılır. Veri yumuşatma için kullanılan yöntemler: i. Binning: Genellikle bir tür özniteliği başka bir türe dönüştürmek için kullanılır. Örneğin, sıcaklık gibi gerçek değerli bir sayısal özniteliği, işlenmeden önce soğuk, ılık ve sıcak değerleriyle nominal bir özniteliğe dönüştürmek gerekebilir. ii. Kümeleme veya aykırı değer analizi: Kümeleme veya aykırı değer analizi, kümeleme yoluyla aykırı değerlerin tespit edilmesini sağlayan bir yöntemdir. Kümelemede, ortak veya benzer değerler gruplar veya 'kümeler' halinde düzenlenir ve bu kümelerin dışında kalan değerler, aykırı değer veya gürültü olarak adlandırılır. iii. Regresyon: Regresyon, verileri bir işleve uydurarak düzgünleştirmeye izin veren bir diğer yöntemdir. Örneğin, Doğrusal Regresyon, iki değişkenin veya özniteliğin değerlerine (yani en uygun) en uygun doğruyu bulmayı amaçlayan en çok kullanılan yöntemlerden biridir. Bunun birincil amacı, ilkinin kullanarak diğer değişkenin değerini tahmin



etmektedir. Benzer şekilde, ikiden fazla deęişken söz konusu olduęunda çoklu Regresyon kullanılır. Regresyon, veriden gürültüyü kaldıran ve dolayısıyla matematiksel denklemler kullanarak veri kümesini düzgünleştiren veri uydurmaya izin verir (Bhatia, 2019:60).

- **Veri Birleştirme**

Bu adım, veri tabanları (ilişkisel ve ilişkisiz olmayan), veri küpleri, dosyalar vb. gibi birden çok kaynaktan gelen verilerin entegre edilmesini içerir. Veri kaynakları homojen veya heterojen olabilir. Kaynaklardan elde edilen veriler yapılandırılmış, yapılandırılmamış veya yarı yapılandırılmış formatta olabilir. Belirli bir kavramı temsil eden bazı öznitelikler, farklı veri tabanlarında tutarsızlıklara ve fazlalıklara neden olarak farklı adlara sahip olabilir. Örneğin, müşteri tanımlamak için kullanılan deęişken, bir veri deposunda müşteri kimlik numarası deęerinde müşteri ID olarak adlandırılabilir. Öznitelik deęerleri için adlandırma tutarsızlıkları da oluşabilir. Örneğin, aynı ad bir veri tabanında "Bill", deęerinde "William" ve "B" olarak kaydedilebilir. Bu nedenle, veri temizlemeye ek olarak, veri entegrasyonu sırasında fazlalıklardan kaçınmaya yardımcı olacak adımlar atılmalıdır. Tipik olarak, veri ambarı için veri hazırlanırken veri temizleme ve veri entegrasyonu bir ön işleme adımı olarak gerçekleştirilir. Veri entegrasyonundan kaynaklanabilecek fazlalıkları tespit etmek ve kaldırmak için ek veri temizliği gerçekleştirilebilir. Entegrasyon süreci düzgün bir şekilde gerçekleştirilmezse, kısa sürede veri fazlalıkları ve tutarsızlıklar ortaya çıkacak ve bu da sonraki analiz süreçlerinin doğruluğunun ve hızının düşmesine neden olacaktır. Bu sürecin önemli bir parçası, gerçek dünya örneęi sunmak için her örneęin ortak bir yapıda nasıl düzenlenmesi gerektiğini belirleyen bir veri haritası oluşturmaktır. İlişkisel veri tabanlarından veriler elde edildiğinde, genellikle düzleştirilir ve tek bir kayıta bir araya toplanır (S García vd., 2015:40).

Veri entegrasyonu saęlık sektöründe de önemli bir rol oynamaktadır. Farklı hasta kayıtlarından ve kliniklerden elde edilen entegre veriler, farklı sistemlerden gelen verileri yararlı bilgilerin elde edilebileceęi birleşik bir yararlı bilgi görünümünde düzenleyerek doktorların tıbbi durumları ve hastalıkları teşhis etmelerine yardımcı

olur. Etkili veri toplama ve entegrasyon, tıbbi sigortacılar için talep işleme doğruluğunu da geliştirir ve hasta adlarının ve iletişim bilgilerinin tutarlı ve doğru bir şekilde kaydedilmesini sağlar.

- **Veri dönüştürme**

Bir özneliğin değeri diğer özneliklere kıyasla küçük olduğunda, o özneliğin bilgi madenciliği üzerinde fazla bir etkisi olmayacaktır, çünkü bu özneliğin değerleri diğer özneliklerden daha küçüktür ve öznelik içindeki varyasyon, ayrıca küçük olur. Bu nedenle, veri dönüştürme, verilerin birleştirildiği veya veri analizi için daha uygun olan diğer bazı standart biçimlere dönüştürüldüğü bir süreçtir. Gerçek hayattan alınan verilerin çoğu sürekli ve sayısal veri formatındadır. Dönüştüreceğimiz veriler ücret, harcama gibi değerlerse bunlara düşük, orta, yüksek, çok yüksek gibi etiketler atabiliriz. Ya da bir hastadan alınan tansiyon ölçümünü yüksek düşük ya da normal olarak etiketleyebiliriz. Eğer verilerimiz yaş ile ilgili verilerse bunlara da çocuk, yetişkin, genç, orta yaşlı ve yaşlı gibi etiketler verebiliriz (Salvador vd., 2015).

Öznelikleri dönüştürmek için genellikle iki teknik kullanılmaktadır: Normalleştirme ve Standardizasyon, en popüler ve yaygın kullanılan veri dönüştürme yöntemleridir. Normalleştirme durumunda, tüm nitelikler normalleştirilmiş bir aralığa (0, 1) dönüştürülür. Kullanılan ölçüm birimi veri analizini etkileyebilir. Tüm özellikler aynı ölçü birimlerinde ifade edilmeli ve ortak bir ölçek veya aralık kullanılmalıdır. Verilerin normalleştirilmesi, tüm özelliklere eşit ağırlık vermeye çalışır ve özellikle istatistiksel ve makine öğrenme yöntemlerinde faydalıdır. Yeni nitelikler üretmeyen, ancak orijinal değerlerin dağılımını, istenen özelliklere sahip yeni değerler kümesine dönüştüren süreçtir.

- **Min-Max Normalleştirme:** Min-maks normalizasyonu, sayısal bir özneliğin A, tüm sayısal değerlerini ( $v$  [yeni - min A, yeni - maks A] ile gösterilen) belirli bir aralığa ölçeklendirmeyi amaçlar. Böylece, yeni  $v$  değerini elde etmek için aşağıdaki ifade  $v'$ 'ye uygulanarak dönüştürülmüş bir değer elde edilir:

$$v' = \frac{v - \min A}{\max A - \min A} (\text{yeni\_max}A - \text{yeni\_min}A) + \text{yeni\_min}A$$

**Z-Score Normalleştirme:** Bazı durumlarda, min-maks normalizasyonunun kullanılması mümkün değildir. A özneliğinin minimum veya maksimum değerleri bilinmediğinde, min-maks normalleştirmenin uygulanması mümkün değildir. Minimum ve maksimum değerler mevcut olduğunda bile, aykırı değerlerin varlığı, değerleri gruplayarak ve değerleri temsil etmek için mevcut kesinliği sınırlandırarak min-maks normalizasyonunu saptırabilir. Eğer A özneliğinin değerlerinin ortalaması ve standart sapması ( $\sigma$ ) belli ise, A'nın orijinal değeri normalleştirilir.

$$v' = \frac{v - \bar{A}}{\sigma_A}$$


#### - Veri İndirgeme

Şu anda, üretilen veri miktarı, büyük veri kavramının ortaya çıkmasının ardından katlanarak artmaktadır. Çağdaş veri kümeleri, üç boyutta (özellikler, örnekler ve önemlilik) büyür ve standart algoritmalar kullanılacaksa karmaşıklığı azaltmak zorunlu bir adım haline gelir. Algoritmalar, genellikle değişken sayısı sınırlı olduğunda ve çok sayıda kayıt homojen gruplar halinde gruplandırılabilirdiğinde performans artışı gösterirler. Örneğin, bir veri analisti binlerce ürün türüyle uğraşmak yerine bunları daha az sayıda grup halinde gruplamak ve her grup için ayrı modeller oluşturmak isteyebilir veya bir pazarlamacı, müşterileri kümeler şeklinde gruplandırmak isteyebilir ve bu nedenle, kişileri tanımlamak için müşterileri homojen gruplara ayırması gerekmektedir. Çok sayıda kaydı (veya durumu) daha küçük bir kümede birleştirme işlemine veri indirgeme denir. Vaka sayısını azaltmaya yönelik yöntemlere kümeleme, değişkenlerin sayısını azaltmaya ise boyut küçültme denir. Boyut küçültme, tahmin gücünü, yönetilebilirliği ve yorumlanabilirliği iyileştirmeyi amaçlayan, yapay zeka algoritmalarını devreye almadan önce atılan ortak bir adımdır (Shmueli vd., 2017:14).

Veri indirgeme, boyutların azaltılması (toplam öznitelik sayısı) veya hacmin azaltılması ile ilgilidir ve farklı yöntemlerle veri indirgeme süreci yönetilebilmektedir. i. Boyut azaltma, Temel Bileşen Analizi (PCA) algoritmasını kullanır. Bu tür algoritmaların kullanımıyla, gereksiz ve zayıf nitelikler veya boyutlar tespit edilerek kaldırılabilir. ii. Sayısal azaltma; Veri kümesi hacmini azaltmak için daha küçük veri gösterimi biçimlerini seçmek için kullanılan bir tekniktir. iii. Veri sıkıştırma; Veri kümesi boyutunu küçültmek için veri sıkıştırma teknikleri de kullanılmaktadır. Veri indirgeme, girdinin orijinal yapısını ve anlamını korumaya izin verir, ancak aynı zamanda çok daha yönetilebilir bir boyut elde edilmesini sağlar (Ramírez-Gallego vd., 2017:40).

### **2.5.2. Dengesiz Veri Setleri**

Makine öğrenmesi algoritmalarında en sık karşılaşılan veri problemlerinden biri olan dengesiz veri setleri, araştırmacıların veri analizi gerçekleştirmek için yaşadığı zorluklardan biridir. Makine öğrenmesi ve derin öğrenme algoritmaları, sınıf dengesizliği sorunundan büyük ölçüde etkilenir (Wong vd., 2020). Veri dengesizliği sorunu, veri kümesindeki bir veya daha fazla sınıftaki örneklerin sayısı başka bir sınıftan (veya sınıflardan) daha az olduğunda ortaya çıkan ve dolayısıyla sınıflandırıcı performansında önemli bir bozulmaya neden olan sorunları ifade eder (Kaur vd., 2019). Bu sorun nedeniyle, sınıflandırma algoritmalarının performansı, dengesiz veri setindeki bazı sınıflara (çoğunluk sınıfı) yönelik olma eğilimi gösterir (Kaur vd., 2019). Dengesiz veri problemi dolandırıcılık / izinsiz giriş tespiti, risk yönetimi, metin sınıflandırması ve tıbbi teşhis dahil olmak üzere birçok uygulamada karşılaşılan önemli bir problemdir (Fotouhi vd., 2019; Kushwaha, 2019).



Dengeli Veri Seti

Dengesiz Veri Seti

Şekil 18. Dengesiz veri sınıflandırıcı probleminin genel gösterimi

Sınıf dengesizliği probleminde dengesizliği azaltmak veya etkisini ortadan kaldırmak için bazı çözümler önerilmiştir (Haixiang vd., 2017). Sınıf dengesizliği probleminin üstesinden gelmek için kullanılan yeniden örnekleme yöntemleri;

- Aşırı Örnekleme (oversampling)
- Az Örnekleme (undersampling)
- Sentetik Veri Üretme

Yeniden örnekleme yöntemleri, veri setindeki örnek miktarı sayısı yetersiz ise azınlık sınıfından örnekleri kopyalayan over sampling (aşırı örnekleme - ROS) tekniği kullanılırken, aşırı örnek içeren sınıflardan örnekleri elimine etmek için ise under sampling (örneklem azaltma - RUS) yöntemi kullanılır (Rendón, vd., 2020) (Blagus ve Lusa, 2017).

Yeniden örnekleme yöntemlerinin, daha uzun eğitim süreleri ve aşırı uydurma gibi dezavantajları da bulunmaktadır. Büyük bir veri setinde RUS yöntemi, veri setindeki örneklerin sayısını azaltarak depolama problemlerini ve çalışma süresini iyileştirebilmektedir. Ancak birçok örnek çıkarılmasıyla birlikte bilgi kaybı da yaşanabilmektedir. Bu nedenle veri setinden rastgele seçilen bir örnek herhangi bir anlam ifade etmeyebilir (Fernández vd., 2018). Sayfa bilgisi kitap ROS yönteminde herhangi bir bilgi kaybına neden olmamaktadır. Ancak RUS yöntemi de örnekleri

çoğalttığı için aşırı öğrenmeye yol açabilir ve model verileri ezberleyebilir. Bu yöntemlerin ardından daha "akıllı" örnekleme olan Sentetik Azınlık Aşırı Örnekleme Tekniği (SMOTE) geliştirilmiştir (Rendón vd., 2020). SMOTE, sezgisel bir örnekleme algoritmasıdır ve günümüzde, en popüler veri örnekleme yöntemlerinden biridir (Basgall, vd., 2019). SMOTE örneklerin çoğaltılması işleminde sentetik örnekler oluşturduğundan, ROS yönteminin neden olduğu ezberleme sorununu azaltır ve faydalı bilgilerin kaybına neden olmaz. Yöntemin dezavantajı ise gürültü üretmesidir (Rendón vd., 2020)(Curukoglu, 2019).

- **Rastgele Aşırı Örnekleme (ROS)**

Rastgele aşırı örnekleme (Random over sampling- ROS), eğitim verilerinde bulunan azınlık sınıfı örneklerinin sayısını rastgele replikasyonla artıran basit bir tekniktir. ROS bilgi kaybına yol açmayan, önerilen eski bir yöntemdir (Kamei vd., 2007). Dengesiz bir veri seti olarak ele alınan bir veri seti için, DSPoz pozitif sınıf (azınlık sınıf) ve DSNeg negatif sınıf (çoğunluk sınıf) olduğunu varsayalım. ROS'un görevi K örneklerini azınlık/pozitif sınıftan rastgele kopyalamak ve bunları veri setine eklemektir. Böylece veri setindeki iki sınıfın aynı örnek sayılarına sahip olması sağlanacaktır. ROS, DSPoz==DSNeg olduğu zaman tamamlanmış olacaktır (J. Sun vd., 2018). ROS etkili bir yöntem olmasına rağmen, azınlık sınıf örneklerinin tam kopyalarını aldığı için aşırı uyum problemi ortaya çıkabilmektedir (Chawla vd., 2002).

- **Rastgele Örnekleme Azaltma (RUS)**

RUS, dengeli bir veri kümesi oluşturmak için çoğunluk sınıflarının örneklerini azınlık sınıfının boyutuna göre rastgele kaldıran bir tekniktir (Guo vd., 2019). RUS, sınıf dengesizliği sorunuyla başa çıkmak için etkili bir tekniktir, ancak en iyi strateji değildir. RUS, sınıf dengesizliğini telafi etmek için çoğunluk sınıfından örnekleri rastgele elimine eder ve bu işlem önemli olabilecek yararlı bilgileri de atabilir. Bu durum modelin başarısını olumsuz yönde etkileyebilmektedir (Elhassan ve Aljurf, 2016). Rastgele Örnekleme Azaltma tekniğinde çoğunluk azaltma sınıfında yapılan işlem rastgele yapılır. Rastgele seçim yaparken önemli sayılabilecek yararlı bilgiler de atılabilir. Bu durum modelin başarısını olumsuz yönde etkileyebileceği için bir dezavantaj olarak görülmektedir (Çürükoğlu, 2019).

- **SMOTE (Synthetic Minority Oversampling Technique)**

Chawla ve arkadaşları (2002), dengesiz veri dağılımını önlemek amacıyla SMOTE yöntemini geliştirmişlerdir (Chawla vd., 2002). Bu yöntem, el yazısı karakter tanımda başarılı olduğu kanıtlanmış bir teknikten esinlenmiştir (Ha ve Bunke, 1997). Bazı denetimli öğrenme algoritmalarında (karar ağaçları ve sinir ağları gibi) iyi bir genelleme yapmak, yani iyi bir sınıflandırma performansı elde etmek için eşit bir sınıf dağılımı gerekmektedir (Elhassan ve Aljurf, 2016). Sentetik azınlık (aşırı) örnekleme tekniği (SMOTE) etkili, basit ve yaygın kullanılan bir sınıf dengeleme çözümdür. SMOTE, birbirine çok yakın olan mevcut örnekleri enterpolasyon yöntemiyle azınlık sınıfından yapay örnekler üretir. Her bir azınlık örneği için  $k$  sınıf içi en yakın komşu bulunur ve bu en yakın komşuların bir kısmı veya tamamı doğrultusunda sentetik örnekler üretilir. Yöntem, örneklerin tutarsızlığını azaltmayı sağlar (Chawla vd., 2002). Sentetik numuneler şu şekilde üretilir: Söz konusu özellik vektörü ile en yakın komşusu belirlenir. İki nokta arasındaki uzaklık hesaplanır ve bu 0 ile 1 arasında rastgele bir sayı ile çarpılır. Elde edilen yeni sonuç, söz konusu özellik vektörüne eklenerek sentetik örnekler çoğaltılır (Basgall vd., 2019). Diğer örnekleme yöntemlerinden en önemli farkı ise, azınlık sınıfında bulunan örneklerin kopyalanarak çoğaltılması yerine yakın komşuluklarına bakılarak sentetik örneklerin üretilmesidir.

### III. BÖLÜM

## YAPAY ZEKA İLE DÖNÜŞEN SAĞLIK YÖNETİMİ VE KARAR VERME

*“Hayatta kalan türler ne en güçlülerdir ne de en zeki olanlar, hayatta kalabilenler değişime duyarlı olanlardır.”*

Charles Darwin

#### 3.1. Yönetim ve Stratejik Yönetim

Charles Darwin'in alıntısı temelde bir stratejik yönetim kavramından bahsetmekte, değişime yanıt verilmesi gerektiğini vurgulamaktadır. Değişimin olmadığı bir dünyada işletmeler için stratejik yönetim gerekli bir olgu değilken, sürekli değişen bir dünyada işletmeler için stratejik yönetim esas olmaktadır. Tıpkı Biyoloji bilimindeki gibi, çevresinin taleplerine en iyi uyum sağlayan işletme gelişir ve dönüşürken, uyum sağlamayanların ekosistemle bağı giderek azalmakta ve en son tamamen yok olmaktadır. Uyum sağlamak, başarının anahtarı rolündedir. Günümüzde de işletmeleri etkileyen teknolojik, sosyal, ekonomik, rekabetçi ve politik değişim oranı gün geçtikçe hızlanmaktadır. Burnes'e göre değişim hem operasyonel hem de stratejik düzeyde, örgütsel yaşamın her zaman var olan bir özelliğidir (Burnes, 2004:98). Bu nedenle, gelecekte olmak istediği yeri tanımlamak ve oraya ulaştıracak değişimi başarmak için gerekli yetkinliklere sahip olmak açısından işletmelerde değişim ve değişim yönetimi de önemlidir. Bu yaşanan hızlı dönüşümde kurum ya da firma yönetimlerinin bu hızı yakalaması ve stratejik yönetimini gelişen teknolojiye göre uyarlaması önem arz etmektedir.

Bir süreç olarak yönetim; örgütsel kaynakların planlanması, organize edilmesi, yürütülmesi ve kontrol edilmesi yoluyla etkili ve verimli bir şekilde kullanılması ve örgütsel amaçlara ulaşılması şeklinde tanımlanmaktadır. Bu tanım iki önemli fikre dayanmaktadır. Bunların ilki planlama, örgütleme, yürütme ve kontrol işlevleri ve ikincisi ise etkili ve verimli şekilde örgütsel amaçlara ulaşılmasıdır (Daft ve Marcic,



2009:8-9). Sanayi Devrimi, modern işletme yönetiminin üzerine kurulu bir temel oluşturan, yeni iş uygulamaları dalgasını başlatan süreç olmuştur. İlerleyen dönemde, işletme alanı üniversitelerde meşru bir çalışma alanı olarak kabul edilmiş ve ilk olarak finansal yönetim ve muhasebe, üretim ve operasyon yönetimi, pazarlama yönetimi ve personel yönetimi benimsenen konular arasında olmuştur. Ancak, tüm disiplinleri anlamlı bir şekilde birbirine bağlayan bir disiplinin olmadığı fark edilmesiyle Harvard gibi işletme okulları ve Boston Consulting Group gibi danışmanlık şirketleri ortaya çıkmaya başlamıştır. 1970'lerdeki iş politikası, şimdilerde stratejik yönetim olarak adlandırılan kavrama dönüşmüştür (Harrison ve Thompson, 2014). Öncelikle strateji, bir örgütün uzun dönemli yönelimi ile ilgilenme eğilimindedir ve gelecekteki belirsizlikler için yapılan bir hazırlık olarak görülmektedir (Robinson ve Pearce 1984: 5). Strateji bir örgütün geleceğini inşa etmekle ilgilenmektedir. Bu yatırım yapmak, yeni ürün geliştirmek, çalışanlara hizmet içi eğitim vermek, örgüt kültürünü değiştirmek ya da teknolojileri geliştirmek gibi faaliyetleri gerekli kılmaktadır. Açık bir sistem olarak çevre, örgütün geleceğini sürekli şekillendirmekte ve böylece geleceğin kendisi değişen ve hareket eden bir hedef haline gelmektedir. Strateji, bu nedenle örgüt çevresinin belirsiz ve etkileşimli doğası kadar gerçek dünyanın karmaşıklığını da yansıtmaktadır (Gell-Mann, 2002). Stratejik yönetim ise, yukarıdaki tanımdaki hususları içermekle birlikte işletmenin karakteri ve ne olmak istediği ile ilgilenir. Stratejik yönetim teorisinin temeli, birkaç kilit yazar Chandler (1962) ve Ansoff (1965) tarafından şekillendirilmiştir. Chandler (1962), organizasyon yapısı ve strateji arasındaki ilişkiyi vurgularken, Ansoff (1965), stratejik yönetim kavramının temellerini vurgulamıştır. Stratejik yönetim, bir şirketin benzersiz bir pozisyon seçmesi, yani işleri rakiplerden farklı veya daha iyi yapmak ve maliyetleri düşürecek, müşteri ihtiyaçlarına daha iyi karşılık verecek şekilde yapmasıyla ilgilenmektedir (Porter, 1979). Bu daha sonra bir tür rekabet avantajına yol açmıştır (Robert M. Grant, 1991; Mintzberg, 1978; Penrose, 1959). Stratejik yönetimin merkezi, stratejinin kendisidir. Stratejik yönetim süreci, firmanın ve çevresinin analizi, stratejik bir hedef oluşturulması, kuruluşun bu hedefe ulaşmak için izleyebileceği alternatif stratejilerin değerlendirilmesi ve uygulama planlaması gibi faaliyetleri içermektedir. Bu nihai hedef, şirketin stratejilerini yönetmek ve kitleyi ortak hedeflere doğru yönlendirmek için gerekli olan adımdır. Bu adım, özellikle karmaşık ve çalkantılı bir ortamda önem

arz etmektedir (Harrison ve Thompson, 2014).Stratejik yaklaşım, deęişimi tahmin etme ve deęişim ile başa çıkabilme becerilerini geliştiren bir yapıyı işletmelere sunmaktadır. Stratejik kararlar, yöneticilerin bildikleri şeylerden çok, önceden tahmin de buldukları şeylere bağlıdır. Bu tip kararlar kuruluşun en çok gelecek vaat eden stratejik seçenekleri seçmesine olanak tanıyacak tahminler geliştirmesini sağlamaktadır. Çalkantılı ve rekabetçi çevrelerde örgüt ancak deęişime karşı proaktif ve ileriye yönelik stratejiler oluşturabilir ve buna uygun bir duruş sergilerse başarılı olabilecektir (Robinson ve Pearce, 1984).

Strateji yazarı Prof. James Brian'ın "Stratejik kararlar, bir işletmenin genel yönünü ve çevresinde meydana gelebilecek öngörülebilir, öngörülemeyen ve bilinemez deęişikliklerin ışığında nihai uygulanabilirliğini belirleyen kararlardır ve nihayetinde işletmenin gerçek hedeflerini şekillendirirler" ifadesinde de stratejik kararların organizasyonlar için ne denli önemli olduğu vurgulanmıştır (Ginter vd., 2018:246). Farklı sektörlerin stratejik karar ya da hedefleri incelendiğinde, rakiplerine karşı güçlü ve zayıf yanları olsa da rekabet avantajı yaratmaya çalışmakta ve bunun için de düşük maliyet ya da farklılaşma stratejisini önemli kaynaklar olarak görmektedirler. Porter (1980)'de yayınladığı çalışmada maliyet liderliği, farklılaşma ve odaklanma olmak üzere üç tür rekabet stratejisinden bahsetmektedir. Maliyet liderliği stratejisi, büyük bir pazar payına sahip olma, hammaddelere ya da en gelişmiş üretim ekipmanlarına elverişli erişim yolu olarak görülmektedir. Farklılaşma stratejisi teknoloji, inovasyon, müşteri hizmetleri vasıtasıyla daha kaliteli bir imaj oluşturmayı sağlamaktadır. Üçüncü strateji olan odaklanma stratejisi ise nispeten daha küçük bir alıcı grubu veya ürün hattının sınırlı bir kısmına odaklanmayı gerektirmektedir (Alkhafaji ve Nelson, 2013). İsveçli otomobil üreticisi Volvo, güvenliğin bilime dayalı bir din olduğunu savunmuş ve son projeleri olan Vision 2020 ile beş yıl içinde tüm yeni arabalarında ölümü ortadan kaldırma hedefini açıklamıştır. Çoğu şirket için ütopyik bir hedef gibi görünse de emniyet kemerini icat eden şirket olan Volvo bu stratejik hedefi için çalışmalarını sürdürmektedir (Petrány, 2014); ("Volvo Cars caps vehicle speed to prevent road deaths", y.y.). Kaliforniya merkezli bir teknoloji şirketi olan Nvidia'nın stok değeri son dört yılda %1.100 oranında büyümüş ve önceki yılın aynı dönemine göre %48 gelir elde etmiştir. Şirketin bu başarısı pazar payının %80'ine sahip olduğu

yonga pazarında yalnızca grafik işlem birimine (GPU) odaklanarak başarılı bir niş oluşturması ile ilişkilidir. Toyota ise sürekli iyileştirme stratejisi ile ABD pazarına girmiş ve orada kendine yer açmayı başarmıştır (Wright, 2021). Küresel pazardaki pek çok zorluk ve fırsat göz önüne alındığında, bugünün yöneticileri, uzun vadeli stratejiler belirlemekten ve en iyisini ummaktan daha fazlasını yapmak durumundadırlar (Begley ve Boyd, 2003). Bugünün liderleri proaktif olmalı, değişimi öngörmeli, sürekli olarak iyileştirmeli ve gerektiğinde dramatik değişiklikler yapabilmelidir.

### **3.1.1. Stratejik Yönetim Alanındaki Yaklaşımlar**

Stratejik yönetim teorisinin temeli Ansoff (1965) ve Chandler (1962) gibi kilit isimler tarafından atılmıştır. Chandler (1962) yayınladığı çalışmada organizasyon yapısı ve strateji arasındaki ilişkiyi vurgularken, Ansoff (1965) stratejik yönetim kavramının temellerini ele almıştır. Stratejik yönetim, bir şirket için benzersiz bir pozisyon seçmekle, yani işleri rakiplerinden farklı ve daha iyi, aynı zamanda maliyetleri düşük veya müşteri ihtiyaçlarına daha iyi hizmet edecek şekilde yapmak olarak tanımlanmaktadır (Porter, 1979). Bu durum daha sonraları bir tür rekabet avantajına yol açmıştır (Robert M. Grant, 1991; Mintzberg, 1978; Penrose, 1959).

Mintzberg vd. (1996), strateji oluşturma süreci ve yönetim uygulamasına odaklanan on farklı düşünce okulu tanımlamıştır (Mintzberg, Henry, Quinn, 1996). Jones ve arkadaşlarının 2008 yılında yaptığı çalışmada şirket içi ve dışı, şirket ortam analizleri ve şirket stratejilerinin seçimi strateji formülasyonu olarak tanımlamıştır (Jones vd., 2008). Bununla birlikte, araştırma sadece strateji oluşturma ve uygulamaya değil, aynı zamanda başarı faktörlerine de odaklanmış; rekabet avantajı sağlamak veya bunu sürdürülebilir kılmak konusunda temel iki görüş olduğu belirtilmiştir. Bu bağlamda ana konular, pozisyon okulu yaklaşımı (Porter, 1979, 1980) ve kaynak temelli görüş (J. Barney, 1991; Penrose, 1959) olarak ele alınmıştır. Pozisyon Okulu Yaklaşımı, endüstri iktisadına dayanan ve rekabet avantajının, endüstrinin yapısından kaynaklandığını ileri süren bir yaklaşımdır. Kaynak temelli görüş ise, rekabet avantajını oluşturan asıl unsurun işletmelerin kendilerine özgü kaynakları, kabiliyetleri ve yetenekleri olduğunu ileri süren yaklaşımdır.

Pozisyon okulu, bir firmanın performansını, çevre ve pazar yapısından etkilenen davranışların sonucu olarak görürken, kaynak temelli görüş, bir şirketin başarısını belirlemek için iç kaynakları baz almaktadır. Bu başarı, kaynak-davranış-performans olarak tanımlanmaktadır (Engert, vd., 2016). Literatürde Pozisyon Okulu yaklaşımı ve kaynak temelli görüşün iki grupta değerlendirilebileceğini ya da bu iki görüşün de birleştirilebileceğini savunan görüşler bulunmaktadır. Bu iddia çerçevesinde başka yazarlar da bu iki okulu gelişimlerinden başlayarak ya tek tek veya karşılaştırmalı olarak incelemiştir (Wielemaker vd., 2001; Bakoğlu ve Dinç, 2010; Taş ve Cevrioğlu, 2015).

### 3.1.1.1.Pozisyon Okulu Yaklaşımı

Strateji formülasyonunun özü rekabetle başa çıkmaktır; bu nedenle stratejik yönetim, endüstrinin rekabet analizi ile başlamaktadır. Pozisyon Okulu görüşünün mimarı Porter, stratejik başarıyı “ya işleri farklı yap yahut farklı işler yap” şeklinde özetleyerek, bunun için “beş güç” adıyla bir analiz çerçevesi sunmuştur (Porter, 1980). Pozisyon okulu yaklaşımı üç varsayımı içermektedir. Buna göre ilk varsayım, firmalar için endüstride iyi bir konum elde etme, rekabet avantajı sağlamaktadır. İkinci varsayımına göre bir endüstride rekabeti şekillendiren beş rekabetçi güç, potansiyel rakipler, ikame ürünlerin/hizmetlerin tehdidi, alıcıların/tedarikçilerin pazarlık gücü ve endüstrideki mevcut rakipler arasındaki rekabettir (Porter, 2008; Porter, 1979). Son varsayımına göre ise firmalar endüstri içinde rekabeti şekillendiren değişkenlere jenerik stratejilerle cevap vermektedir. Yaklaşımına göre sürdürülebilirliği sağlayan temel mekanizma firmanın endüstrideki konumunu giriş engelleriyle korumasıdır. Dolayısıyla rekabet avantajı elde etmek isteyen bir firma için başka firmaların giriş tehdidinin düşük, tedarikçilerin/müşterilerin pazarlık gücünün az, ikame ürünlerin, hizmetlerin ve yıkıcı rekabetin olmadığı endüstrilere yönelmesi gerekmektedir (Bağış ve Öztürk, 2020; Porter, 1979). Rekabeti şekillendiren beş güç modeli, rekabetin yoğunluğunun yapısal olarak belirlenmesine yardımcı ve çevrenin analiz edilmesinde detaylı bir açıklama sunmayı hedeflemektedir. Buna göre beş güç modeli; **Potansiyel Girişler:** Piyasaya yeni girecek olan firmalar, piyasadaki firmalar için bir tehdit oluştururlar. Yeni bir rakibin pazara girmesi ne kadar kolaysa, yerleşik bir işletmenin

pazar payının tükenmesi riski de o kadar büyük olur. Pazara giriş engelleri arasında marka sadakati, maliyet avantajları, müşteri değiştirme maliyetleri, ilk sermaye gereksinimi ve hükümet düzenlemeleri bulunmaktadır (Porter, 1979: 5). **İkame Ürünler:** Benzer müşteri ihtiyaçları, farklı işletmelerin veya endüstrilerin ürünleri veya hizmetleri tarafından karşılanabilmektedir. İkame ürün ve hizmetlerin tehdidinin derecesi, ikamelerin sayısı ve teknolojilerin varlığı ile belirlenir. İkame ürünler mevcut ürünlerin kar potansiyelini sınırlayarak firmaların kazançlarının düşmesine neden olmaktadır (Porter, 1998: 18- 23). **Tedarikçiler:** Piyasadaki firmalar üzerinde fiyatları artırmak, kalite ve hizmeti düşürmek doğrultusunda baskıda bulunarak bir pazarlık gücü elde etmeye çalışmaktadırlar. Tedarikçilerin pazarlık gücü, piyasada ikame ürünlerin var olma durumuna, sektörün tedarikçi için önemli olmasına, tedarikçilerin yoğunluğuna, ürünün firma için değerine ve firmanın ürünü değiştirme maliyetine bağlı olduğu savunulmaktadır (Porter, 1998: 27-28). **Alıcılar:** Alıcıların maliyetleri, alınan ürünlerin miktarı, ürünlerin farklılaştırılmış olması durumu, alıcıların ürünü değiştirme maliyeti, tedarik edilen ürünlerden elde edilen kar, bu ürünleri kendilerinin üretebilme olanağına sahip olmaları, kendi ürettikleri ürün kalitelerinin tedarik ettikleri ürünlerden etkilenme durumu ve piyasa hakkındaki bilgileri, alıcıların pazarlık güçlerini belirlemektedir. Alıcıların pazarlık gücünün yüksek ya da düşük olması, firmayı ürünlerin kalite ve fiyat konusunda değişiklik yaparak rekabet etmeye zorlamaktadır (Porter, 1979:24-26). **Mevcut Rakipler Arası Rekabet:** Sektörde faaliyet gösteren rakipler arasındaki yoğun rekabet, güçlü bir kârlılık tehdidi oluşturmaktadır. Rekabetin yoğunluğu, endüstrinin rekabet yapısı, sektörün yavaş veya hızlı gelişmesi, sabit maliyetlerin yüksek olma durumu, firmalar arası farklılaşma ve sektöre giriş engellerinin yüksekliği gibi çeşitli faktörler endüstrideki rekabetin yoğunluğunu belirleyen en önemli unsurlar olarak karşımıza çıkmaktadır (Porter, 1979:18-22).

Pozisyon Okulu Yaklaşımı, endüstriyel organizasyon ekonomilerinden Yapı-Davranış-Performans (YDP) paradigması (Bain, 1956) üzerine temelleri atılmıştır. Yapı (Structure), bir ekonomideki piyasaların ve endüstrilerin ekonomik ve teknik özelliklerini ifade etmektedir. Bu yapı, firmaların kullandıkları fiyat, reklam, yetenek ve kalite gibi stratejileri veya davranışları (conduct) belirlemektedir. Bu, firmaların

aldıkları kararları ve işletmelerinde izledikleri süreçleri içermektedir. Firmaların kullandıkları bu stratejiler firma performansını, bu da dolaylı olarak firma karlılığını etkilemektedir. Performans ölçülerinden bazıları, kazanılan karlar, operasyonel maliyette azalma, kalitenin iyileştirilmesi, geliştirilen doğru ürünlerdir (Ralston vd., 2015). YDP paradigması ilk olarak endüstriyel organizasyon ekonomisinde ortaya çıkmıştır. Paradigma (Bain, 1956) endüstri yapısının firma stratejileri üzerindeki belirleyici etkisinden dolayı statiktir ve yöneticilerin stratejik seçimlerini dikkate almamaktadır (Michael E. Porter, 1980). YDP paradigması, firmanın performansının, firma davranışı ile kolay bir şekilde değişmeyen endüstri yapısınca belirlendiğini ileri sürmektedir (Porter, 1981: 610). Firmalar, daha yüksek kar elde etmek için davranışlarını ayarlayan iş ortamına yanıt olarak stratejiler geliştirmektedir (Weiss, 1979). YDP paradigması, performans ölçümünde endüstri (tedarik zinciri) ve şirket düzeyindeki faktörleri dikkate almaktadır.

### **3.1.1.2.Kaynaklara Dayalı Yaklaşım**

Kaynaklara Dayalı Yaklaşım göre strateji, süreç içinde kendiliğinden oluşmakta ve başarının örgüt dışı unsurlarda değil örgüt içi kaynak ve bilgide aranması gerekmektedir. Çünkü örgüt dışı faktörlerin çözümlenmesinde çevre, her örgüt için veri niteliğindedir. Oysa örgütsel kaynaklar farklı ve paylaşılamaz oluşları nedeniyle örgüte özgü nitelikte üstünlük kaynağı olabilmektedirler (Coşkun, 2016: 33-37). Kaynaklara Dayalı Yaklaşımında rekabet üstünlüğü zaman içerisinde, öğrenme yoluyla gerçekleşen ve rasyonel olmayan bir süreç ile gelişen stratejilerin olduğunu varsaymaktadır (Erol ve İnce, 2012). Pozisyon Okulu stratejiyi endüstriden firmaya doğru geliştirirken, kaynaklara dayalı yaklaşım ise stratejiyi firma içi etmenlerden dış çevreye uzanan bir süreç olarak tasvir etmektedir.

1960'larda stratejik yönetim disiplini, yönetsel becerilerin önemine odaklanan çalışmalara önem vermiştir (Andrews, 1971; Ansoff, 1965; Chandler, 1962). 1980'lerde endüstri yapısının firmalar, arasındaki performans farklılıklarını belirlemede oynadığı rolle karakterize edilirken, 1990'larda kaynak temelli görüş ile

yeni bir paradigmanın doğuşu gerçekleşmiştir (J. Barney, 1991; Peteraf, 1993; Wernerfelt, 1984).

Tablo 1. Kaynaklara dayalı yaklaşım görüşleri

Görüş	Teorik Temeller	Sürdürülebilirlik Yeteneği
<b>Kaynak Temelli Görüş</b>	Chicago Okulu (Demsetz, 1973)	değerli, taklit ve ikame edilmesi zor, nadir kaynaklar
<b>Bilgi Temelli Görüş</b>	Firmanın Büyüme Teorisi (Penrose, 1959) Örgütsel Öğrenme Teorisi (Argyris ve Schön, 1978) Avusturya Ekonomi Okulu (Hayek, 1945)	Örtük bilgi
<b>İlişkisel Görüş</b>	Sosyal Ağ Teorisi ( Granovetter, 1985; Granovetter, 1973)	İlişki bağlamında gelişen taklidi zor kurulan ortaklıklar
<b>Dinamik Yetenekler</b>	Firmanın Büyüme Teorisi (Penrose, 1959) İşlem Maliyetleri Teorisi (Williamson, 2009) Sosyal Ağ Teorisi (M. S. Granovetter, 1973); Firma Davranışı Teorisi (Cyert ve March, 1963), Davranışsal Karar Teorisi (March ve Simon, 1958)	Örgüte özgü yetenekler
<b>Kaynaklara Dayalı Yaklaşımları Tamamlayıcı Görüşler</b>		
<b>Faaliyet Temelli</b>	Durumlu Öğrenme Teorisi (Lave ve Wenger, 1991); Firma Davranışı Teorisi (Cyert ve March, 1963); Kurumsal Teori (Meyer ve Rowan, 1977)	Taklit edilmesi zor uygulama ve süreçler
<b>Kurum Temelli Görüş</b>	Davranışsal Karar Teorisi (Simon, 1947; Williamson, 2009); Yeni Kurumsal Ekonomiler (North, 1990)	Kurum ve kaynak sermayesi
<b>Dikkat Temelli Görüş</b>	Davranışsal Karar Teorisi (Simon, 1947)	-----

#### - Kaynak Temelli Görüş

Stratejik yönetim alanının temelinde ‘örgütler nasıl rekabet eder’ sorusu Kaynak Temelli görüş (KATG) ile açıklanmaya çalışılmıştır. Kaynak Temelli görüş, temel

yeteneklere, rant teorisine ve firma büyüme teorisine (Penrose, 1959) dayanmaktadır (Keskin vd., 2016:62). Stratejik yönetim arařtırmalarının hâkim yaklaşımı kabul edilen KATG, Wernerfelt (1984)'in çalışmasıyla ortaya çıkmıştır. Sonrasında (Barney, 1991, 2007) ve (Peteraf, 1993) gibi arařtırmacılar görüşün kavramlarını ve temellerini oluşturmuşlardır. Endüstriyel organizasyon ekonomilerini ele alan ve verimliliğe vurgu yapan Chicago Okulu temelinde şekillenen görüş, getirilerin doğasının açıklanması anlamında Chicago Okulundan, rant teorisi açısından Ricardo ekonomisinden (neoklasik ekonomiler) yararlanmıştır. Chicago Okulu, düşük maliyetler ile gerçekleştirilen üretim, firma ünü ve kaliteli ürün çıktısı gibi firmaya özgü kaynakların verimlilik getirileri sağladığı görüşünü savunmaktadır (Demsetz, 1973). Neoklasik ekonomisinde ise getiriler nadir kaynaklara sahip olunması sonucu elde edilmektedir (Ricardo, 1821: 39-50). Bu bağlamda konum avantajı, değerli toprak, patentler ve kopyalama haklarından elde edilen getiriler bu kapsamda değerlendirilmektedir (Mahoney ve Pandian, 1992). Denge analizlerine dayanan bu görüş statik yaklaşım olarak da bilinmektedir (Bağış ve Öztürk, 2020).

Kaynak temelli görüş, temel kaynaklara sahip olmanın bir firmanın rekabet avantajına sahip olmasını ve performansını arttırdığı görüşünü savunmaktadır (Barney, 1991; Slotegraaf vd., 2003; Vorhies ve Morgan, 2005). KATG perspektifi, firmaların stratejik hedeflerine ulaşmak için etkili bir strateji, sürdürülebilir rekabet avantajı ve dinamik yetenek geliřtirmelerine yardımcı olmaktadır (Chahal vd., 2020).

KATG fikri, “bir idari organizasyon ve potansiyel hizmetler demeti üretken kaynakların bir koleksiyonunun” vazgeçilmez olması gerektiği ilkesine dayanmaktadır (Penrose, 1959). Dasgupta ve Gupta'nın 2009 yılında yaptığı çalışmada dış çevre ortamında artan kargaşayla yüzleşmek, ayakta kalabilmek ve rekabet avantajı elde edebilmek için temel güç kaynağı olarak işletmelerin iç kaynaklarına ve yeteneklerine odaklanmaları gerektiğini vurgulamışlardır. Bu rekabet üstünlüğü, stratejik amaçlar için bir zorunluluktur ve taklit edilemez olmalıdır. Penrose (1959) bu görüşü, stratejinin “mevcut kaynakların kullanımı ile yenilerinin geliştirilmesi arasında bir denge” olduğunu açıklamıştır. Kısacası, örgütlerin rekabet avantajı elde edebilmeleri



için öncelikle iç kaynaklarını en iyi şekilde kullanmaları ve ardından yeni kaynaklara yönelmeleri gerekmektedir.

Wernerfelt'e göre rekabetçi avantaj hem Porter'ın (1980) rekabetçi, çevreye odaklanan jenerik stratejileri (farklılaştırma ve odaklaşma, düşük maliyet liderliği) hem de firmanın rekabet stratejisi uygulamasını sağlayan mevcut kaynakları ile açıklanabileceğini savunmaktadır. Firmalar çevrelerinde karşılaştıkları her fırsat için yeni bir yetenek edinmektense mevcut kaynaklarını farklı şekillerde kullanmayı başararak çevrelerindeki fırsatları değerlendirebilirler. Bu çerçevede firmaları rekabet avantajı elde etmesinde benimsedikleri strateji etkileyen kaynak temellerinin önemli bir rolü bulunmaktadır (Barney ve Clark, 2007). Bir örgütün kaynakları, örgütün daha iyi rekabet etmesine ve vizyon, misyon, strateji ve hedeflerini gerçekleştirmesine yardımcı olan güçlü yönler olarak değerlendirilebilmektedir (Peter, 1981). Kaynak temelli görüşün perspektifi, firmaların stratejik hedeflerine ulaşmak için etkili bir strateji ve dinamik yetenek geliştirmelerine ve sürdürülebilir rekabet avantajı elde etmelerine yardımcı olmaktadır (Burnard ve Bhamra, 2011). KATG başlangıçta yalnızca stratejik yönetim alanında tanınmasına rağmen, operasyonel yönetim dahil olmak üzere tüm fonksiyonel iş alanlarında uygulanabilmektedir (Chahal vd., 2020).

Stratejik yönetim literatürü kaynak hareketsizliği ve kaynak heterojenliği varsayımlarına dayanmaktadır. KATG bu iki varsayımdan yola çıkmakta, - firmalar stratejilerini yönlendiren kaynak ve yetenekler bakımından heterojendir ve - kaynak ve yetenekler firmalar arasında tam olarak hareketli değildir, bir örgütten diğerine aktarılamaz ve bu nedenle örgütsel kaynak farklılıkları çok uzun süre devam edebilir görüşünü savunmaktadır (Miles, 2012). Rakiplerine kıyasla daha üstün ya da daha ayırt edici kaynaklara ve yeteneklere sahip olan örgütler, eğer kaynaklarını ve yeteneklerini mevcut çevresel fırsatlar ile doğru biçimde eşleştirirlerse rekabet avantajı elde edebileceklerdir (Peteraf, 1993). Kaynak Temelli görüş kapsamında, firmalar içinde buldukları çevrede ortalama bir firmadan daha yüksek bir marjinal değer yaratmayı başarabiliyor ve uyguladıkları strateji başka firmalar tarafından taklit edilemiyor ise o firmaların sürdürülebilir rekabet avantajına sahip oldukları düşünülmektedir. Rekabet avantajının sürdürülebilir olması, yalnızca mevcut rakiplere

karşı değil; gelecekte rakip olma potansiyeline sahip firmalara karşı da üstün bir pozisyon elde etmeyi ifade etmektedir (Assensoh-Kodua, 2019). Sürdürülebilirlik, rekabet avantajının belli bir zaman aralığı ile kısıtlı olmadığını vurgulamaktadır. Sürdürülebilir rekabet avantajı, bir örgütün kontrol ettiği ve değerli, nadir, taklit ve ikame edilemez kaynak ve kabiliyetler ile elde edilmektedir (Engert vd., 2016). Kaynaklar bağlamında arz-talepten daha az olduğunda nadir kaynaklardan söz edilmektedir. Kaynaklar hareketsiz olduklarında ve takip edilmeleri veya çoğaltılmaları maliyetli olduğunda ikame edilemez ve taklit edilemez olarak nitelendirilmektedir. Örgütün kaynaklarının sürdürülebilir rekabet avantajı elde etmek üzere özümseme ve kullanma yeteneğine sahip olması gerekir, bunu da örgütsel süreçleri ile sağlamaktadır (Barney ve Clark, 2007; Keskin vd., 2016).

#### - **Bilgi Temelli Görüş**

Bilgi, uzun vadede firma performansını belirleyen kilit stratejik firma kaynaklarından biri olarak kabul edilmektedir (Curado ve Bontis, 2006). Bu nedenle bilgiye sahip olma veya erişilebilirlik, firmaya değer katması, taklit edilmesi zor, organize edilebilirliği yüksek olması özellikleri ile firmalara sürdürülebilir rekabet avantajı sağlamaktadır (Arend ve Lévesque, 2010). Firmaların stratejik karar vermesinde bilginin öneminin farkındalığı, bilgi tabanlı kaynaklar ve bunların firma içindeki koordinasyonunu ele almak amacıyla kaynak tabanlı görüşün büyümesi Bilgi Temelli Görüşün (BTG) doğmasına neden olmuştur. BTG, kurumsal öğrenme kavramı ve firmanın pazar ortamını tarama, tanımlama, yorumlama, entegre etme ve ilgili bilgileri depolama yeteneği ile ilişkilidir (Grant, 1996). BTG, fırsatları belirlemek ve bunlardan yararlanmak için kullanılan kaynaklar olarak operasyonel hale getirilen bilgi tabanlı kaynak demetlerinin firma performansına önemli bir katkı sağladığını ortaya koymaktadır (Wiklund, vd., 2003). Benzer şekilde, yapılan bir çalışmada firmanın bilgi algılama yeteneği ile yeni ürün performansı arasında pozitif bir ilişki bulunduğu vurgulanmıştır (Olavarrieta vd., 2008). Bilgi temelli kaynakların, bir firmanın pazar yönetimi ile firma performansı arasındaki bilginin kaynağı, miktarı ve özgüllüğü ile yenilik performansı arasındaki ilişkilere de aracılık ettiği gösterilmiştir (Atuahene-Gima vd., 2008). Bir firmanın dönüştürücü bir teknolojiyi benimseme motivasyonları,

teknolojinin; artan verimlilik veya etkinlik nedeniyle maliyetleri düşürme veya değer algılarını artırarak talebi artırma yeteneği ile bağlantılı olduğu ifade edilmiştir. Mevcut bilgi kaynağından elde edilen rekabet avantajları, dinamik pazarlarda kısa ömürlü olabilmektedir. Rekabet avantajının uzun ömürlülüğü, bu avantajın altında yatan yeteneklerin taklit edilemezliğine bağlı olmaktadır (Barney, 1991; Pereira ve Bamel, 2021).

Slater ve Narver (1995) firmanın bilgi kaynaklarının, iç ve dış kaynaklardan, deneyimlerden, başkalarının deneyimlerinden veya kurumsal hafızadan elde edilen bilgilerin toplamı olduğunu vurgulamıştır (Slater ve Narver, 1995). Bilginin birçok yönü mevcut olmakla birlikte, Grant (1996) örtük bilgi ve açık bilgi olmak üzere iki bilgi kategorisi tanımlanmıştır. Açık bilgi, kolayca kodlanabilen, aktarılabilen ve elde edilebilen bilgiyi ifade etmektedir (R. M. Grant, 1996) . Örneğin, yeni bir teknoloji hakkında bilgi sahibi olmak farkındalık ve anlayış kazanmaktır. Bu durumda, açık bilgi nadir, taklit edilemez veya ikame edilemez özelliklere sahip olmadığından rekabet avantajı kaynağı olarak kabul edilmemektedir. Örtük bilgi, yani “know-how”, organizasyonel eylemi yönlendiren bir dizi benzersiz beceri, süreç veya yeteneklere dayalı olarak bir şeyin nasıl yapılacağını bilmek şeklinde tanımlanmaktadır (Kogut vd., 1992). Bu bilgi insanların zihnine gömülü bir bilgi türüdür. Bir işin nasıl yapılacağını öğrenilmesiyle ve deneyimle kazanılmakta olduğundan, örtük bilginin kazanımı kimi zaman yıllar alabilmektedir. Bilgi ne kadar örtük ise, diğer firmaların kopyalaması o kadar zor olacak ve rekabet kaynağı olma olasılığı o kadar yüksek olabilecektir (Vargo ve Lusch, 2004). Bilgiye dayalı kaynaklar doğası gereği stratejiktir ve ticari kazanç için bilginin elde edilmesi, özümsemesi ve kullanılması aracılığıyla müşteriler için değer yaratmak amacıyla firmanın kullandığı süreçleri ve yetenekleri içermektedir (Hunt ve Gauthier-Loiselle, 2010). Organizasyonlardaki yapısal değişiklikler, teknolojik gelişmeler, ürün temelli ekonomiden bilgi temelli ekonomiye geçiş ve Endüstri 4.0 gibi modern iş koşulları, performans ve rekabet avantajı sağlamak için kaynak-bilgi temelli görüşün bir çerçeve olarak popülerleşmesine ivme kazandırmıştır. Yapılan çalışmalarda, Endüstri 4.0’ın hayatımıza girmesi ve büyük veride yaşanan artış ile firmaların stratejik ve operasyonel kararlarında iyileşme yaşandığı ve aynı zamanda şirketlerdeki bilgi odaklı

dönüşümün gerçekleşmesi ile rekabet gücünde bilginin öneminin arttığı belirtilmiştir (Gupta vd., 2021).

#### - **Dinamik Yetenekler Görüşü**

Dinamik yetenekler görüşü (DYG), son on yılda stratejik yönetim araştırmalarında en etkili teorik perspektiflerden biri olarak görülmektedir (Schilke, 2014). Schumpeter'in yaratıcı yıkım mantığı üzerine inşa edilen dinamik yetenekler, firmaların ortaya çıkan iş fırsatlarını yakalamalarına ve değişen piyasa koşullarına uyum sağlamak için iş yapma biçimlerini yeniden yapılandırmalarına izin vermek amacıyla önerilmiştir (Teece, 2007). Dinamik yetenekler, firma liderlerinin yeni ürünler ve süreçler geliştirmek için kullanabilecekleri hem yetenekleri hem de yetkinlikleri içermektedir (Augier vd., 2009). Rekabetçi piyasa ortamlarında gelişmiş ve tutarlı performans elde etmek için şirket kaynaklarının uyarlanmasını sağlamak amacıyla DYG kullanılmaktadır (Lin ve Wu, 2014). DYG, kaynakları yeni değer yaratan stratejilere dönüştürerek dinamik pazarlarda firmalar için ürün geliştirme, stratejik karar verme, değer yaratma gibi belirli stratejik, organizasyonel ve yönetsel süreçler olarak tanımlanmıştır (Eisenhardt ve Martin, 2000). Literatür, dinamik yetenekleri stratejik değişime yönelik üç temel sürece ayırmıştır. Bunlar, yeni fırsatları ve tehditleri algılamayı, iş modeli tasarımı ve stratejik yatırımlar yoluyla yeni fırsatlar yakalamayı ve mevcut iş modellerini ve stratejilerini dönüştürmeyi veya yeniden yapılandırmayı içermektedir (Helfat ve Raubitschek, 2018; Steininger, vd., 2022).

Evrimsel ekonomi literatürü ve kaynak tabanlı görüşten doğan dinamik yetenekler görüşü, firmaların farklı çalışma ortamlarında rekabet edebilmek amacıyla firmaya özgü yeteneklerini nasıl geliştirip kullandıklarına odaklanmaktadır (Wilden vd., 2013). DYG, dinamik yetenekler ve operasyonel yetenekler olmak üzere iki temel yeteneği içinde barındırmaktadır. Dinamik yetenekler, firmaların yeni yetenekler oluşturma ya da çevresel belirsizlik karşısında var olan örgütsel yeteneklerini dönüştürme yetkinlikleri olarak tanımlanmıştır (Teece vd., 1997). Bu yetenekler, işletmenin mevcut işletme yetenekleri üzerine inşa edilmekte ve firmanın rekabet avantajının temeli olarak kullanılmaktadır (Leih ve Teece, 2016). Operasyonel yetenekler ise

firmanın geçmiş başarılarını tekrarlamak ya da sürdürmek için gerekli olan prosedürleri, süreçleri ve becerileri öğrenerek ve iyileştirerek kaynak tabanında yararlandığı kapasitesini ifade etmektedir (Winter, 2003). Bu yetenekler statik (Collis, 1994: 148), ilk düzey (Danneels, 2002: 1114), sıfır düzey (Winter, 2003: 992) ve sıradan yetenekler (Teece, 2014: 330) olarak da adlandırılmaktadır. Bunlar, firmanın yeteneği haline gelme eğiliminde olan bir dizi kalıcı organizasyonel rutinden kaynaklanmaktadır (Winter, 2003).

Dinamik yeteneklerle ilgili yapılan çalışmalarda, kaynakların değerinin farklı koşullar altında değişebileceği öne sürülmekte; bu nedenle stratejik kaynakların elde edilmesi, biriktirilmesi ve yeniden yapılandırılması temel hale gelmektedir (Teece vd., 1997). DYG, hızla değişen ortamları ele almak için yeni yetenek biçimleri oluşturabilen, değiştirebilen ve meta yetenekler olarak tanımlanmaktadır (Teece, 2007). DYG, küresel finansal kriz, iklim değişikliği ve yükselen ekonomiler gibi giderek daha fazla öngörülemeyen çevresel zorluklar nedeniyle daha popüler hale gelmektedir (Randhawa, vd., 2021); (Bağış ve Öztürk, 2020).

#### - İlişkisel Görüş

Kaynak temelli teoriye dayalı olarak, dinamik yetenekler görüşü, bilgi temelli görüş dışında, ilişkisel görüş, firmanın piyasada başarılı olmasını garanti eden değerli kaynaklar olarak görülmektedir. Rindfleisch ve Moorman (2003), organizasyonların rakipleriyle iş birliği yapmaları halinde (firmalar arası iş birliği), bireysel bir iş modeli altında faaliyet göstermelerine kıyasla daha yüksek düzeyde verimlilik sağlamak için yeni kaynaklar ve yetenekler elde edebileceklerini vurgulamışlardır. Pazarda kar elde etmek için diğer varlıklarla rekabet eden firmanın atomistik duruşu, firmaların sosyal ve profesyonel ağlarda kurulduğu ve diğer ekonomik varlıklarla ilişkiler içinde olduğu dünyada giderek yetersiz kalmaktadır (Gulati vd., 2000). Burada ilişkisel bağlar devreye girmekte ve iki ya da daha fazla firma arasında insan kaynakları, para, sermaye, bilgi ve teknoloji gibi somut ve soyut kaynakların ödünç alınması ve verilmesi ya da alışı ve satışı gibi işlemlerin gerçekleştirilmesini sağlamaktadır (Wasserman vd., 1994).

İlişkisel görüş, rekabet avantajının karşılıklı olarak uyarlanmış firmalar arası ilişkilerin ve ortakların ortak girdilerinin bir sonucu olduğu savunulmakta (Dyer vd., 1998), bu da şirketlerin birlikte gelişmelerini ve böylece ilişkisel rantların oluşmasını sağlamaktadır. Şirketler arasındaki rekabet genel kural olsa da kaynaklarını farklı bir şekilde entegre eden firmalar, bunu yapamayan veya istemeyen rakip firmalara kıyasla daha fazla avantaj sağlayabilmektedir. İlişkisel görüş, yüksek kaliteli organizasyonlar arası ilişkilerin (potansiyel olarak rakipler dahil) şirket performansını nasıl olumlu yönde etkileyebileceğine odaklanmıştır (Dyer vd., 1998). Barney (2018) tarafından yapılan çalışmada, karar vericilerin işlerinde daha başarılı olmak için kilit ortaklarla (örneğin, bu mevcut rakipler) yakın çalışması gereken koşulları kabul ederek, paydaş boyutunda kaynak tabanlı görüşü genişletmiştir (Barney, 2018).

İlişkisel görüş, hiçbir firmanın piyasada başarılı olmak için gerekli ve değerli tüm kaynaklara ve yetkinliklere sahip olmadığını vurgulamaktadır. Çözümlerden biri, organizasyonlar arası bağların oluşturulması ve çevreden kaynak ve yetkinliklerin edinilmesi yoluyla ilişkilerin başlatılmasıdır. İlişkinin belirlenmesinin temeli, ağ içinde var olan veya diğer ortaklarla ilişkiler geliştirilmesi sonucu olarak firmanın dahili ögesi olabilecek ilişkisel kaynakların belirlenmesi olarak ifade edilmektedir (Castaldo, 2007). Ağdaki ilişkilerin oluşturulması, firmanın bilgiye, kaynaklara, pazarlara ve teknolojiye erişim sağlaması, ölçek ve kapsam ekonomilerini öğrenmesi ve bunları kullanması sürecindeki faydalar, firmanın stratejik hedeflere ulaşılmasına yardımcı olmaktadır (Gulat vd., 2000). Firmalar arasındaki ilişkileri başlatmanın amacı, sadece firmaları geliştirmek ve müşterilere ürün tekliflerini ayarlamak değil, aynı zamanda faaliyetlerin çevreye saygılı hale getirilmesi için yeni teknolojilere ve bilgilere erişim sağlamaktır. Firmalar arasındaki ilişkilerin önemi, iç kaynaklarının çığır açan bir yenilik yaratmak için yetersiz olduğu, dinamik teknolojik ortamlarda faaliyet gösteren kuruluşlarda gözlenmektedir (Srivastava ve Gnyawali, 2011). İlişkileri başlatmak, özellikle yenilikler yaratma sürecinde bilginin kullanımına odaklanarak kaynakları birleştirmelerine olanak tanımaktadır. Farklı ortaklarla olan çeşitli ilişkiler, firmaların risk ve belirsizlik yönetimine yardımcı olan ve ortakların belirli bir kaynak tabanını kullanma fırsatları sunan birçok değerli kaynağa erişmesi sağlanmaktadır (Wassmer, 2010). İş birliği ve ekip faaliyetlerini ilgilendiren ilişkisel

görüş, ayrıca sinerjinin özelliğinden kaynaklanan bir katma değer yaratma kaynağı olarak görülebilmektedir (Otola vd., 2013).

#### - Faaliyet Temelli Görüş

Strateji çalışmaları uygulamalı olarak (Whittington, 1996)'ın çalışmasıyla ortaya çıkmıştır. Bu çalışmalar faaliyet temelli görüş (FTG) (Jarzabkowski, 2005) veya stratejinin uygulama temelli görüşü (Jarzabkowski vd., 2016) olarak da bilinmektedir. Stratejik yönetim araştırmasında FTG için kullanılan eş anlamlılar mikro faaliyetler, mikro strateji veya stratejik uygulamalardır (Allen ve Helms, 2006). FTG, stratejik sonuçlarla ilgili örgütsel yaşamın günlük faaliyetlerini oluşturan ayrıntılı süreçlere ve uygulamalara odaklanmaktadır (Johnson vd., 2003:8). FTG temelli görüşün ana hedefleri arasında strateji oluşturan sayısız mikro aktiviteyi anlamak ve pratikte strateji oluşturmak yer almaktadır (Johnson vd., 2003:3). Bu sayede, faaliyetlerin “kara kutusuna” girmek ve “iş modellerinin mikro mekanizmalarının” daha iyi anlaşılması sağlanmaktadır (Zott vd., 2010:224).

Faaliyetler, bir amacı yerine getirmek ya da belirli bir amaca hizmet etmek için varlıkların, kaynakların ve yeteneklerin katılımı olarak görülür. Buna uygun olarak, faaliyet sistemleri, bir firmanın sınırları içinde ve ötesinde birbirine bağlı faaliyetler dizisidir (Zott ve Amit, 2011). FTG, bir firmanın kaynakları ve yeteneklerinin katılımı ile rekabet avantajı elde etmede firma faaliyetlerinin, rutinlerinin ve iş süreçlerinin rolünü vurgulamaktadır (Sheehan ve Foss, 2007). FTG altında yatan mantık, firmaların ürünler için değil, tüketicilere ürün veya hizmet sağlamak için gerçekleştirdikleri faaliyetler için ödeme almaları olarak belirtilmektedir (Sheehan ve Foss, 2007; Porter, 1985). Faaliyetler üst düzey planlama, kaynak bulma, üretim veya teslim faaliyetleri gibi farklı düzeylerde veya alt faaliyetler düzeyinde değerlendirilebilmektedir (Davenport, 2005:189). FTG’de rekabet avantajı, “kaynakların ve yeteneklerin nihai değerlerinin ve rekabet avantajı yaratma yeteneklerinin gerçekleştiği piyasa süreçlerine maruz kaldığı mekanizmalardan” kaynaklanmaktadır (Ray vd., 2004:35). FTG aynı zamanda firmaların endüstri içinde elde ettikleri rekabet avantajları gibi

makro fenomenleri mikro açıklamalarla ilişkilendirmeye izin vermektedir (Zellner, 2014).

### - Kurum Temelli Görüş

Kurumları bağımsız değişkenler olarak ele alan kurum temelli strateji görüşü (KTG), kurumlar ve kuruluşlar arasındaki dinamik etkileşime odaklanmakta ve stratejik seçimleri böyle bir etkileşimin sonucu olarak değerlendirmektedir (Mike vd., 2008). Kurum temelli görüş, endüstri bazlı rekabet, firmaya özgü kaynaklar ve yetenekler olmak üzere strateji tripodunun üçüncü bir ayağı olarak görülmektedir. Endüstri temelli ve kaynak temelli görüşlere ek olarak, firmaların strateji oluştururken devlet ve toplum gibi kaynaklardan daha geniş etkileri de hesaba katmaları gerektiğini savunan kurum temelli görüş stratejisidir (Peng, vd., 2009). Bu paradigmaya olan ilginin nedenlerinden biri, son yıllarda çoğu endüstride yaşanan küreselleşme sürecinden kaynaklanmaktadır (Dunning ve Lundan, 2008)

Kurumların en temel rolü belirsizliği azaltmak, karar yönergelerini belirlemek ve bunlara anlam kazandırmaktır (Scott, 2014). KTG, kurumlar ve kuruluşlar arasındaki dinamik etkileşime odaklanmakta ve stratejik seçimleri böyle bir etkileşimin sonucu olarak değerlendirmektedir (Peng, vd., 2009, s. 66). Bu nedenle, KTG'ün temel önermesi, bireylerin ve kuruluşların (firmalar ve hükümetler gibi) "belirli bir kurumsal çerçevedeki formal ve informal kısıtlamalar dahilinde rasyonel olarak çıkarlarını takip etmeleri ve stratejik seçimler yapmaları" olarak vurgulanmaktadır (Peng, vd., 2009). Görüş, rekabet avantajının dayanağını kurumsal bağlamdaki normatif rasyonellik, kurumsal izolasyon mekanizmaları ve eş biçimlilik baskılarını yönetebilme yeteneğine bağlamaktadır. Temel olarak KTG, firmanın baskın kabul edilebilir ekonomik davranışlarla olan ilişkisinin ve bu davranışların yansımalarının, bir firmanın kaynakları ve endüstri yapısı içindeki göreceli konumu nedeniyle ortaya çıkan etkiye ek olarak bir firmanın performansını etkileyebileceğini savunmaktadır (Peng vd., 2009). KTG, sürdürülebilirlik mekanizmalarını kaynak sermayesi ve kurumsal sermaye ile açıklamaktadır (Oliver, 1997:697) Kaynak sermayesi, firmanın değer artıran kaynakları ve yetenekleri olarak tanımlanmaktadır. Kurumsal sermaye ise kaynak



sermayesinin verimli bir şekilde kullanılmasını sađlayan bađlamsal faktörler olarak nitelendirilmektedir. Görüşle ilgili yapılan açıklamalar KATG'yi tamamlayıcı bir nitelik taşıdığını göstermektedir (Bađış ve Öztürk, 2020).

#### - **Dikkat Temelli Görüş**

Dikkat temelli görüş (DTG) (Ocasio, 1997:162), firmaların stratejik karar vermesini ve adaptasyonunu yani stratejideki kilit konuları açıklamak için önerilmiştir. Bu görüş, davranışsal karar teorisinden dikkat kavramı üzerine temellenmiştir. Dikkat temelli görüş, bir firmanın belirli bir dizi konuya, sorunlara, fırsatlara ve tehditlere ayırdığı zaman ve çabayı ifade etmektedir (Ocasio, 1997:188). DTG, firmanın stratejik gündemini, organizasyonlarda kaynakların tahsisini ve dağıtımını yönlendiren sorunları ve eylem alternatiflerini kapsamaktadır (Ocasio ve Joseph, 2005). DTG ilk önerildiğinde, amaç, Simon'un (1947) yapı ve biliş çalışmasına paralel olarak dikkatin yapılandırılmasının önemine dair daha derin bir anlayış geliştirme ve “bireysel bilgi işleme ve davranışı örgütsel yapıyla ilişkilendirmek” amacıyla ileri sürülmüştür (Ocasio, vd., 2005). Bu bilgi işleme görüşü, performans geri bildirim etkileri (Washburn vd., 2012), firma tahmin yeteneđi dahil olmak üzere strateji araştırmasında dikkat temelli görüş uygulamalarına da yansıtılmaktadır (Iyer ve Miller, 2008). Görüşün stratejik yönetim alanına katkısı, karar alma aşamasında örgütsel süreçlerin temeline dikkati koymasını olarak açıklanmaktadır (Washburn vd., 2012). Bu kapsamda dikkatin odaklandığı bu örgütsel süreçler ile dinamik yeteneklerin bađlantısı dikkat çekmektedir (Bađış ve Öztürk, 2020). Görüş, bu özelliđi nedeniyle dinamik yetenekler araştırmaları kapsamında tamamlayıcı bir özellik göstermektedir (Ocasio vd., 2005:56).

### **3.2. Sađlık Hizmetlerinde Stratejik Yönetim ve Önemi**

Günümüzün dinamik ve rekabet ađırlıklı çevresinde faaliyet gösteren sađlık kurumları, faaliyetlerini sürdürebilmek ve rekabet üstünlüğü elde etmek amacıyla stratejik yönetime ihtiyaç duymaktadır. Sađlık kurumunun hayatını devam ettirmesi, kurumun amaç ve hedeflerine uygun stratejiler belirlemesi ve belirlenen stratejilerin etkin bir

şekilde uygulanması süreci ile mümkün olabilmektedir. Bu nedenle tüm örgütlerde olduğu gibi sağlık sektörü için de stratejik yönetim önem teşkil etmektedir (Eren, 2010:355). Aynı zamanda sağlık yöneticileri ve liderleri, sağlık kurumlarını hem değişen iç ve dış ortamlara uyarlamak hem de sağlık sektörünün karmaşıklığına uyum sağlamak için de stratejik yönetim yaklaşımını benimsemelidir. Strateji, rekabet avantajı elde etmek ve paydaşların beklentilerini karşılamak için yetkinliklerin ve kaynakların yapılandırılması yoluyla değişen küresel, çalkantılı ve belirsiz bir ortamda bir kuruluşun uzun vadeli yönünü ve kapsamını ifade etmektedir (Johnson, 2008).

Sağlık sektöründe stratejik yönetim kavramının önem kazanmaya başlaması 1970'lerin başında gerçekleşmiştir. Bu durumu tetikleyen nedenlerden biri çoğu hastanenin ve sigorta şirketinin kar amacı gütmeyen kurum statüsünden kar amacı güden kurum statüsüne geçmiş olması ile yaşanmıştır. Yaşanan bu değişim sağlık kurumları arasındaki rekabet düzeyinin artmasına ve daha rekabetçi stratejilerin benimsenmesine yol açmıştır (Walston, 2013: 6). Geçen zaman sürecinde sağlık hizmetleri en gelişmiş ticari şirketlerle benzer süreçleri kullanan karmaşık bir iş kolu haline gelmiştir. Sağlık sistemi gelişmeye devam ettikçe, sağlık hizmeti kuruluşlarının stratejik olarak yönetilen işletmelerden öğrenecekleri de artmaktadır. Hem kamu hem de özel sağlık kuruluşları tarafından benimsenen yönetim şekillerinin çoğu, başlangıçta iş sektöründe geliştirilmektedir (Ginter vd., 2018:52). 1980'ler ve 1990'lar boyunca endüstri değişikliklerinin devam etmesi, hastaneler ve sağlık sistemleri arasında artan çeşitlendirme ve entegrasyon faaliyeti ile stratejik yönetim perspektifi sağlık hizmetleri araştırmacıları arasında popülerlik kazanmaya devam etmiştir (Fennell ve Alexander, 1993). Bu dönemde stratejik yönetim teorisini kullanan sağlık kuruluşları ile ilgili değişen hastane endüstrisinde hayatta kalma stratejilerine ilişkin değerlendirme (CodCoddington, vd., 1985), sağlık organizasyonlarında stratejik adaptasyon (Kimberly ve Zajac, 1985) ve hastaneler arasında değişen stratejilerin incelemesi (Zajac ve Shortell, 1989) üzerine çalışmalar gerçekleştirilmiştir. Yakın zamanda yapılan çalışmalarda küresel alanda sağlık liderliği (Figuroa, vd., 2019), akıllı ve sürdürülebilir sağlık yönetiminin tasarlanması (Aquino, vd., 2018), kişiselleştirilmiş sağlık hizmetleri alanında stratejik bakış açısı (Naamati Schneider,

2020), sađlık kurumlarında stratejik planlama (Esfahani, vd., 2018) konularında çalıřmalar ele alınmıřtır.

Strateji ve stratejik yönetim anlayıřı sađlık sektöründe başarılı olabilmek için bir yol haritası olarak görülebilmektedir. Bu yönetim anlayıřı sađlık kurumları yöneticilerine daha iyi karar verici olmaları yolunda dikkate almaları gereken önemli ve kritik hususlar konusunda yardımcı olmaktadır. Stratejik düşünebilen yöneticiler örgütlerin proaktif olarak řekillenmesini sađlayarak sınırlı olan kaynakların etkili bir biçimde dađıtımının yapılmasını, tehditlerin daha etkin bir şekilde minimize edilmesini ve farklı tüketici gruplarının memnuniyetini sađlayabilmektedir. Bu durumda sađlık kurumlarında rekabet avantajı kazanılmasına ve kazanılan bu avantajın sürdürülmesine katkıda bulunabilmektedir. Sađlık hizmetlerine olan talep ve bu sektördeki deđişim devam ettikçe strateji ve stratejik yönetim kavramlarına duyulan ihtiyacın gelecekte de devam edeceđi düşünölmektedir. Sađlık kurumları ancak yařanan içsel ve dışsal deđişimler dođrultusunda ilgili stratejiler belirleyip uygulayabildikleri ölçüde rakiplerine fark yaratıp ayakta kalmayı başarabilecekleri vurgulanmaktadır (Walston, 2014). Sosyal medya araçlarının hastanelerde stratejik karar verme düzeyini etkileyip etkilemediđini deđerlendiren çalıřmada, İstanbul ilinde 237 hastanenin sosyal medya araçları incelenmiř ve metin madenciliđi çalıřması gerçekleştirilmiřtir. Yapılan bu çalıřmada, hastanelerin sosyal medyayı tek taraflı bilgilendirme, haberleřme ve müşteri řikâyet yönetim sistemi aracı olarak kullandıkları; mevcut derin öğrenme, yapay zekâ ve veri madenciliđi gibi yöntemlere uygun alt yapı oluřturacak şekilde kullanmadıkları ve stratejik karar verme aracı olarak görmedikleri sonucuna varılmıřtır. (Silahtaröđlu ve Canbolat, 2018). Başarılı sađlık merkezleri için stratejik düşünce ve bilgi yönetimi araçlarına dayanan veri ambarı ile stratejik karar verme yetkisine sahip personelin olması ve yönetimin yetkilendirilmesinin önem tařıdıđı vurgulanmıřtır (Ali vd., 2016). Deđerişken sađlık hizmetleri pazarında dinamik ve karmařık yapılar, hızla deđerişen tıbbi teknolojiler, bilgili ve talepkar müşteriler, yetenekli ve profesyonel rakipler ve kaynak sınırlaması stratejik yönetimde rekabet avantajı elde etmek için deđerli ve faydalı bir araç olarak görölmektedir (Mosadeghrad, 2014; Esfahani, vd., 2018).

Günümüzde dinamik çevrelerde faaliyet gösteren tüm örgütlerin başarılı olabilmesinin temelinde esas olan yönetim anlayışı stratejik yönetim olarak kabul edilmektedir. Diğer endüstrilerde olduğu gibi sağlık sektöründe de başarılı olunabilmesi için mevcut kaynakların etkili kullanılabilmesi ve çevrede meydana gelen değişimlere daha hızlı ve etkili bir şekilde cevap verilmesi gerekmektedir. Bu bağlamda stratejik yönetim yaklaşımının benimsenmesi oldukça önem taşımaktadır. Özellikle belirsizliğin yüksek olması, ortaya çıkabilecek hataların insan hayatı ve sağlığını olumsuz yönde etkiliyor olması, dikkatli bir şekilde koordine edilmesi gereken çok fazla sayıda ve çeşitte hizmetin bir arada sunuluyor olması ve en önemlisi de sunulan hizmetin ikame edilemez ve ertelenemez olması sağlık sektöründe stratejik yönetim anlayışının gerekliliğini artırmaktadır (Uğuroğlu vd., 2019). Yaşanan hızlı değişimlerin önümüzdeki yıllarda da artarak devam edeceği düşünülürse, sağlık kurumlarında yeni ve inovatif stratejiler belirlenmesi ve bunların en iyi şekilde uygulanabilmesinin başarılı stratejik sonuçlara ulaşılması sektör için önemlidir.

2019 yılında başlayan pandemi süreci birçok açıdan mevcut sorunları daha da gün yüzüne çıkarmış, sağlık kurumları iş baskısı, stres, yetersiz insan gücü ve yatak sayısı, mali ve organizasyonel sorunlar açısından zorluklarından bağımsız olarak, bilinmeyen bir virüsle baş etmek zorunda kalmışlardır. Ayrıca, pandeminin neden olduğu strese ek olarak hastaneler, ameliyatlarda ve diğer tıbbi faaliyetlerde azalma, ekonomik istikrarlarına zarar verme, hasta kuyruklarının uzaması, personelin azalması ve itibar zedelenmesi ile karşı karşıya kalmıştır (Ron ve Harefuah, 2020). Hastanelerin ve sağlık sisteminin yaşadığı bu sorunlar ve sonuçta farkındalığın oluşması, stratejik yönetim konusunun, ekonomik ve örgütsel olarak istikrarlı sağlık kurumları üretme çabasının bir parçası olarak ulusal bir öncelik haline gelmesine neden olmuştur (Naamati Schneider, 2020).

### **3.3. Sağlık Hizmetlerinde Karar Verme**

Karar verme, seçeneklerin içinden birinin tercih edilmesi, seçilmesi olarak tanımlanmaktadır (Daft, 2004). Bu seçim, karar vermenin yalnızca bir parçasını oluşturmaktadır. Herbert A. Simon'a göre karar verme, yönetim süreci açısından en

önemli kavram olarak nitelendirilmiştir. Simon karar verme sürecinin, işletmenin niteliği ve başarısını belirlediğini savunmaktadır. Alternatifler arasından tercih yapılması ile bir sürecin sonucuna ulaşılması, karar verme süreci olarak tanımlanmaktadır (Frantz, 2003). Drucker (2001)'a göre karar verme süreci aşamaları;- sorunu sınıflandırma, - sorunu tanımlama, - sorunu özelleştirme ve çözüm belirleme, - sınır koşullarını (neyin kabul edilebileceğinden çok neyin doğru olduğunu) belirleme, - kararı eyleme geçirme ve - kararın geçerliliğini ve etkinliğini olayların gerçek akışına karşı test etmektir. Karar tipleri ile ilgili olarak literatürde yaygın olarak yapılan sınıflandırma (Koçel, 2013):

- Programlanabilen (rutin) ve programlanamayan (rutin olmayan) kararlar
- Stratejik ve operasyonel kararlar
- Kişi ve grup kararları
- Alt ve üst kademe kararları
- Belirlilik ve belirsizlik şartları altında verilen kararlar

Yapılan bu sınıflandırmalar arasında örtüşmeler olmakla birlikte her karar tipinin vurguladığı özellik farklıdır. Örneğin, üst kademelerde verilen kararların çoğu stratejik nitelikte, programlanamayan ve belirsizlik şartları altında verilen kararlardır. Ancak bu özelliklerine rağmen, programlanabilme ve programlanamama, karar vermede izlenecek yol ve prosedürleri ile seçim kriterlerini önemli ölçüde etkilemektedir.

Programlanabilen kararlar, tekrarlanan karar süreci içinde prosedürleri belirlenebilen rutin kararlar olarak sınıflandırılmaktadır. Kişiye ya da kişilere bağlı olan ve prosedüre bağlanması mümkün olmayan stratejik nitelik taşıyan kararlarda programlanamayan kararlar şeklinde tanımlanmaktadır. Üst kademelerde alınan kararlar, stratejik nitelik taşıması nedeniyle programlanamayan, belirsizlik koşullarında yöneticinin sezgileri aracılığı ile alınan kararlardır (Koçel, 2013:187). Stratejik ve operasyonel kararlar, işletmelerin rekabet etmeleri amacıyla sahip oldukları kaynaklar ve yönetimi açısından büyük önem arz etmektedir. Üst düzey yöneticiler stratejik kararların alınmasında sorumluluğu en fazla olan çalışan grubudur.

Sağlık alanında hekimler ya da sağlık personelleri tarafından verilen kararlar, tıbbi bakımın maliyetini ve kalitesini kontrol eden en önemli faktörlerden biri olarak karşımıza çıkmaktadır. Tıbbi kararlar bilgiyi eyleme dönüştüren süreçler olup (Eddy, 1986), hangi önleme prosedürlerinin gerçekleştirildiğini, hangi teşhislerin yapıldığını, hangi testlerin istendiğini ve hangi tedavilerin gerçekleştirildiğini belirlemeye yardımcı olmaktadır. İçinde bulunduğumuz rekabet çağında, eylemin yükünü taşıyacak olan tıbbi karar vermedir ve tıbbi uygulamanın kalitesini belirleyecek olan tıbbi karar vermenin başarısı veya başarısızlığı olacaktır. Tüm bunlar nedeniyle tıbbi kararlar son derece karmaşık olabilmektedir. Çoğu durumda sayısız test, laboratuvar ya da görüntüleme sonucunu, çok sayıda faktörü, yüzlerce ilişkiyi içermekte ve her unsur hakkında belirsizlikler bulunmaktadır (Spring, 2008). Bu nedenle sağlık personelleri genelde belirsizlik koşulları içinde kararlar almakta ve uygulamaktadırlar.

Günlük kararların aksine, birçok sağlık hizmeti kararının önemli sonuçları bulunmakta ve önemli belirsizlikler içermektedir. Belirsizlikler, tanı, mevcut tanı testlerinin doğruluğu, hastalığın doğal seyri ya da hastaya verilen tedavinin etkileri olabilmektedir. Hastanın mevcut durumuyla ilgili belirsizlik, klinik bulguların hatalı gözlemlenmesinden veya yanlış kaydedilmesinden veya verilerin hekimler tarafından yanlış yorumlanmasından kaynaklanabilmektedir. Örneğin, karotis arter darlığı gerçekten asemptomatik miydi? Hastanın hiç fark edilmeyen veya başka bir şey olarak yorumladığı geçici bir iskemik atak (beynin bir bölgesine kan akışının kesilmesine bağlı geçici semptomlar) oldu mu? Belirsizlik, verilerin belirsizliği veya bilgilerin yorumlanmasındaki farklılıklar nedeniyle de ortaya çıkabilmektedir. Örneğin, ultrason muayenesi tekrarlandığında, aynı sonucu alır mıydık? Klinik bilgi ile hastalığın varlığı ya da yokluğu arasındaki uyum konusunda da belirsizlikler bulunmaktadır (Hunink, vd., 2014).

Sağlık hizmeti veren kurumlarda karar vermenin üç düzeyi ile (stratejik, yönetsel ve operasyonel), örgütsel planlamanın üç düzeyi (stratejik, uzun vadeli ve operasyonel planlama) yakından ilişkilidir. Stratejik karar verme, örgütün tamamına uygulanan ve örgütler için uzun vadeli sonuçlara sahip olan kararlardır. Örgütün temel hedefleri ve stratejisi ile dış çevreyle ilişkilerini içeren bu kararlar genellikle üst yönetim tarafından

alınmaktadır. Programlanamayan kararların temel alanı genellikle burasıdır ve yönetsel karar verme, taktiksel karar verme olarak da adlandırılmaktadır. Orta düzey yönetim kademesinin aldığı kararlar bir departmana ya da bağlantılı birkaç birime uygulanmaktadır. Bu kararlar uzun ya da orta vadede sonuçlara sahip olabilmektedir. Yönetsel kararlar genellikle programlanabilen kararlar altında değerlendirilirken bunun yanı sıra programlanamayan kararları da kapsayabilmektedir. Operasyonel karar verme, denetleyiciler ya da alt düzey yöneticilerce alınmakta ve uygulanmaktadır. Bu kararlar günlük işlemlere yöneliktir ve tek bir birime uygulanmaktadır. Bu kararlar tipik olarak kısa vadeli sonuçlara sahiptirler. Denetleyiciler zaman zaman programlanamayan kararlarla ilgilenseler de genellikle programlanabilen kararların temel alanı olarak ifade edilmektedir (Sperry, 2003:170).

#### **3.4. Sağlık Sektöründe Dijitalleşme ve Dönüşüm**

Teknolojik dönüşüm hız kesmeden devam ederken yaşanan dijitalleşme, dijitalleşme ve dijital dönüşüm iş yapış modellerini de değiştirmektedir. Bu dönüşüm iş modeli inovasyonu olarak adlandırılmakta ve neredeyse her sektörde önu alınamaz bir hızda gerçekleşmektedir. Temel olarak iş modeli (business model), “bir firmanın müşterilere nasıl değer yaratıp sunduğuna ve bu değerden pay almak için kullanılan mekanizmalara ilişkin bir mimaridir” (Teece, 2018). Bu mimari yapı sürekli değişim, yenilik ve beklenmedik bozulmalara yol açtığından son yıllarda iş dünyasının odağı haline gelmiştir (Savić, 2019). Bu, büyük ölçüde, öngörülemez olasılıklara olanak tanıdığından endüstri üzerinde tüm gücüyle kendini gösteren dijitalleşmenin katlanarak büyümesinin bir sonucu olmuştur (Brynjolfsson ve Mcfee, 2014). Dijital teknolojiler “dijitalleşme” ve “dijital dönüşüm” olarak üçe (Şekil 19.) ayrılmaktadır (Bloomberg, 2018); (Savić, 2019).

	Dijitalleştirme	Dijitalleşme	Dijital Dönüşüm
<b>Odak</b>	Veri dönüşümü	Bilgi işleme	Bilgiyi kullanma/yararlanma
<b>Amaç</b>	Analogdan dijitale dönüşüm	Mevcut iş süreçlerini ve operasyonlarını otomatize etme	Şirketin çalışma, düşünme şeklini ve kültürünü değiştirme
<b>Eylem</b>	Kağıt belgeleri, fotoğrafları, mikro filmleri ve VSH kasetleri dijital formata dönüştürme	İş süreçlerinin tamamen dijitalleştirilmesi	Dijital bir işletmeye dönüşüm ya da yeni bir dijital şirketin kurulması
<b>Araçlar</b>	Bilgisayarlar, dönüştürme / kodlama ekipmanı	Bilgi Teknolojileri sistemleri ve bilgisayar uygulamaları	Yeni ve yıkıcı dijital teknolojilerin matrisi
<b>Zorluklar</b>	Yoğunluk - Malzeme	Finansal	Değişime Direnç - İnsan Kaynakları



Şekil 19. Dijitalleştirme, dijitalleşme ve dijital dönüşüm kavramları

Dijitalleştirme, analog bilgilerin dijital bir formata dönüştürülmesi anlamına gelmektedir (Ng ve Wakenshaw, 2018). Dijitalleştirme, tüm süreçlerin, hizmetlerin ve ürünlerin merkezine ileri teknolojiyi yerleştirmenin önemini vurgulamaktadır. Dijitalleşme ise dijital yayılma yoluyla gerçekleşen ekonomilerin, kurumların ve toplumun sistem düzeyinde yeniden yapılandırılmasını ifade etmektedir (Unruh ve Kiron, 2017). Dijitalleşme, iş modelini değiştirmek, yeni gelir kaynağı ve değer üreten fırsatlar yakalamak amacıyla dijital teknolojilerin kullanılmasını esas alan dijital işletme yapısına geçme sürecinin bir adımı olarak görülmektedir (Gartner, 2018). Dijitalleşme ile süreçler arası koordinasyon verimliliği artmakta ve kullanıcı deneyimleri geliştirilerek müşteriler için değer yaratılmaktadır. Dijitalleşmede maliyet tasarrufuna odaklanılırken, aynı zamanda müşteri deneyimlerini geliştirebilecek süreç iyileştirmeleri de ele alınmaktadır (Ritter ve Pedersen, 2020).

Dijital Dönüşüm, gerçekten dijitalleşmenin sağlandığı iş dönüşümü olarak vurgulanmaktadır. Firmalar ile müşteriler arasındaki (devlet-vatandaş arasında) ilişkiler yeniden şekillenirken yeni iş modelleri geliştirilmektedir, bu sürecin tamamı dijital dönüşümü ifade etmektedir (Savić, 2019). Dijitalleşmenin yol açtığı hızlı ve



dönüştürücü deęişiklikler, çeşitli sektörlerde faaliyet gösteren firmalar için birçok fırsat sağlamıştır. Günümüzde firmalar, dijital dönüşüm ve iş modeli inavosyonu sayesinde kaynak kullanımının iyileştirilmesi, maliyetin düşürülmesi, çalışan üretkenliğinin yoğunlaştırılması, tedarik zinciri optimizasyonu, müşteri memnuniyeti ve sadakatinin arttırılmasından birçok sağlayabilmektedir (Loebbecke ve Picot, 2015). Yeni bilimsel ve teknolojik yenilikler, biyotıp, tıp mühendisliği, klinik teşhis, sıhhi ekonomi, hastane yönetimi ve kültürü ile ilgili hastanelerde çeşitli veri ve olguların elde edilmesini, arşivlenmesini, işlenmesini ve görselleştirilmesini mümkün kılmıştır (Wei-dong, 2004) .

Saęlık sektörünün dijitalleşmesinin en önemli örneklerinden biri, laboratuvar sonuçlarının elektronik tıbbi kaydolara veri tabanlarında depolanması olarak bilinmektedir. Bu sayede saęlık hizmetlerinde karşılaştırmalı deęerlendirmenin önü açılmıştır. Bunun dışında röntgen filmlerinin, reçete bilgilerinin, hekim notlarının ve hasta yatak başı verilerinin dijital olarak tutulması adımları saęlıkta dönüşümün başlamasının mihenk taşları olarak görülmektedir. Saęlıkta dijitalleşmenin gerçekleşmesi ile gerçekleşen tele tıp uygulamaları ile hastalar, hastaneye gitmeden saęlık hizmetleri alabilmektedir (Glauner vd., 2021:74). Dijital Hastane, tıbbi cihazlar, akıllı bilgi sistemleri, lokasyon bazlı servisler gibi en son teknolojileri entegre ederek, personel verimliliğini arttırmaya, hastanenin operasyonel süreçlerini kolaylaştırmaya, süreç kalitesini iyileştirmeye, dijital iletişim araçlarını saęlık süreçlerine dahil etmeye ve hasta güvenliğini saęlamaya katkıda bulunan bir kavramdır (Della Mea, 2001); (Eden, vd; 2021). Saęlık Bakanlığı'na göre Dijital Hastane; idari, finansal ve tıbbi süreçlerde bilişim teknolojilerinin maksimum düzeyde kullanıldığı bir hastaneden, birbirleriyle ve dięer bilgi sistemleri ile saęlık personeli ve hastalar, teletıp ve mobil tıp uygulamalarını kullanarak hastane içinde veya dışında veri alışverişi yapabilmektedir (T.C. Saęlık Bakanlığı, 2016). Dijital hastane, tıbbi gelişimi teşvik etmek ve saęlık hizmeti kalitesini iyileştirmek için gelişen ve dönüşen hastanelerin en önemli hedefi olmalıdır.

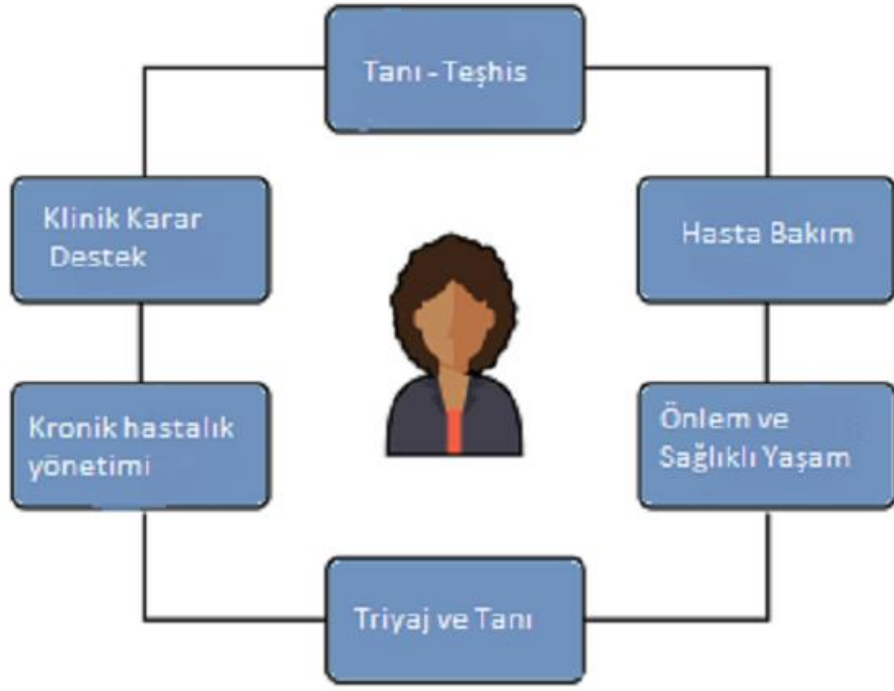
Saęlık hizmetlerinde hastalıkların önlenmesi, teşhisi, tedavisi ve izlenmesine yönelik bilgi ve iletişim sistemlerinin kullanımı ve saęlık danışmanlığı verilmesi “e-Saęlık”

terimi ile tanımlanmaktadır. Bu kapsamda “Dijital hastane, mobil sağlık, tele tıp ve robotik sağlık” e-Sağlığın alt bileşenleri olarak tanımlanmaktadır (Wicks, vd., 2014). Dijital Hastane, yüksek kalitede sağlık hizmeti sunmak için bilgi ve iletişim teknolojilerini klinik ve idari iş akış süreçlerine entegre ederek, hastane hizmetlerini hastane dışındaki bireylere taşıırken hem hastane içindeki hem de hastane dışındaki (birbirinden uzak yerlerde çalışan birimler) sağlık personeli arasında da bağlantı kurmaktadır. Dijital hastane kavramı, sağlık sektöründe son dönemde ön plana çıkan uygulamalardan biridir. Bu nedenle Avrupa ve Türkiye'deki birçok hastane dijital dönüşüm sürecinden geçerek “dijital hastane” sertifikası almak için akreditasyon faaliyetlerine başlamıştır. Hali hazırda Sağlık Bilişimi ve Yönetim Sistemleri Topluluğu (Healthcare Information and Management Systems Society, HIMSS), değerlendirmeleri kapsamında Türkiye’de 174 hastane “Aşama 6”, üç hastane ise üst düzey “Aşama 7” dijital hastane sertifikası almıştır. Bu sayılar ile Türkiye dijitalleşme sürecinde Avrupa ve bölge liderliğini sürdürmektedir (HIMSS Analitik Nedir?, 2021).

‘Hastanelerimizde Dijital Dönüşüm Projesi’ olarak adlandırılan dijital/kâğıtsız hastane projesini 2012 yılında hayata geçmiştir. Türkiye’deki kamu hastanelerinde bilişim teknolojileri kullanım oranlarını ölçme ve değerlendirme süreçlerinin yürütülmesi konusunda HIMSS Analitik ile anlaşılmıştır. Teknoloji ve bilginin daha iyi kullanımını sağlayarak, hasta güvenliği konsepti ile sağlık bakım kalitesini iyileştirmeyi hedefleyen HIMSS, bu amaçla farklı değerlendirme modelleri ile ölçüm yapmakta ve hastanelere kendilerini ulusal ve uluslararası alandaki benzer kurumlarla karşılaştırma imkânı sunmaktadır. Böylece hastanelerin kişisel bilgi güvenliğini ön planda tutarak, elektronik verilerinin uluslararası geçerli bir standarda göre kayıt, işleme ve değerlendirmesi sağlanmaktadır. HIMSS, Kuzey Amerika, Avrupa, Birleşik Krallık, Orta Doğu ve Asya-Pasifik'te operasyonları ile 60 yılı aşkın bir süredir küresel sağlık topluluğuna hizmet veren ve kar amacı gütmeyen bir kuruluştur (“Who we are | HIMSS”, y.y.). EMR Benimseme Modeli (EMRAM), Avrupa ve dünyadaki diğer sağlık kuruluşlarına karşı ilerlemeyi, bunun karşılaştırmalı izlenmesini sağlayan sekiz aşamalı bir model olarak sunulmuştur. Kuruluş, sağlık hizmetlerinin sunumunda ve geliştirilmesinde bilgi teknolojilerinden optimum faydanın sağlanmasını amaçlamaktadır. Hastanelerin dijitalleşme seviyeleri uluslararası düzeyde EMRAM

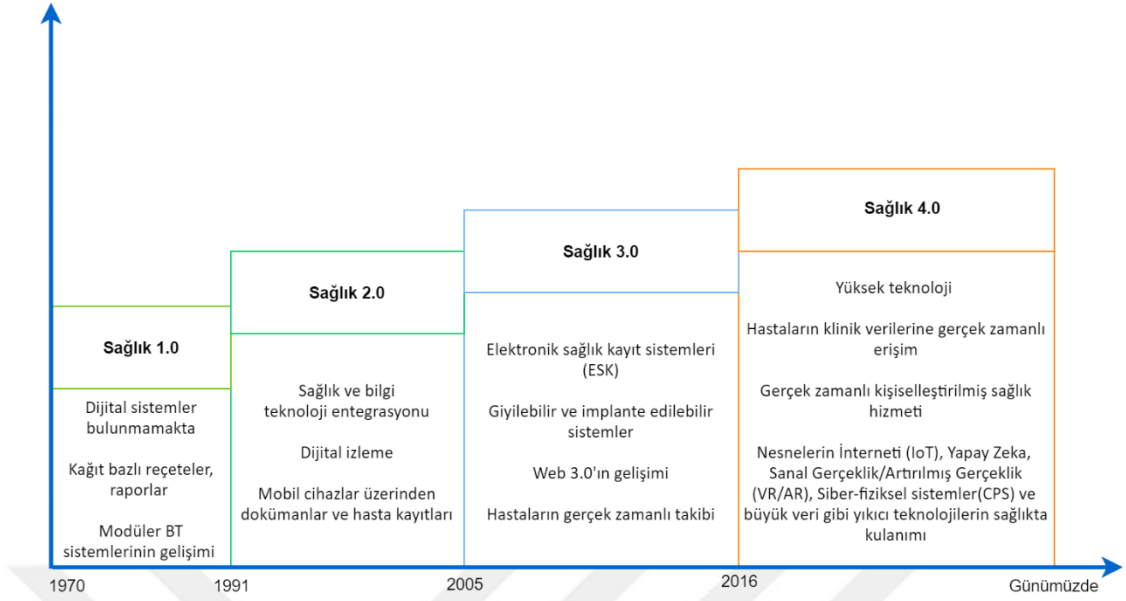
ile derecelendirilmektedir. Bu süreçte sağlık kuruluşlarının işleyişinde bilgi sistemlerinin kullanım düzeyi denetlenmekte ve akredite edilmektedir. HIMSS, dijital süreçleri değerlendirmek ve başvuran hastanelerin süreçlerini belirlemek için evrensel olarak kabul görmüş akreditasyon ve standart model EMRAM'ı kullanmaktadır. Bu modelde hastaneler 1'den 7'ye kadar derecelendirilmekte ve 6. ve 7. aşamalara kadar dijitalleşme sürecini tamamlayanlara sertifika verilmektedir. EMRAM yataklı hizmet veren sağlık kuruluşlarında kullanılan bir süreçtir. Bu model, hastanelerin elektronik tıbbi kayıt yeteneklerini en temel hizmetlerden kağıtsız tıbbi kayıt ortamına kadar genişleyen bir aralıkta ele almaktadır. HIMSS EMRAM seviyelendirmesi sayesinde hastanelerin sürekli gelişen sağlık bilişimi teknolojilerine, uluslararası standartlarda uyum sağlamasını kolaylaşmaktadır. Bunların yanında ayaktan tedavi hizmeti sunan kuruluşlar için elektronik sağlık kaydı modeli O-EMRAM, kurumların teknolojik ve analiz yeteneklerini ölçümleyen model AMAM, dijital görüntüleme adaptasyon modeli DIAM, sağlık yöneticilerinin kurumlarının altyapı hedefini ve teknolojik altyapı yeteneklerinin uluslararası standartlar ile ölçümlenmesini sağlayan INFRAM ve hasta bakımı süresince kullanılan bakım ürünlerinin izlenmesini sağlayan dijital bir altyapı CISOM gibi farklı dijital ölçümleme süreçleri de yer almaktadır HIMSS Avrupa, dünya üzerindeki hastanelerde süreçleri iyileştirmek ve hastaların daha iyi hizmet almasını sağlamak için geliştirdiği yöntem ve akış modellerini, HIMSS Analitik adı altında uluslararası bir standardizasyon mekanizması şeklinde sunmaktadır (“HIMSS Analitik”, y.y.).

Sağlık hizmetlerinin iyileştirilmesinde teşhis, hasta bakımı, önleme ve sağlıklı yaşam, triyaj ve teşhis, kronik bakım yönetimi ve klinik karar destek sistemlerinde (Şekil 20.) dijitalleşme ne kadar fazla gerçekleştirilebilirse, hekimlerin verimliliği ve etkinliği de o denli artış gösterecektir (Holley ve Becker, 2021:119). Sağlık hizmetlerinin dijitalize edilmesi ile operasyonel süreçlerin de verimliliğinde artış yaşanmaktadır. Yapılan bir çalışmada süreçlerin dijitalleştirilmesi sayesinde hastanın hastanede kalış süresinin %34-44 oranında azaltılabileceği vurgulanmıştır (Mazor vd., 2016).



Şekil 20. Sağlık hizmetlerinde dijitalleşmenin odak alanları

Akıllı üretim çağını başlatan Dördüncü Sanayi devrimini yaşadığımız bu dönem, Endüstri 4.0 olarak adlandırılmaktadır. Endüstri 4.0, son yıllarda ekonomik ve sosyal kalkınma için benzersiz fırsatlar sunan, endüstriyel değer zincirinin dijitalleşmesidir (Eynard ve Cherfi, 2020). Endüstri 4.0, nesnelerin interneti, yapay zeka, 3D yazıcılar ve büyük veri dahil olmak üzere ortaya çıkan ve birçok teknolojinin dijital çözümler sağlamak için birleştiği, yeni bir endüstriyel aşama olarak kabul edilmiştir (Frank vd., 2019). Neredeyse tüm sektörleri etkisi altına alan Endüstri 4.0 sağlık alanında da Sağlık 4.0 olarak dönüşümünü gerçekleştirmektedir. Sağlık sektörünün yıllar içindeki dönüşümü Şekil 21’de gösterilmiştir (Bongomin vd., 2020).



Şekil 21. Sağlık sisteminin evrimi

Sağlık sektörü, giderek artan sağlık hizmetleri, sağlık personelleri ve ekipman maliyetlerindeki artış, vasıflı sağlık profesyonellerindeki eksiklikler, yüksek kaliteli sağlık hizmetlerine yönelik artan talep, sağlık hizmeti değer zincirinin boyutu ve karmaşıklığı ve sağlık hizmeti sağlayıcıları arasındaki yoğun rekabet zorlukları ile mücadele edebilmek amacıyla bilgi teknolojilerine dayalı yeni sağlık modellerinin gelişimine ve kullanımına yönelmektedir. Dijitalleşme sayesinde sağlık hizmetlerinin daha geniş popülasyonlar için erişilebilir hale gelmesi hedeflenmektedir. Bu yaygın erişim ise dijitalleşmenin (sayısallaştırmanın) ve ardından gelecek olan yapay zekanın gücüne dayanmaktadır. Yapay zeka özellikli tıbbi cihazlar ve blok zinciri elektronik sağlık kayıtları, sağlık hizmetlerinde sağlık personelleri ile etkileşim kurma şeklimizi, verilerimizin sağlayıcılar arasında nasıl paylaşıldığını, tedavi planlarımızı ve sağlık sonuçlarımız hakkında kararların nasıl alındığını yeniden şekillendiren dijital dönüşümün örneklerinden bazılarıdır. Buradaki sürecin adı dönüşüm ve yeniliktir ve ana hedefi hekimlerin çalışmalarını düzenlemek, sistemleri optimize etmek, hasta sonuçlarını iyileştirmek, insan hatalarını azaltmak ve web ve mobil uygulamalar aracılığıyla maliyetleri düşürmektir (Bongomin vd., 2020).

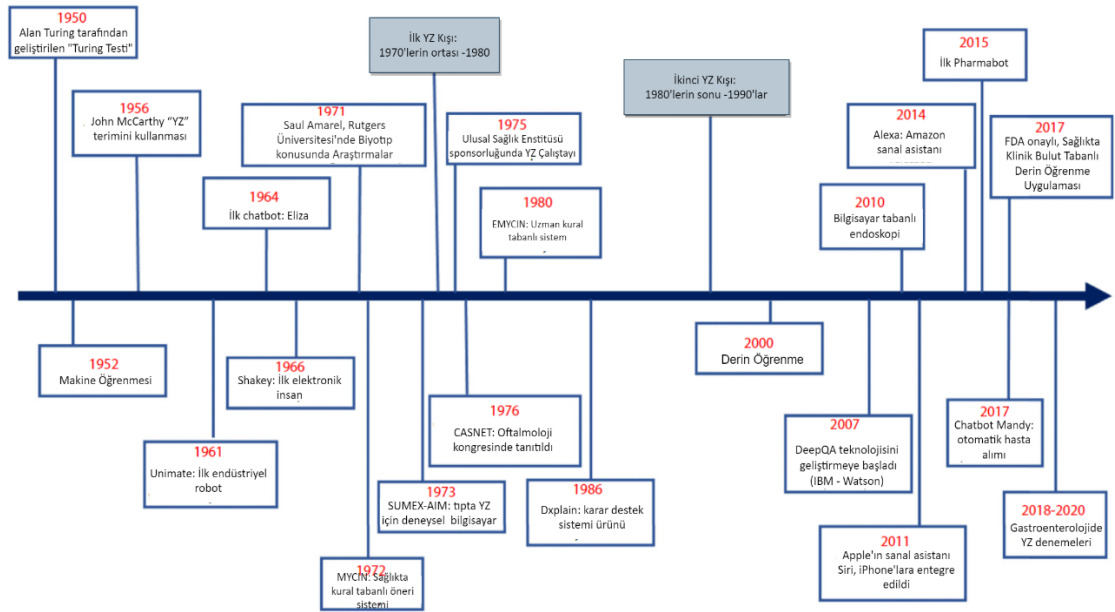
Covid-19 pandemisi ile sağlıkta dijitalleşmenin önemi daha çok anlaşılmış ve salgınla mücadelede dijital teknolojilerden yararlanılmıştır. Hayat kurtarıcı bir strateji olarak,

bazı sađlık tesisleri, hastaların yařamlarını sŸrdŸrmek iin 3D baskılı hasta solunum ventilatŸrlerini ve solunum ekipmanlarını kullanmıřtır (Frank vd., 2019). DŸnya Sađlık ŐrgŸtŸ, Covid-19 ile ilgili yanlış ve kirli bilgilerin yayılmasını Őnlemek amacıyla Facebook Messenger'da Sprinklr ile iř birliđi iinde 4.2 milyar kiřiye ulařma potansiyeline sahip olan bir sohbet robotu kurgulamıřtır (WHO, 2020b). Aynı zamanda yařanan bu pandemi, dijital sađlık teknolojisi ŸzŸmlerine yŸnelik benzeri gŸrŸlmemiř bir talebin tetiklenmesine neden olmuř ve nŸfus taraması, enfeksiyonun izlenmesi, kaynakların kullanımına ve tahsisine Őncelik verilmesi gibi bařarılı ŸzŸmler bu dŸnem iinde sunulmuřtur (WHO, 2020a). Pandemi, deđiřen tŸketiciler, hızlı geliřen teknolojiler, yeni yetenek modelleri ve klinik inovasyon dahil olmak Ÿzere eřitli trendleri hızlandırıcı bir etki yaratmıřtır. Bu eđilimler karřısında, hastaneler ve sađlık sistemleri iřlerini uyarlamaya alıřırken, dijital teknolojilere yŸnelik yaklařımlar bu dŸnŸřm stratejisinin merkezinde yer alacađı dŸřŸnŸlmektedir.

### **3.5. Sađlık Hizmetlerinde Yapay Zeka Uygulamaları**

EndŸstri 4.0'ın geliřini ve geliřimini destekleyen yapay zeka, sađlık hizmetleri ve tıbbi teřhis alanındaki ilerleme ve yenilikler iin Őnem arz etmektedir. Sađlık hizmetlerinin dijitalleřtirilmesi, eřitli BT uygulamaları ve sistemleri tarafından gerekleřtirilmektedir. Őrneđin, Elektronik Sađlık Kayıt (ESK) sistemleri, bir hastanın aldıđı sađlık hizmetinin sayısallařtırılmıř kayıtlarını depolamaktadır. Hastanın sađlık hizmeti alması sonucu oluřan ıktıların dijitalleřtirilmif kayıtları bir zamanlar son teknoloji olarak gŸrŸlmekteydi. Ancak gŸnŸmŸzde ESK sistemlerinde harcanan zaman, hekimlerin hastalarıyla geirdikleri sŸreyi azaltmakta ve hasta iliřkilerini olumsuz yŸnde etkilemektedir. Verilerin saklanması klinik bir ara deđildir ve bu yeterli sađlık hizmeti verebilme yeteneđine sahip deđildir. Stanford Medicine adına yŸrŸtŸlen anket alıřmasında, ESK 'ları iin hastalık teřhisi, hastalık Őnleme ve nŸfus sađlıđı yŸnetimini kapsayan yapay zeka kullanım vakaları sunulmuř ve alıřmada 10 doktordan 9'unun ESK 'ların sezgisel ve duyarlı olmasını istediđi belirtilmiřtir (Medicine, 2018). Bu ve benzer alıřmalar sađlıkta yapay zekanın benimsenmesi iin mŸkemmelen bir fırsat oluřmasını sađlamıřtır.

Sağlık hizmetleri alanında, YZ teknolojilerinin uygulanması hem hastalara hem de sağlık hizmeti sağlayıcılarına fayda sağlayan hastalıkların tahmininde, teşhisinde ve tedavisinde fayda sağlamaktadır (Y. Guo vd., 2020). Yapay zeka terimi hayatımıza 1950'li yıllara girmiş olsa da sağlık alanında yapay zeka gelişimi 1970'li yıllara dayanmaktadır (Şekil 22.). Geliştirilen ilk uygulamalar arasında yer alan CASNET, glokom göz hastalığının tanısı için kullanıma sunulmuştur. Hastalığın sebepleri ve sonuçları şeklinde tanımlanmış olan sistem, uzman hekime hasta yönetimi konusunda tavsiyelerde bulunmaya yönelik geliştirilmiştir. Hekimler tarafından girilen hasta bilgileri ve yaklaşık 600 kuraldan oluşan bir bilgi tabanına dayanan MYCIN, bakteriyel patojenlerin listesini sağlayarak enfeksiyonlara neden olan bakterileri belirlemek ve antibiyotik önermek için geliştirilmiş bir sistemdir. 1990'ların sonunda, özellikle tıp dünyasında makine öğrenmesine artan ilgi sağlıkta yapay zeka çağına zemin hazırlamıştır (Kaul vd., 2020). 2007'de DeepQA, IBM Watson'ın arkasındaki temel teknoloji olarak tanıtılmıştır. DeepQA olası cevaplar üretmek için yapılandırılmamış içerik üzerindeki verilerin analizinde doğal dil işlemeyi kullanmıştır.




Şekil 22. Tıpta yapay zekanın gelişimi ve kullanımının zaman çizelgesi.

Sağlık hizmetlerinde ABD Gıda ve İlaç Dairesi onaylı ilk klinik bulut tabanlı derin öğrenme uygulaması Arterys 2017 yılında geliştirilmiştir. Bu tıbbi görüntüleme platformunun, doktorların kalp problemlerini teşhis etmesine yardımcı olmak için kullanıma sunulmuştur. Yapay sinir ağı ile geliştirilmiş olan ve şimdiye kadar 1.000 vakadan öğrenmiş olan sistem kendi kendine öğrenmeye devam etmekte ve incelediği her yeni vakada kalbin nasıl çalıştığına dair bilgisini geliştirmektedir (Arterys, 2020).

Bugün sağlıkta yapay zeka uygulamaları, sağlık bakımı, klinik araştırma, ilaç geliştirme ve sigortaya kadar sağlık sektörünün harcamalarını azaltmak ve hasta sonuçlarını iyileştirmek gibi devrimler yaratmayı amaçlamaktadır. Sağlık sektörü, yeni teknolojilere en fazla yatırım yapılan kamu politikası sektörlerinden biri olarak tıbbi verilerin madenciliği, tekrarlayan işler ve tedavi planları tasarlama gibi dönüştürücü işler yapma potansiyelinin en yüksek olduğu alanlardan biri olarak karşımıza çıkmaktadır (T. Q. Sun ve Medaglia, 2019b). Yapay zeka ile sağlık sektöründe üretilen her türlü verinin çeşitli boyutlarda sınıflandırılabilmesi ve bu verilerden sonuç çıkarılabilmesi sağlanabilmektedir. Birden fazla tıbbi uzmanlık alanında yapılan araştırmalarda, doktorların teşhis ve karar verme yeteneklerini taklit etmek için yapay zeka teknolojileri kullanılmıştır (Gulshan vd., 2016); (Cheng vd., 2016); (Kermany vd., 2018). Yaşanan bu değişimler otomatik operasyonlara, hassas cerrahiye ve önleyici müdahaleye (öngörüye dayalı teşhis sayesinde) kademeli olarak yansiyacak, ancak on yıl içinde bilinen sağlık hizmeti ortamının temelden yeniden şekillendireceği öngörülmektedir. Forbes dergisinde yayımlanan yazıda Accenture, sağlıkta yapay zeka uygulamalarının 2026 yılına kadar yıllık 150 milyar dolarlık tasarruf (Şekil 23) sağlayabileceği ifade edilmiştir (Forbes Insights, 2019).





Şekil 23. Sağlıkta yapay zekanın 2026 yılına kadar tahmini maliyet faydası

Yapay zeka uygulamaları genelinde değerlendirildiğinde en fazla faydanın robotik cerrahi de yaşanacağı öngörülmektedir. Aynı zamanda yapay zeka sayesinde karşılanamayan sağlık hizmetlerinin %20'sinin de karşılanabileceği bu istatistik ile vurgulanmıştır. YZ yatırımlarının klinik bakımdan ziyade sağlık sistemlerinin operasyonel ve yönetsel alanda daha fazla hissedileceği belirtilmiştir (Forbes Insights, 2019).

Sağlık sektöründe yapay zeka; maliyetlerin azaltılması, verimliliğin artırılması, zamanında ve doğru şekilde tanılama imkanı ile zamandan ve ekonomiden tasarruf sağlanması, bilgi eksikliğinden kaynaklanan personel hatalarının azaltılması ya da tamamen ortadan kaldırılması gibi nedenlerden dolayı kullanımının gerekliliği vurgulanmıştır (Dejan ve Markovic, 2016). Yapay zeka ile desteklenen sağlık hizmetleri, sağlık hizmetleri kalitesini artırarak, sadece hizmet alanlara değil aynı zamanda hizmet sağlayıcılar ve paydaşlar için etkili bir maliyet-gelir yapısının oluşturulmasını sağlayabilecek güçte olduğu ifade edilmiştir (Garbuio ve Lin, 2019).

YZ, hekimlere ya da sađlık personellerine semptomları daha hızlı teŖhis etmede etkili bir Ŗekilde yardımcı olabilmektedir. Aynı zamanda YZ hastaların karmaŖık semptomları takip etmesine, hastaların yaŖam kalitesini iyileŖtirmesine ve ilaca uyumu artırmasına yardımcı olabilmektedir (Kreps ve Counseling, 2013). Randomize bir klinik deney alıŖmasında, bir YZ platformunun antikoagölasyon tedavisi alan inme hastalarında ilaca uyumu %50 oranında artırdığı kanıtlanmıŖtır (Y. Guo vd., 2020). Sonuçları ge ıkan laboratuvar testlerini daha erken sürede öngörebilmek amacıyla yapılan alıŖmada, önceki test sonuçlarından makine öğrenmesi ile laboratuvar sonuçlarının dođru bir Ŗekilde tahmin edilmesi amaçlanmıŖtır. Toplam 107.646 benzersiz hasta verisi kullanılan alıŖmada Rastgele Orman Algoritması kullanılarak Kreatin Kinaz testi sonucunun AST ve ALT test deđerleri kullanılarak %97 dođrulukla belirlenebilmiŖtir. Bu durum testi deđerlendirme süresinde ve tanıyı koyma süresinde önemli bir azalma sađladığı için, hekimler ve hastalar için önemli bir başarı olarak deđerlendirilmiŖtir (Canbolat vd., 2020).

BirleŖik Krallık'ta pilot olarak kullanılan YZ tabanlı bir sohbet robotu olan Babylon uygulaması (Pelcyger, 2017), yüz yüze muayene için sevk edilmesi gereken hastaları diđer hastalardan ayırt etmek için kullanılan bir triyaj aracı olarak geliŖtirilmiŖtir. YZ tabanlı triyaj, teorik olarak sađlık sistemi üzerindeki yükü azaltacak ve kaynakları gerek tıbbi ihtiyacı olması muhtemel hastalara yönlendirmesi hedeflenmektedir. 2017 yılında Proteus Digital Health, ABD Gıda ve İla İdaresi'nin (FDA) dünyanın ilk diđital ilacı olan Abilify MyCite'ı onaylamıŖtır. Abilify MyCite, hastanın hapı yuttuđunu kaydeden bir sensör içermekte ve hasta, midesindeki mide suları tarafından aktive edilen sensörlü ila ile takip edilmektedir. Bu sayede hastanın ilacı aldıđı tarih ve saati tanımlayan sinyaller kaydedilmektedir. Abilify MyCite, Ŗizofreni ve diđer bazı akıl hastalıklarının tedavisinde kullanılan Abilify ilacına özeldir. Bu tür bir teknoloji ok önemlidir, ünkü ilaca uymayan Ŗizofreni hastalarının daha fazla psikotik atak geirdiđi ve daha fazla hastaneye yatıŖ ve yođun bakım gerektirebileceđi ve kendilerine ve baŖkalarına zarar verme potansiyeli olduđu bilinmektedir (Holley ve Becker, 2021:116). California Üniversitesi, algoritmik güdümlü sistem reeteleri geliŖtirmiŖtir. Semptomları, teŖhisi ve ilaları hatasız bir Ŗekilde bir araya getiren sistem yaptıđı hata oranı bakımından insanlardan daha başarılı bulunmuŖtur (Steiner,

2012). IBM, 2014'ten itibaren yapay zeka teknolojileri sunan Watson'ın üreticisi firması olarak bilinmektedir (Ilić ve Marković, 2015:412-415). Watson, iş karar verme sürecini iyileştirmek için ideal bir platformu temsil ederken, aynı zamanda sağlık sektöründeki sorunları ele almaktadır. IBM Watson, belirli orta ölçekli hastaneler tarafından üretilen tüm tıbbi kayıtları, Amerika Birleşik Devletleri'nde 6 saniyeden daha kısa bir sürede okumak ve gerçek zamanlı tahminleme yapmak üzerine yapay zeka algoritmaları ile çalışmaktadır. Algoritma tabanlı akıllı telefon uygulaması "Skinvision" (<https://www.skinvision.com>), cilt kanserini düzenli olarak kişinin kendi kendine kontrol etmesi için rehberlik edebilen mobil tabanlı bir uygulamadır. Algoritma, bir doktorun yaptığı gibi lezyonların dokusunu, rengini ve şeklini belirleyebilir. Kullanıcılar 30 saniye içinde cilt lezyonları için anında risk değerlendirmesi alır ve algoritmanın cilt kanserinin %95'ini erken aşamada tespit ettiği kanıtlanmıştır (Freeman vd., 2020).

Sağlık hizmetlerinde yapay zekanın kullanım amaçları özetlenecek olunursa:

- Diyabet gibi bir hastalık riski taşıyan kişileri belirlemek, hastalığın gelişmesini önlemek ve müdahale etmek için nüfus sağlık modellerini analiz etmek (Dankwa-Mullan vd., 2019),
- Tedavi planlarını optimize etmek ve hastalar için gelecek en iyi eylemleri önermek,
- Kişiselleştirmeyi gerçekleştirmek, sağlık hizmetini ve tele tıbbı daha etkili hale getirmek,
- Yapay zeka karar destek sistemleriyle klinik karar vermeyi artırmak (Kent, 2020),
- Hekimlerin uzmanlığını daha önce yetersiz hizmet verilen alanlara veya topluluklara sunarak sağlık hizmetlerini demokratikleştirmek (Deloitte Life Sciences & Healthcare Group, 2015),
- Giyilebilir cihazlar ve diğer dijital teknolojileri kullanarak doktor ziyaretleri yerine evde yapılan testlere odaklanan teknolojileri geliştirilmek,
- Göz hastalığı veya kanser gibi hastalıkların daha doğru ve verimli bir şekilde tanımlanmasını sağlamak için dijital görüntüleri analiz etmek,

- Hastalar, tüketiciler, sağlayıcılar ve sigortacılar için sağlık hizmetlerini gerçek zamanlı sağlık hizmetlerine dönüştürmek,
- Verimliliği artıran yeni ilaçların geliştirilmesinde yeterlilik sağlamak (Holley ve Becker, 2021:147)

Sağlıkta yapay zeka uygulamaları için belki de en güçlü rol, sağlık personellerinin bir eklentisi veya güçlendiricisi konumunda olacaktır. Çalışmalar, hekimler ve yapay zeka birlikte çalıştığında, tek başına olduğundan daha iyi sonuçlar ürettiğinde sinerjik bir etki gösterdiğini ortaya koymuştur (Wang vd., 2017); (Paras Lakhani ve Sundaram, 2017). Yapay zeka tabanlı teknolojiler ayrıca gerçek zamanlı klinik karar desteğini artırabilmekte ve hassas tıbbı yönelik çabaların sonuçsuz kalmamasını sağlayabilmektedir (Sitapati vd., 2017).

## IV. BÖLÜM

# YOĞUN BAKIM ÜNİTELERİNDE SEPSİS ENFEKSİYONU VE YAPAY ZEKA ALGORİTMALARI İLE MODELLENMESİ

### 4.1. Sepsis Enfeksiyonu ve Önemi

Yoğun bakım ünitelerinde ölümlerin en önemli nedenlerinden biri olan sepsis enfeksiyonu, ciddi bir küresel sağlık krizi olarak görülmektedir. Sepsis, her yıl 47 ila 50 milyon insanı etkilemekte, yaklaşık 11 milyon insanın da ölümüne neden olmaktadır. En son açıklanan rakamlara göre dünyada 2,8 saniyede bir sepsis nedeniyle bir insan hayatını kaybetmektedir (“Sepsis - A Global Health Crisis”, 2020). Sepsis, Dünya Sağlık Örgütü ve araştırmacılar tarafından sürekli araştırılan, hem toplum bilinci oluşturabilmek hem de erken tanı koyabilmek amacıyla sürekli üzerinde çalışılan önemli bir sağlık sorunu iken Dünya’da 2019’un sonunda Çin’in Wuhan kentinde ortaya çıkan, koronavirüs 2 (SARS-CoV-2) olarak adlandırılan (Guan vd., 2020) ve pandemiye dönüşen virüs nedeniyle daha da önemli bir sağlık sorunu haline gelmiştir. Bu yaşanan süreçte COVID-19 hastalarının yaklaşık %2 ila %5’inde yaklaşık 8-10 gün sonra sepsis enfeksiyonunun neden olduğu çoklu organ yetmezliği belirtilerinin ortaya çıktığı ifade edilmektedir (Global Sepsis Alliance, 2021). Bu nedenle sepsis enfeksiyonunun erken tespiti ve tedavisi daha da önemli hale gelmiştir.

Sepsis tanımında altın standart olmadığı için klinisyenler, spesifik olmayan fizyolojik ve laboratuvar anomalilerini birleştirerek sepsis tanısı koymaya çalışmışlardır. Bu nedenle 1991, 2001 ve son olarak 2016’da düzenlenen uluslararası konferanslarda farklı sepsis tanımları önerilmiştir. Günümüzde sepsis, vücutta gelişen enfeksiyona verilen düzensiz bir konak tepkisinin, yaşamı tehdit eden organ disfonksiyonu olarak tanımlanmıştır (Rhee vd., 2014)(Seymour vd., 2016). Diğer bir ifade ile vücutta gelişen enfeksiyona neden olan bakterilerin kana karışması ile bağışıklık sisteminin bu bakterilere karşı büyük bir savunma göstermesi; bu nedenle vücutta organ

yetmezliđinin gerekleŒmesidir. Normal Œartlarda vücutun kana karışan bakterilere karşı yanıt niteliđinde bir bađışıklık geliřtirmesi olađan bir durumdur. Fakat bu yanıt, bazı durumlarda olması gerekenden ok daha güçlü olduđunda, organ ve dokulara hasar verebilmektedir (Singer vd., 2016). Sepsis, bulařıcı olabilen bir enfeksiyonun komplikasyonudur, fakat sepsis enfeksiyonu bulařıcı deđildir. Sepsis genellikle bakteriyel enfeksiyonlardan kaynaklansa da COVID-19 veya influenza seyrinde sekonder enfeksiyon olarak görülebilmektedir (“What is sepsis?”, 2021).

COVID-19 özelinde alıřılan verilere göre, hastalıđın ilk ařamasında bir sitokin fırtınasına neden olan ve ardından vücuda önemli ölçüde zarar veren orantısız bir reaksiyon geliřebilmektedir. Buna ilave, iltihaplanma ve pıhtılařma ile ilgili önemli sayıda faktörün üretimine neden olmakta, bu da sepsis sırasında gözlemlenene oldukça benzer bir durum olan pıhtılařma ve bununla iliřkili damar ii pıhtılařma sorunlarının bařlamasına neden olmaktadır. Bu nedenle, oklu organ yetmezliđi ile hayatını kaybeden Covid-19 hastalarının sepsis enfeksiyonundan kaynaklı olduđu düşünölmektedir (López-Collazo vd., 2020). Sepsis enfeksiyonunun erken tanısı yapılamaz ve tedaviye hızlı bir Œekilde bařlanamazsa, septik Œoka ardından oklu organ yetmezliđine ve son olarak ölüme neden olabilmektedir (“World Health Statistics”, 2018). Sepsisin erken fark edilememesi SARS-CoV-2 / COVID-19 gibi viral enfeksiyonlar da dahil olmak üzere dünya apında ođu bulařıcı hastalıkta ölüme yol aan ortak nedendir (“Sepsis - A Global Health Crisis”, 2020).

Sepsis farklı zamanlarda eřitli belirti ve semptomlarla ortaya ıkabilmekte ve bazı semptomları: 38°C üstünde veya 36°C altında vücut sıcaklıđı, zihinsel durum deđiřikliđi, kalp atıř hızının dakikada 90 atıřım üzerinde olması, dakikada 22 nefesten yüksek solunum hızı, zayıf nabız / düşük tansiyon, az idrar ıkıřı, siyanotik veya benekli cilt ve ařırı vücut ađrısı veya rahatsızlıđı Œeklinde olabilmektedir (Halm vd., 1998)

Sepsisin küresel yükünü tespit etmek zordur, ancak 2017'de yapılan alıřmada dünya apında 48,9 milyon vaka ve 11 milyon sepsis ile iliřkili ölüm olduđu, bunun da tüm küresel ölümlerin neredeyse %20'sini oluřturduđu ifade edilmiřtir. Aynı zamanda

sepsis insidansı ve mortalitesinde önemli bölgesel eşitsizliklerin mevcut olduğu; dünya çapında sepsis vakalarının ve sepsise bağlı ölümlerin yaklaşık %85'inin düşük ve orta gelirli ülkelerde meydana geldiği vurgulanmıştır (Rudd vd., 2020). Yapılan son araştırmalarda, sepsisin ABD'deki tüm hastane ölümlerinin üçte birini kapsadığı, sepsis harcamalarının yılda 24 milyar doları bulduğu ve genel sağlık bakım maliyetlerinin önemli bir bölümünü oluşturduğu ifade edilmiştir (Medical Association, 2014; Rhee vd., 2019; Mayr vd., 2014). Bazı insanlarda sepsis enfeksiyonunun gelişme riski daha yüksektir. Bunlar zayıf bağışıklık sistemi olan; çok genç, çok yaşlı ve kronik hastalığı olan kişileri kapsamaktadır. Sepsis, şiddetine bağlı olarak yaklaşık %25-30 arasında değişen ölüm oranları ile kalp hastalığı ve kanserden sonra üçüncü en sık görülen ölüm nedeni olduğu ifade edilmektedir (Vidant Beaufort Hospital, 2017).

#### **4.1.1. Sepsis Enfeksiyonunda Geleneksel Skorlama Sistemleri**

Sepsisin fizyolojik mekanizması ve sepsisi tetikleyen değişkenlerin stokastik davranışı nedeniyle karmaşık bir süreç olduğu belirtilmektedir. Değişkenler arasındaki dinamiklerin doğru bir şekilde anlaşılması, hastalığın gerekçesini yorumlamak için önem arz etmektedir. Sepsis ve septik şok tanısının konulması/kesinleştirilmesi, prognozun belirlenmesi amacıyla klinik bulgu ve laboratuvar inceleme sonuçları ile acil servislerde ve yoğun bakım ünitelerinde kullanılmak üzere skorlama sistemleri geliştirilmiştir. Bu skorlama sistemleri erken dönemde tanıyı netleştirmek ve prognozun öngörülmesinde (SIRS, SOFA, qSOFA, MEWS) kullanılmaktadır. En sık kullanılan SOFA ve qSOFA skorlama kriterlerinden aşağıda bahsedilmiştir:

#### **SOFA**

Vincent JL ve arkadaşları tarafından 1996 yılında tanımlanmış olan Sıralı Organ Yetmezliği Değerlendirme (Sequential Organ Failure Assessment Score: SOFA) Puanı sepsis ilişkili organ disfonksiyonu değerlendirme sistemi olarak geliştirilmiş olup, özellikle Yoğun Bakım Ünitesi (YBÜ) mortalitesini tahminleme amacıyla geliştirilmiştir (J.-L. Vincent ve Moreno, 1996). İlerleyen yıllarda yapılan

arařtırmalarda SOFA skoru yüksek olan hastalarda daha fazla mortalitenin gerekleřtiđi sonucuna ulařılmıřtır (Vincent, vd., 1998).

Tablo 2. SOFA kriterleri

SOFA Skor	0	1	2	3	4
Solunum, PaO <sub>2</sub> /FiO <sub>2</sub> , mmHg	>400	≤400	≤300	≤200	≤100
Böbrek Kreatinin,	<1.2	1.2-1.9	2-3.4	3.5-4.9 idrar ıkıřı, mL/gün≤500	>5.0 idrar ıkıřı, mL/gün<200
Karaciđer Billuribin, mg/dL	<1.2	1.2-1.9	2.0-5.9	6.0-11.9	>12
Trombosit 10 <sup>*3</sup> /µL	>150	≤150	≤100	≤50	≤20
Kardiyovasküler	Hipotansiyon yok	MAP<70 mmHg	Dopamin≤5 veya Dobutamin	Dopamin>5 veya Epinefrin≤0.1 veya Norepinefrin≤0.1	Dopamin>15 veya Epinefrin 0.1 veya Norepinefrin>0.1
Santral Sinir Sistemi (GKS)	15	13- 14	12-10	9-6	<6

SOFA Tablo 2’de gösterildiđi gibi altı organ sisteminin deđerlendirilip 0 ile 4 arasında puan verilmesi ile gerekleřtirilmektedir. Sepsiste organ iřlev bozukluđu, SOFA skoru iin 2 ve üzerinde bir artıř olarak tanımlanmıř ve bu %10'luk bir mortalite riski ile iliřkilendirilmiřtir (McLymont ve Glover, 2016).

### qSOFA

SOFA skorlamasının sofistike ve zaman alıcı olması nedeniyle, sepsiste organ yetmezliđi olan hastaları ayırt etmek iin sadece klinik belirtilere bađlı olan ve bu sayede daha hızlı sonuç alınabilen Hızlı Ardıřık Organ Yetmezliđi Deđerlendirme (quick Sequential Organ Failure Assesment: qSOFA) Skoru önerilmiřtir (Singer vd.,2016). qSOFA, iyi tahmin yeteneđi ile iliřkili az sayıda deđiřkenle, basit bir puanlama sistemi elde etmek iin geliřtirilen bir modeldir. qSOFA'nın temel faydası, řüpheli veya bilinen bir enfeksiyonu olan, kötü sonuç geliřtirme riski yüksek olan ve hedefli



müdahalelerden fayda görebilecek hastaların tanımlanmasıdır. Bu bağlamda, sepsis tanısının spesifik bir parçası olmasa da bir risk öngörücüsü olarak hareket etmektedir (J. L. Vincent vd., 2016).

qSOFA kriter pozitifliği, solunum sayısının dakikada 22 veya üzerinde olması, mental durum değişikliği veya sistolik kan basıncının 100 mmHg veya altında olması kriterlerinin en az iki tanesinin olması durumunda sepsisin varlığının düşünülmesi önerilmektedir (Singer vd., 2016).

Tablo 3. Quick SOFA kriterleri

<b>qSofa (Quick SOFA Kriterleri)</b>	<b>0 Puan</b>	<b>1 Puan</b>
<b>Solunum Sayısı <math>\geq 22/dk</math></b>		
Evet		
Hayır		
<b>Mental Durum Değişikliği (GCS)</b>		
Evet		
Hayır		
<b>Sistolik Kan Basıncı <math>\leq 100</math> mmHg</b>		
Evet		
Hayır		

qSOFA'nın, hesaplanmasında yalnızca üç yaşamsal belirtiyeye bağlı olması nedeniyle (Tablo 3), sepsis tespiti için diğer puanların yerini alacağı düşünülmüştür. Ancak yapılan çalışmalarda, mevcut puanların ciddi şekilde düşük performans gösterdiği vurgulanmaktadır (Churpek ve Edelson, 2016; Askim vd., 2017; Lo vd., 2019). Geliştirilen bu erken uyarı skorlama sistemlerinin düşük performansı nedeniyle, sepsis ve diğer kritik hastalıkların teşhisini erken tahmin etmek için daha doğru klinik tahmin modelleri geliştirmeye yönelik klinik bilişim, makine öğrenmesi ve yapay zeka alanlarına önemli bir yönelme başlamıştır.


## 4.2. Sepsis Enfeksiyonu Tanısında Yapay Zeka Algoritmalarının Kullanımı

Sepsisin derhal teşhis edilmesi ve septik şoka ilerlemeden önce müdahale edilmesi, artan hasta sağ kalım ve hastanede kalış süresinin kısalmasıyla ilişkilendirilmiştir (Nguyen vd., 2007) (Shorr vd., 2007). Elektronik sağlık kayıtlarının (Electronic Health Records: EHR) hastanelerde yaygın olarak uygulanması, otomatik klinik karar verme tahmin sistemlerini daha uygulanabilir hale getirerek, karmaşık sendromların ortaya çıkışını ve tedavisini potansiyel olarak iyileştirmiştir (Kawamoto vd., 2005). Bu tür sistemler, hasta bakımını iyileştirmek için hastanın tıbbi verilerine klinik olarak erişilebilmekte, bilgilere dönüştürebilmekte uyarılar ve öneriler sağlayabilmektedir (Sittig vd., 2008).

Günümüzde artık sepsis enfeksiyonunda mevcut araçların öngörücü doğruluğunun zayıf olması; SIRS kriterlerinin zayıf özgüllüğü (SIRS, SAUROC =0,7 – ML, SAUROC=0.89) (Islam vd., 2019; Kaukonen vd., 2015), qSOFA'nın düşük duyarlılığı (Dorsett vd., 2017) ve SOFA skorlamasının zaman alıcı ve karmaşık olmasının yanı sıra zaman alıcı laboratuvar test sonuçlarına olan gereksinim nedeniyle (Desautels vd., 2016), sepsis teşhisinde farklı modellerin geliştirilmesi ihtiyacı doğmuştur. Ayrıca yapılan bazı çalışmalarda, bu puanlama sistemlerinin versiyonları EHR'lere uygulanmıştır. Bu araçlar yüksek hassasiyet gösterebilse de optimalin altında özgüllük sağlamış ve sepsis gelişimini tahmin etmek için tasarlanmadığı vurgulanmıştır (Sittig vd., 2008). Ayrıca, farklı hasta popülasyonları ve enfeksiyon kaynağının heterojenliği, kurallara dayalı skorlarda doğru temsil edilemediği belirlenmiştir (Berger, vd., 2010). Ancak bunların aksine makine öğrenmesine dayalı tahmin araçları; sepsis riskinin önceden bildirilmesi, daha yüksek başarı potansiyeline sahip olması nedeniyle, hekimlerin daha erken müdahale etmesini sağlarken aynı zamanda yanlış alarmların yükünü de azaltabileceği vurgulanmıştır (Barton vd., 2019).

Son yıllarda birçok araştırmacı ve hekim, sepsisin erken tespitine yardımcı olan araçlar oluşturmak için verilerden yararlanmaya ve bunları entegre etmeye çalışmaktadır. Bu

araçların ve tahmine dayalı çözümlerin çoğu, sepsis başlangıcını veya ölüm oranını tahmin etmeye yardımcı olmak için yapay zeka ve makine öğrenmesi tekniklerini kullanmaktadır. Yapay zekanın bir alt disiplini olan makine öğrenmesi, otomatik öğrenme, algılama veya sınıflandırmaya yardımcı olmak için kullanılmakta ve tıbbi verilerin işlenmesi ve anlamlandırılmasında potansiyel bir fayda sağlamaktadır. Veriye dayalı erken uyarı skorlarının geliştirilmesine yönelik yapay zeka ve makine öğrenmesi çalışmaları, sepsis enfeksiyonu teşhisinde ve modellenmesinde kullanılmaya 1990 yılında başlamıştır. Web of Science (WOS) veri tabanında "sepsis", "machine learning" ve "artificial intelligence" anahtar kelimeleri konu içeriğinde aratıldığında toplamda 333 sonuç elde edilmiştir. "Machine learning" ve "sepsis" anahtar kelimeleri ile yapılan aramada ilk çalışmanın 2009 yılında yapıldığı, "artificial intelligence" ve "sepsis" anahtar kelimeleri ile yapılan aramada ise ilk çalışmanın 1990 yılında yapıldığı sonucuna ulaşılmıştır (Şekil 24). Verilerin depolanma kapasitelerinin ve işleme hızlarının artmasıyla birlikte, yapay zekaya dayalı sepsis özelindeki çalışmalar, 2016 ve takip eden yıllarda artış gösterdiği anlaşılmaktadır.



Şekil 24: "Yapay zeka" ve "sepsis" çalışmalarının WOS veri tabanında tarandığı yıllar

Yapılan bir çalışmada rastgele orman yöntemlerini kullanan bir makine öğrenmesi yaklaşımının, sepsisli hastaların hastane içi mortalitesini tahmin etmek için klinik karar kurallarından ve geleneksel analitik tekniklerden daha iyi performans (AUC=0.86) gösterdiği sonucuna ulaşılmıştır (Taylor vd., 2016). Hazır tıbbi verilerden yeni doğan sepsis tahmininde öngörücü modeller geliştirmek için destek vektör makinesi, Naive Bayes, K -en yakın komşular, karar ağacı, rastgele orman, lojistik regresyon, CART gibi makine öğrenmesi algoritmaları kullanılmıştır. Çalışmada, makine öğrenmesi algoritmaları kullanılarak geliştirilen öngörücü modellerin hekimlerin duyarlılığı ve özgüllüğünden daha yüksek sonuçlar verdiği ifade edilmiştir (Mani vd., 2014). Septik hastaların sonuçlarını izlemek ve bu hastaların şiddetli sepsis olup olmayacağını tahmin etmek için destek vektör makinelerinin kullanıldığı bir çalışmada, modelin hastalığı doğru bir şekilde sınıflandırdığı sonucuna ulaşılmıştır (S. L. Wang, Wu ve Wang, 2010). Yapılan farklı bir çalışmada ise sepsisli hastaların ölüm riskini tahmin etmek için destek vektör makineleri algoritması kullanılmıştır. Bu çalışmada yapılan analizlerde ayrıca serum laktat düzeylerini de tahmin etmenin mümkün olacağı ifade edilmiştir. Bu durumun, sepsis risk değerlendirmesini kolaylaştırabildiği ve tedavi kılavuzlarına uyumu artırarak ölüm riskini de önemli ölçüde azaltabileceği ifade edilmiştir (Gulpepe vd., 2014). Sepsis enfeksiyonunda önemi yadsınamayacak derecede yüksek olan Laktat düzeyine yönelik yapılan bir çalışmada ise venöz laktat düzeyleri ile mortalite arasındaki ilişki incelenmiştir. Laktatın eşik değerinin 2.5 mmol olduğu çalışmada, laktat düzeyindeki herhangi bir artışın mortaliteyi artırdığı bulunmuştur (Callaway vd., 2009). Sepsis enfeksiyonunda önemli değişkenler olarak bilinen laktat ve ph değerlerinin kullanılarak verinin denetimsiz olarak eğitildiği çalışmada %79 başarı ile sepsis olan ve olmayan hastaların kümelenmesi sağlanmıştır (Canbolat ve Silahtaroglu, 2020).

Antibiyotiklerle erken müdahale, septik hastalarda sağ kalımı iyileştirebildiğinden araştırmacılar, hekim şüphesinden önce sepsis insidansını belirleyebilmek için yapay zeka algoritmalarından yararlanmışlardır. Erken sepsis tahmini için yapay zeka algoritması geliştirmeyi amaçlayan bir çalışmada 27.527 vaka incelenmiştir. Yapay zeka tabanlı sepsis uzmanı algoritmasının kullanıldığı çalışmada, sepsisin 4 saat önce

saptanmasında AUROC = 0.82 ve duyarlılık ise %85 olarak bulunmuştur (Nemati vd., 2018). Derin sinir ağı modelleri, özellikle Uzun Kısa Süreli Bellek (LSTM) zaman serisi verilerinde zamansal bağımlılıkları yakalama yetenekleri nedeniyle sağlık verilerini analiz etmede büyük başarı göstermiştir. Derin öğrenme ile sepsis tespit modellerinin geliştirildiği çalışmada, derin öğrenme yönteminin performansı regresyon ile karşılaştırılmıştır. Çalışmada, derin öğrenme mimarisi LSTM uygulanmış ve LSTM'in (AUC=0,93) regresyon modellerine kıyasla daha başarılı bir performansa sahip olduğu sonucuna ulaşılmıştır (Kam ve Kim, 2017). Hayati belirtiler, nabız oksimetresi, GCS ve yaşı içeren çok değişkenli bir makine öğrenmesi sınıflandırma algoritması olan InSight'ı kullanan araştırmacılar sepsis oluşmadan dört saat önce hastalığı tahmin etmek için orta düzeyde (AUROC 0.74) bir performansa ulaşmışlardır (Desautels vd., 2016). Yapılan bir diğer çalışmada ise Yapay Zeka Sepsis Uzmanı (AISE) algoritmasının geliştirilmesi ve doğrulanması amaçlanmıştır. AISE, ilerleyen T saatlerinde sepsisin başlangıcını tahmin etmek ve önemli faktörlerin bir listesini çıkarmak için kullanılmıştır. Sepsisin 12, 8, 6 ve 4 saat öncesi tahmini için, AUROC 0,83-0,85 aralığında performans göstermiştir. Ancak önerilen sepsis tahmin modelinin klinik kullanımını belirlemek için ileriye dönük bir çalışmanın gerekliliği de vurgulanmıştır (Nemati vd., 2018). Sepsisin erken tahmini için tekrarlayan bir nöral hayatta kalma modeli olan DeepAISE (Derin Yapay Zeka Sepsis Uzmanı) algoritması geliştirilmiştir. DeepAISE, gerçek zamanlı saatlik sepsis risk skorları sağlayan bir klinik iş akışına dahil edilmiş ve test edilen iki ayrı kohortta en doğru tahminleri (AUC = 0,90 ve 0,87) ve en düşük yanlış alarm oranlarını (FAR = 0,20 ve 0,26) üretmiştir (Shashikumar vd., 2019). Bebeklerde gelişen sepsisi öngörmek için önerilen istatistiksel bir tahmin modeli, daha erken tanımayı destekleyerek, düşük doğum ağırlığına sahip bebeklerde (<1500 gram) sepsise bağlı mortaliteyi azaltmayı başarmıştır (Fairchild vd., 2017).

Londra'daki Imperial College'de Sepsis ve Kanser Araştırmacıları için gerçekleştirilen yapay zeka araçları, YBE'lerinde sepsisli yetişkin hastalar için doktorların optimal sıvı ve vazopresör dozlarını seçmelerine yardımcı olmak için YZ ajanı geliştirme üzerine çalışmalarını sürdürmektedir. YZ Klinisyeni olarak adlandırılan klinik karar destek aracı, 5 YBÜ'den ve 17.000'den fazla sepsis yatışından

elde edilen bir veri seti üzerinde geliştirilmiştir. Demografik özellikler, yaşamsal belirtiler, laboratuvar testleri gibi hasta özelliklerine ve ayrıca uygulanan sıvı ve vazopresör dozlarına ve ilişkili hasta sonuçlarına göre kişiselleştirilmiş tedavi stratejilerini belirlemek için pekiştirmeli öğrenme kullanılmıştır. 79.000'den fazla veriden oluşan bağımsız bir veri kümesinde doğruluğu test edilen YZ Klinisyenin tavsiyelerine benzer dozlar alan hastalarda diğerlerinden farklı olarak daha düşük mortalite görülmüştür. Raporda, YZ Klinisyenin her seferinde kişiselleştirilmiş tedavi önerileri sunabileceği ve bunun, hastaların sonuçlarını iyileştirmesine yardımcı olabileceği vurgulanmıştır (Abbasi, 2018). Yapılan diğer çalışmalarda ise mortalite açısından sepsis ilişkili en riskli bireyleri belirlemek için makine öğrenmesi (Gulpepe vd., 2014; Taylor vd., 2016; Mayhew vd., 2018) algoritmalarından yararlanılmıştır.

Literatürde genel olarak araştırmacılar erken sepsis tespiti için farklı makine öğrenmesi algoritmaları önermişlerdir. Ancak bu tür yöntemleri doğrudan karşılaştırmak; farklı hasta kohortları, klinik değişkenler, sepsis kriterleri, değerlendirme ölçütleri ve diğer farklılıklar nedeniyle mümkün olmamıştır. Görüldüğü gibi sepsis teşhis ve tedavisinde hem geleneksel hem de yenilikçi tedavileri değerlendirmek için klinik araştırmalar devam etmektedir. Yine de sorunun nihai bir çözümü bulunamamıştır.

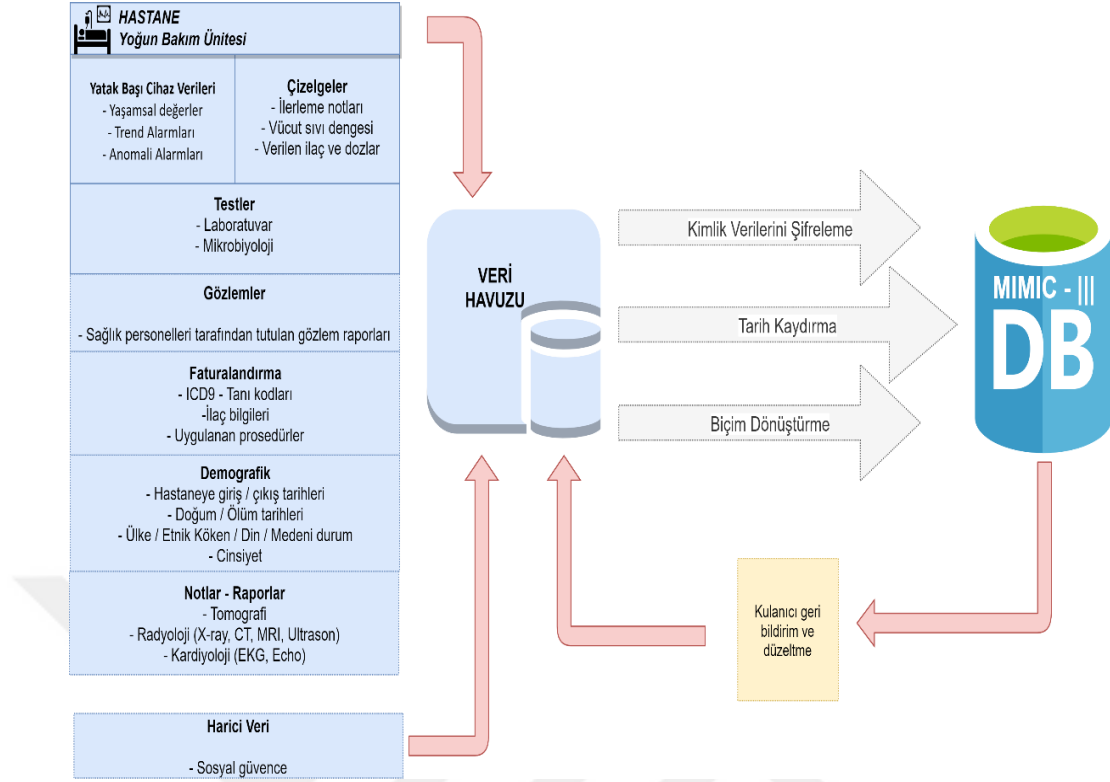
### **4.3. Tezin Genel Kapsamı**

Akademik çalışmaların temelini, araştırma yöntemleri oluşturmaktadır. Her yöntemin kendi felsefi dünya görüşü bulunmaktadır. Felsefi dünya görüşü metodoloji ve eylemlere rehberlik eden bir dizi temel inanç olarak bilinmektedir (Kingma ve Ba, 2015). Creswell, makalesinde her biri kendine has özelliklere sahip Postpozitivist, Yapılandırıcı, Dönüştürücü ve Pragmatik olmak üzere dört dünya görüşünden bahsetmiştir. Pragmatik, gözlem ve deneyim yoluyla doğal yasaların veya gerçeklerdeki sabit ilişkilerin keşfi sürecidir. Bu kapsamda yapılmış olan bu tez çalışması pragmatik görüşü baz alarak kontrollü koşullar altında deney yapmak, anlamak ve modeli inşa etmekle ilgilidir. Araştırma yaklaşımı ise hem nitel hem de nicel yöntemleri birleştiren karma bir yaklaşıma sahiptir.

Tez çalışması, Medipol Mega Hastanesindeki Yoğun Bakım ve Enfeksiyon hastalıkları hekimleri ve Pusula HBYS Yazılım şirketi ile ortak gerçekleştirilen Tübitak 1501 Programı, «*Erken Teşhis ve Tanılamaya Yönelik Öngörücü-Önerici Klinik Platform Projesi*» kapsamında ilerlemiştir. Bu platformun gelişimi öncesinde Medipol Üniversitesi Yoğun Bakım hekimleri ile görüşülmüş ve görüşme sonunda hekimlerin erken tanıda zorlandıkları sepsis enfeksiyonu kapsamında çalışmanın ilerletilmesi kararlaştırılmıştır. Sepsis, vücudun bir enfeksiyona tepki olarak kendi doku ve organlarına zarar vermeye başlamasıyla ortaya çıkan kritik bir hastalıktır. Bu durum, uzun süreli ve daha fazla sayıda hastaneye yatış, yüksek tıbbi maliyetler ve artan ölüm riski gibi çeşitli olumsuz faktörlerle karakterize edilmektedir. Sepsis, diğer durumlarla karşılaştırıldığında hastanede kalış süresini %75 oranında artırmakta ve Septik Şok, hastalarda ölüm riskini %50 oranında dramatik bir şekilde yükseltmektedir (Hall vd., 2011). Tüm bu nedenler doğrultusunda proje sürecinde sepsis özelinde hangi verilerin nasıl toplanacağı, verilerin ne tür veri ön işlemlerinden geçirilerek klinik veri ambarının hazırlanacağı, verilerin hangi yapay zeka algoritmaları ile analiz edileceği ve son olarak geliştirilen modellerin performansının değerlendirilmesi ile sistemin canlıya alınmasını kapsayan adımları içermektedir.

#### **4.3.1. Tez Kapsamında Kullanılan Veri Seti**

Tez araştırması genelinde kullanılan Yoğun Bakım Tıbbi Bilgi Merkezi (Medical Information Mart for Intensive Care: MIMIC) 2001 ve 2012 yılları arasında Beth Israel Deaconess Tıp Merkezi'nin yoğun bakım ünitelerinde kalan 40.000'den fazla gerçek hastaya ilişkin, kimlik bilgilerini ve şifrelenmiş verilerini içeren geniş bir veri tabanıdır (A. E. W. Johnson vd., 2016). Araştırmada veri tabanının güncel sürümü olan MIMIC-III v1.4 versiyonu kullanılmış, analizler bu veriler ile gerçekleştirilmiştir (Johnson vd., 2016). MIMIC-III, Boston, Massachusetts'teki Beth Israel Deaconess Tıp Merkezine kabul edilen hastaların tanımlanmamış, kapsamlı klinik verilerini birleştirmiş ve bir veri kullanım anlaşması kapsamında araştırmacıların kullanımına açmış ve erişilebilir hale getirmiştir.



Şekil 25. MIMIC-III yoğun bakım veri tabanının genel çerçevesi

Veriler (Şekil 25) yatak başında alınan zaman damgalı cihaz verilerini, ilaçları, laboratuvar ölçümlerini, sağlık personelleri tarafından alınan gözlemleri ve notları, prosedür kodlarını, tanı kodlarını, görüntüleme raporlarını, hastanede kalış süresini, hayatta kalma verilerini, müdahaleleri, reçeteleri ve demografik bilgileri içermektedir (A. E. W. Johnson vd., 2016).

#### 4.3.2. Veri Ambarının Hazırlanması ve Modelde Kullanılan Değişkenler

Araştırmada kullanılan MIMIC-III (versiyon 1.4), 26 farklı tablodan oluşan rutin klinik bakım sırasında kaydedilen verileri içeren büyük bir sağlık veri tabanıdır. Veri tabanında statik ve dinamik veri olmak üzere iki tür veri bulunmaktadır (Johnson, vd., 2016). Statik veriler, belirli bir tanımlayıcı için bir kez kaydedilen verileri ifade etmektedir. Örneğin hastanın, zamanla değişmeyen ve ilişkili bir zaman damgasıyla kaydedilmeyen doğum tarihi, cinsiyet ya da değişmeyen kimlik numarası/hasta ID statik veri olarak görülmektedir. Dinamik veri ise, bir hastanın hastanede kaldığı süre



boyunca periyodik olarak ölçülen kan basıncı, hemoglobin, tansiyon, laktat, ph, glikoz vb. sağlık verilerini kapsamaktadır (Han vd., 2021). Tez kapsamında yoğun bakım ünitesinde tedavi gören hastaların demografik, laboratuvar ve cihaz verileri kullanılarak sepsis enfeksiyonu özelinde yapay zeka algoritmaları analizleri gerçekleştirileceğinden MIMIC-III veri tabanı kullanılarak sepsis konusu odağında veri ambarı oluşturulmuştur. AzureCloud üzerine kurulan PostgreSQL (v.13) veri tabanına yaklaşık 50GB alanı kaplayan MIMIC-III kurulmuştur. PostgreSQL üzerinde gerekli sorgular yapılarak yoğun bakımda tedavi gören hastalara ait veri ambarı, veri modellemesinin yapılacağı makine üzerinde oluşturulmuştur. Veri tabanında bulunan yirmi altı tablo içinden admissions, patients, labevents, labitems, chartevents, d\_items, d\_labitems, d\_ICD\_diagnose tabloları veri ambarı oluşumunda kullanılmıştır. Denetimli ve denetimsiz öğrenmenin gerçekleşebilmesi için modelde kullanılan değişkenlerin bir kısmı (Resp, Creatinine, GCS, kalp ritmi vb.) sepsisin geleneksel skorlama sistemi olan SOFA, qSOFA da kullanılan değişkenlerdir. Bunların yanı sıra Tübitak projesi kapsamında Medipol Mega Hastanesi yoğun bakım ve enfeksiyon hastalıkları hekimleri ile yapılan görüşmelerde hastanın laktat değeri, solunum, sistolik kan basıncı, Glaskow Coma Skalası (GCS) ve Trombosit değerlerinin sepsis enfeksiyonunun teşhisinde önemli olduğu sonucuna varılmıştır. Aynı zamanda yoğun bakımda tedavi altında olan sepsis hastalarında verilerin nasıl tutulduğu ve hekimler için hangi değerlerin önemli olduğunu anlayabilmek amacıyla Medipol Mega Hastanesi yoğun bakımında üç tam gün boyunca gözlem yapılmıştır. Bunlarla birlikte literatürde sepsis özelinde yapılan çalışmalar da incelenmiş ve değişken çeşitliliği bu çalışmalarla da desteklenmiştir (Marshall ve Creery, 1998; Nemati vd., 2018; Barton vd., 2019; Ozalp, vd., 2019; Han vd., 2021). Şekil 26'da gösterildiği gibi tez kapsamında yapılan analizlerde float ve integer veri tipinde toplam 41 değişken kullanılmıştır.

Hayati Değerler		Değişken Türü	Laboratuvar Değerleri		Değişken Türü
HR	Nabız(dakikada atım sayısı)	float64	BaseExcess	asit baz dengesi	float64
O2Sat	Nabız oksimetresi	float64	HCO3	bikarbonat	float64
Temp	Vücut sıcaklığı	float64	FiO2	oksijen oranı	float64
SBP	Sistolik BP	float64	pH	ph	float64
MAP	Ortalama arter basıncı	float64	PaCO2	Karbondioksit Kısmi Basıncı	float64
DBP	Diastolik KB	float64	SaO2	Oksijen Saturasyonu	float64
Resp	Solunum(dakikada nefes sayısı)	float64	AST	Aspartat Aminotransferaz	float64
EtCO2	Karbondioksit miktarı	float64	BUN	Kan üre azotu	float64
Demografik Değişkenler			Alkalinephos	Alkalın fosfataz	float64
Age	yaş	float64	Calcium	Kalsiyum	float64
Gender	Kadın (0) ve Erkek (1)	int64	Chloride	Klorür	float64
Unit1	YBÜ (MICU için)	int64	Creatinine	Kreatinin	float64
Unit2	YBÜ (SICU için)	int64	Bilirubin_direct	Bilirubin	float64
HospAdmTime	Hastaneye kabul ile YBÜ arasında geç	float64	Glucose	Glikoz	float64
ICULOS	YBÜ kalış süresi	int64	Lactate	Laktik asit	float64
Laboratuvar Değerleri			Magnesium	Magnezyum	float64
PTT	kısmi tromboplastin zamanı	float64	Phosphate	Fosfat	float64
WBC	Lökosit sayısı	float64	Potassium	Potasyum	float64
Fibrinogen	Fibrinojen	float64	Bilirubin_total	Toplam bilirubin	float64
Platelets	Trombosit sayısı	float64	Hct	Hematokrit	float64
Hgb	Hemogloblin	float64	Hedef Değişken		
TroponinI	TroponinI	float64	SepsisLabel		int64

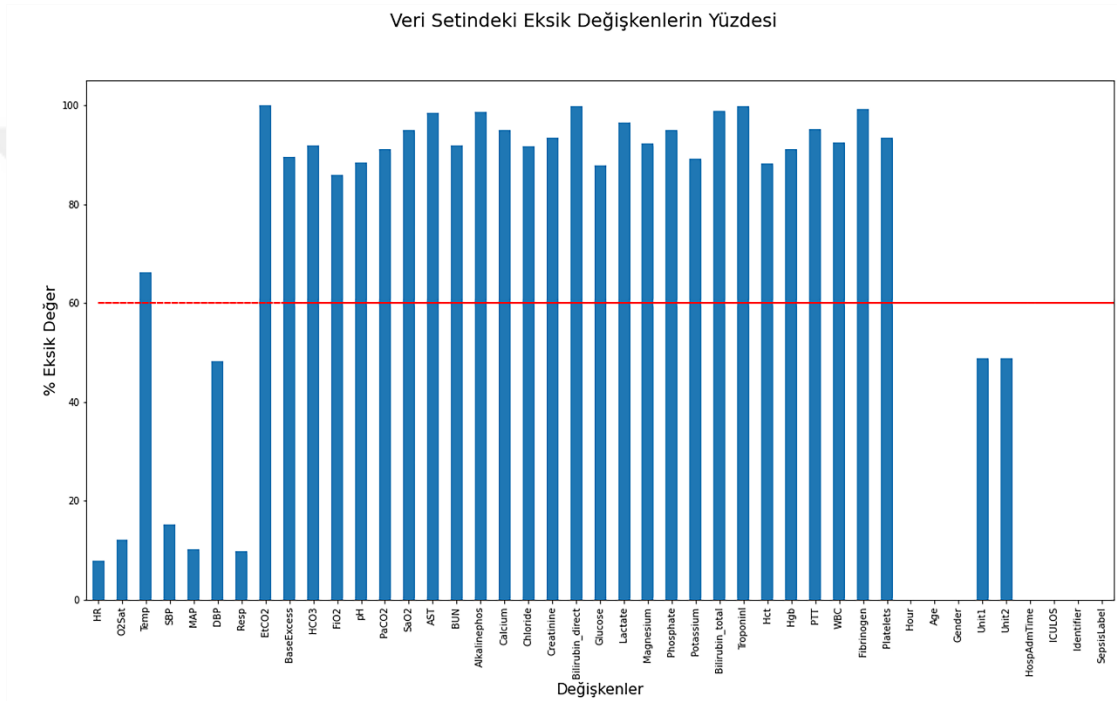
Şekil 26. Sepsisin erken teşhisinde kullanılan değişkenler

Tez çalışması kapsamında oluşturulan nihai veri ambarı, 120 bin hastanın kaydı ve bu hastalara ait zaman damgalı 1.552.210 satırı içermektedir. Veri setini daha iyi anlamak amacıyla tanımlayıcı istatistiklerin dağılımı benzersiz hasta kayıtları (42.842 hasta) içinde incelenmiştir. Buna göre tüm veri setinde %56 erkek, %44 kadın hastanın bulunduğu ve 60-80 yaş aralığında hasta dağılımının %45, 80 yaş üstünün %14 ve 20 yaş altının ise %0,84 olduğu sonucuna ulaşılmıştır.

#### 4.3.2.1. Veri Ön İşlemleri

Tez kapsamında hazırlanan veri ambarında, toplam 1.552.210 satır hasta kaydı bulunmaktadır. Bu satırlar, hastaların farklı zamanlarda ölçülen zaman serisi formatında sağlık değerlerini içermektedir. Klinik verileri yapay zeka ya da makine öğrenmesi alanında modellerken karşılaşılan en sık problemlerden biri eksik, kirli ve gürültülü verilerdir. Sağlık personellerinin yoğun iş temposundan kaynaklı veri girişlerinin yapılamaması ya da eksik yapılması, cihazlarda yaşanan kesintiler veya

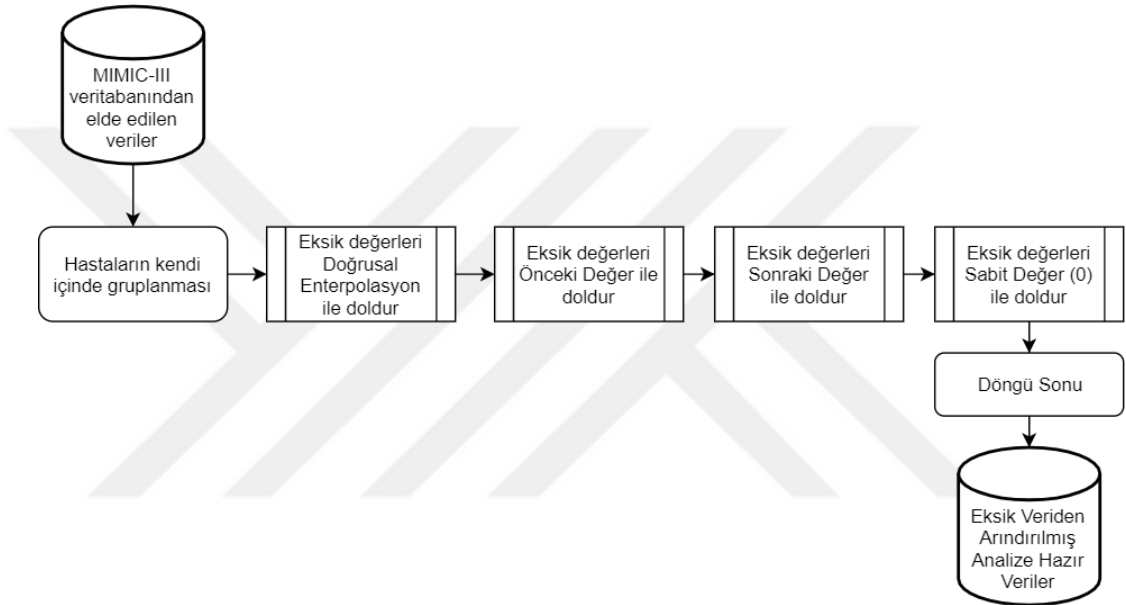
sorunlardan kaynaklı veri akışlarında eksiklik, kirlilik ya da gürültü yaşanabilmektedir. Çalışmada kullanılan MIMIC-III veri tabanında, sepsis özelinde oluşturulan veri ambarı hasta bazında eksik veriler içermektedir. Bu nedenle veri analizine geçmeden önce veri seti üzerinde veri ön işlemleri yapılmıştır. Veri setindeki değişkenlerdeki eksik değerlerin oranı incelendiğinde (Şekil 27) hastaların demografik verilerinde eksik değer bulunmazken, laboratuvar verilerinde eksik verilerin çoğunlukta olduğu görülmüştür.



Şekil 27. Veri setindeki eksik değerlerin yüzdesi

Veri setindeki eksik verilerin giderilmesi için doğrusal enterpolasyon, önceki ya da sonraki değer ile eksik veri giderme ve sabit değer ile eksik veri doldurma işlemleri gerçekleştirilmiştir. Doğrusal enterpolasyon, zaman serisi mevsimsellik içermediğinde, eksik, eşit olmayan aralıklı veya senkronize edilmemiş değerleri işlemek için kullanılmaktadır. Sonraki değer yani ileri doldurma, başka bir boş olmayan değerle karşılaşıncaya kadar son gözlemlenen değeri olmayı ileriye doğru taşımayı amaçlamaktadır. Önceki değer ile yani geriye doğru doldurma, başka bir eksik olmayan değer ile karşılaşıncaya kadar ilk gözlemlenen dolu değeri geriye doğru

doldurmaktadır. Veri setinde zaman serisi formatında bulunan hasta kayıtları gruplandırılmış, böylece her hastanın eksik verisinin kendi içindeki değer ile doldurulması amaçlanmıştır. Klinik verilerin veri ön işlemlerinde dikkate alınması gereken en önemli hususlardan biri, her hastanın kendi değer aralıkları içinde ele alınması gerektiğidir. Bu nedenle eksik verilerin giderilmesi ve kaliteli bir klinik veri ambarının oluşabilmesi için veri ön işlemlerinin ekstra önemli olduğu düşünülmektedir.



Şekil 28. Eksik verilerin giderilme süreci

Her bir hasta grubu içindeki eksik değerler giderilirken öncelikle doğrusal enterpolasyon yöntemi kullanılmış, ardından önceki ve sonraki değer ile eksik veriler giderilmiştir. Bu adımlardan sonra hala hastanın kayıtlarında eksik değer bulunuyor ise bu durumda numerik veriler için sabit değer (0) kullanılarak eksik veri giderme işlemi sonlandırılmıştır.

	HR	O2Sat	Temp	SBP	MAP	DBP	Resp	EtCO2	BaseExcess	HCO3	...	PTT	WBC	Fibrinogen	Platelets	Age	Gender	HospAdmTime	ICULOS	SepsisLabel	patient	
0	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	...	NaN	NaN	NaN	NaN	83.14	0	-0.03	1	0	p000001	
1	97.0	95.0	NaN	98.0	75.33	NaN	19.0	NaN	NaN	NaN	...	NaN	NaN	NaN	NaN	83.14	0	-0.03	2	0	p000001	
2	89.0	99.0	NaN	122.0	86.00	NaN	22.0	NaN	NaN	NaN	...	NaN	NaN	NaN	NaN	83.14	0	-0.03	3	0	p000001	
3	90.0	95.0	NaN	NaN	NaN	NaN	30.0	NaN	24.0	NaN	...	NaN	NaN	NaN	NaN	83.14	0	-0.03	4	0	p000001	
4	103.0	88.5	NaN	122.0	91.33	NaN	24.5	NaN	NaN	NaN	...	NaN	NaN	NaN	NaN	83.14	0	-0.03	5	0	p000001	
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
75	61.0	97.0	36.11	NaN	58.00	NaN	18.0	NaN	NaN	NaN	...	NaN	NaN	NaN	NaN	75.91	0	-98.60	22	0	p000002	
76	55.0	95.0	NaN	NaN	51.00	NaN	11.0	NaN	NaN	NaN	...	NaN	NaN	NaN	NaN	75.91	0	-98.60	23	0	p000002	
77	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	...	NaN	NaN	NaN	NaN	45.82	0	-1195.71	1	0	p000003	
78	87.0	96.0	NaN	131.0	70.33	NaN	29.0	NaN	NaN	NaN	...	NaN	NaN	NaN	NaN	45.82	0	-1195.71	2	0	p000003	
79	93.0	97.0	37.11	130.0	69.33	NaN	40.0	NaN	NaN	NaN	...	NaN	NaN	NaN	NaN	45.82	0	-1195.71	3	0	p000003	

Veri setinin ilk hali (patient1, patient2, patient3 için bazı sağlık değerleri)

	HR	O2Sat	Temp	SBP	MAP	DBP	Resp	EtCO2	BaseExcess	HCO3	...	Platelets	Age	Gender	Unit1	Unit2	HospAdmTime	ICULOS	SepsisLabel	patient	
0	97.0	95.0	36.11	98.0	75.330	0.0	19.0	-1.0	24.000000	45.0	...	317.0	83.14	0	0	0	-0.03	1	0	p000001	
1	97.0	95.0	36.11	98.0	75.330	0.0	19.0	-1.0	24.000000	45.0	...	317.0	83.14	0	0	0	-0.03	2	0	p000001	
2	89.0	99.0	36.11	122.0	86.000	0.0	22.0	-1.0	24.000000	45.0	...	317.0	83.14	0	0	0	-0.03	3	0	p000001	
3	90.0	95.0	36.11	122.0	88.665	0.0	30.0	-1.0	24.000000	45.0	...	317.0	83.14	0	0	0	-0.03	4	0	p000001	
4	103.0	88.5	36.11	122.0	91.330	0.0	24.5	-1.0	23.857143	45.0	...	317.0	83.14	0	0	0	-0.03	5	0	p000001	
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
75	61.0	97.0	36.11	114.0	58.000	36.0	18.0	-1.0	0.000000	22.0	...	158.0	75.91	0	0	1	-98.60	22	0	p000002	
76	55.0	95.0	36.11	114.0	51.000	36.0	11.0	-1.0	0.000000	22.0	...	158.0	75.91	0	0	1	-98.60	23	0	p000002	
77	87.0	96.0	37.11	131.0	70.330	50.0	29.0	-1.0	8.000000	32.0	...	488.0	45.82	0	1	0	-1195.71	1	0	p000003	
78	87.0	96.0	37.11	131.0	70.330	50.0	29.0	-1.0	8.000000	32.0	...	488.0	45.82	0	1	0	-1195.71	2	0	p000003	
79	93.0	97.0	37.11	130.0	69.330	50.0	40.0	-1.0	8.000000	32.0	...	488.0	45.82	0	1	0	-1195.71	3	0	p000003	

Şekil 29. Eksik verilerden arındırılmış veri seti

Veri setinin ilk durumu ve eksik verilerin giderilmesinden sonraki mevcut durum Şekil 29’da gösterilmiştir. Bu işlemler sonrasında veri setinde herhangi eksik değer kalmamıştır.

#### 4.4. Uygulama1: Denetimsiz Öğrenme: Bulanık C- Ortalamalar Algoritması

##### 4.4.1. Araştırmanın Amacı

Bu araştırma, sepsis enfeksiyonunun gelişimini etkileyen değişkenlerin yardımıyla sepsis pozitif ve sepsis negatif tanısı konan hasta verilerine Bulanık C-Ortalamalar algoritmasının uygulanarak hastalara ait örüntülerin monitörize edilmesi ve bu sayede

hem hastalar arasındaki farkın anlaşılması hem de YBÜ'ne yeni gelen bir hastanın değerlerinin hangi bölgeye yakın olduğunun tespit edilebilmesi amaçlanmaktadır. Hastaların kümelerine homojen şekilde dağıtılması sayesinde, sepsis pozitif ve sepsis negatif olan bölgelerin belirlenmesi ve böylece hastanın anlık değerleri ile hastanın hangi kümeye doğru yönelim gösterdiği hekime sunulacaktır. Bu sayede yeni gelen hastanın değerleri anlık olarak işlenerek hastanın hangi bölgeye yakın olduğu tespit edilebilecektir.

Denetimsiz öğrenme tekniği olan kümeleme, hedef veriye ihtiyaç duymadan yalnızca verilere dayalı çıkarım yapan bir makine öğrenmesi koleksiyonudur. Kümeleme analizi ile keşifsel bir analiz gerçekleştirilerek hasta segmentasyonuna dair örüntülerin çıkarılması amaçlanmıştır. Çalışmada Bulanık C- Ortalamalar algoritmasının kullanılmasının nedeni, bu hastaları ayıran kesin bir çizginin olmamasıdır. Hekimlerle yapılan toplantı ve görüşmeler esnasında sepsis enfeksiyonunun zor anlaşılması ve bu nedenle erken tespitinin yapılamadığı belirtildiğinden, bu hastaları kümelemek için kesin sınırları olan kümeleme algoritmaları değil, Bulanık C- Ortalamalar algoritması kullanılmıştır.

#### **4.4.2. Denetimsiz Öğrenme Modelinde Veri Ön İşlemleri**

Veri analizi için kullanılacak olan MIMIC veri tabanı tez kapsamında yapılacak olan araştırmaların temel konusu olan sepsis enfeksiyonu özelinde veri ambarına dönüştürülmüştür. Ardından klinik veri ambarına uygun olacak şekilde eksik verilerin giderilmesi (doğrusal enterpolasyon, önceki değer, sonraki değer, sabit değer) adımı gerçekleştirilmiştir. Her bir hastaya ait eksik verilerin giderilmesinin ardından oluşan veri setinde toplam 41 değişken ve 1.552.210 satır hasta kaydı bulunmaktadır.

Araştırmada, verilerin denetimsiz olarak eğitilerek homojen şekilde gruplanmaları amaçlanmaktadır. Kümeleme uygulaması öncesinde zaman serisi formatında bulunan hasta kayıtları, her bir hastaya ait tek satır olacak şekilde veri ön işlemden geçirilmiştir. Bu amaçla, hasta bazında HR, O2Sat, Temp, Resp, ph AST, BUN ve diğer tüm klinik değişkenler minimum, maksimum, ortalama ve standart sapma değerleri hesaplanarak

tek bir satıra indirgenmiştir. Son durumda veri setinde modele girecek olan değişken sayısı 140, benzersiz hasta ise 42.842 satırdan oluşmaktadır. Bu benzersiz hasta hasta kayıtları uluslararası tanı kodlarını içeren ICD-9 kodları kullanılarak sepsis pozitif ve sepsis negatif olarak etiketlenmiştir. Etiketlenen veriler sonucunda veri setinde 2.932 sepsis pozitif ve 39.910 sepsis negatif hasta elde edilmiştir.

Age	Gender	SepsisLabel	Mean (HR)	Max* (HR)	Min* (HR)	Standard deviation (HR)	Mean (O2Sat)	Max* (O2Sat)	Min* (O2Sat)	Standard deviation (O2Sat)	Mean (Temp)	Max* (Temp)	Min* (Temp)	Standard deviation (Temp)	Mean (SBP)	Max* (SBP)	Min* (SBP)	Standard deviation (SBP)
20	0	1	84.700	100	72	9.742	94.900	98	89	3.107	38.399	38.890	37.830	0.358	143.600	149	120	11.423
20	0	1	124.313	131	118.500	4.535	96.188	97	94	1.153	37.906	38.700	36.650	0.638	123.125	142	112.500	9.742
20	0	1	138.436	154	128	10.507	94.906	96	94	0.801	0	0	0	0	97.125	105	77	9.094
20	0	1	131.333	136	126	3.317	94.333	99	85	4	38.094	38.600	37.900	0.269	167.889	189	160	9.545
20	0	1	116.900	152	92	16.341	97.050	100	86	4.058	38.420	39	38	0.322	108.300	118.500	92	7.470
20	0	1	132.850	144	126	5.677	94.850	97	93	1.733	38.635	39.400	37.900	0.510	104.000	121	92	10.317
19	0	1	82.556	91	73	6.912	98.500	100	91	3.182	36.376	36.780	36.220	0.215	116.222	126	101	9.471
19	0	1	108.660	123.800	102	7.215	99.500	100	98.500	0.589	36.820	37.200	36.200	0.376	124.560	140	114	7.548
19	1	1	84.400	101	75	9.407	97.900	100	97	1.101	36.035	36.170	35.713	0.142	122.100	136	110	7.767
19	1	1	86.250	95	73	6.529	98.700	100	96	1.229	38.054	39.220	37.280	0.517	127.700	145	109	13.695
19	1	1	87.600	103	65	9.559	100	100	100	0	37.435	37.720	37.280	0.157	110.850	134	84	17.431
18	0	1	108.550	127	95	11.285	100	100	100	0	36.640	37.500	35.800	0.552	105.250	120	93	7.562
18	1	1	108.111	120	96	7.491	99.333	100	95	1.658	38.413	38.780	37.690	0.375	119.667	157	96	18.118
18	1	1	82.450	103.500	76	8.308	99.100	100	96	1.524	37.050	37.100	36.800	0.094	143.100	165	135	8.399
17	1	1	152.750	156	146	4.238	89.250	96	82	6.146	0	0	0	0	87.125	96	84	3.806
17	1	1	89.778	114	82	9.667	100	100	100	0	38.300	38.600	37.900	0.269	106.111	122	96	8.710
20	0	0	86.894	103	74	7.319	98.117	100	95	1.265	36.959	37.330	36.500	0.211	114.830	127	97	7.943
20	0	0	88.218	113	72	8.901	97.500	100	93	2.226	37.369	38.940	36.560	0.561	121.827	142	92	9.832
20	0	0	98.452	149	54	24.595	99.645	100	96	0.985	36.672	37.440	34.720	0.663	134.500	142	114	5.595
20	0	0	82.188	102	53	12.692	98.687	100	96	1.183	36.690	37.060	36	0.348	118.786	133	98	6.198
20	0	0	92.125	105	79	7.168	99.847	100	98	0.411	37.036	37.330	36.780	0.111	112.634	147	97	12.455
20	0	0	110.786	130	99	7.775	99.020	100	97	1.078	36.802	37.060	36.110	0.270	111.520	125	83	8.052

Şekil 30. Veri ön işlemleri sonrası veri kesitinden örnek

Bu uygulama kapsamında kullanılacak olan veri setinde, sepsis pozitif hastaların %59'unun erkek (n=1739), %40'inin kadın (n=1193) hasta olduğu tespit edilmiştir. Sepsis Pozitif (SP) olan hastaların %46'sı 60-80 yaş aralığındadır. Bu tanımlayıcı istatistiğe dayanarak sepsis enfeksiyonunun en fazla yoğun bakımda tedavi gören 60-80 yaş aralığında hastalarda görüldüğü söylenebilir. Sepsis Negatif (SN) olan hasta dağılımı incelendiğinde ise kadın hastalar %44 (n=17.595), erkek hastalar ise %55 (n=22.315) oranında bir dağılım gösterdiği belirlenmiştir.

#### 4.5. Bulanık C -Ortalamlar (Fuzzy C-Means) Algoritması

Bulanık C- ortalamlar algoritması (Fuzzy C-Means Algorithm: FCM), verileri iki ya da daha fazla kümeye bölen bir kümeleme yöntemidir. Örüntü tanımada sıklıkla kullanılan bu yöntem Dunn tarafından 1973'te ortaya atılmış (Dunn, 1973) ve 1981'de Bezdek tarafından geliştirilmiştir (Bezdek vd., 1984). FCM, özellik analizi, kümeleme ve sınıflandırıcı tasarımı gibi çok çeşitli problemlere uygulanan denetimsiz bir kümeleme algoritmasıdır. FCM kümeleme yönteminde örüntüler, farklı üyelik dereceleri ile kümelere dahil olabilmektedir (Nayak, vd., 2015) FCM, kimya, jeoloji, astronomi, görüntü analizi, tıbbi teşhis, örüntü analizi ve hedef tanımada yaygın olarak kullanılmaktadır (Yong vd., 2004). Bu algoritma, çeşitli veri giriş noktaları arasındaki mesafeye dayalı analiz için kullanılmaktadır. Veri noktaları arasındaki mesafeye göre kümeler oluşturulmakta ve her küme için küme merkezleri bulunmaktadır. FCM algoritması temelde bir nesne ile bir küme arasındaki bağlantı veya üyelik düzeyi değeri hesaplanmasına dayanan kümeleme tekniği olarak ifade edilmektedir (H. Lin, 2008). FCM, denklem 1'de gösterilen amaç fonksiyonunu minimuma indirmeyi amaçlamaktadır:

$$J_m = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^m \|x_i - c_j\|^2, 1 \leq m < \infty \quad (1)$$

Denklemden  $x_i$  veri dizisinin  $i$ . nesnesini,  $c_j$ ,  $j$ . kümenin merkezini, temsil etmektedir.  $U_{ij}$ , her bir verinin oluşturulan küme ya da kümelerin üyesi olma olasılığını gösteren bir matristir.  $m$  bulanıklık katsayısıdır,  $m = 1$  olduğunda, neredeyse hiç bulanıklık olmayacaktır. Ancak  $m$  değeri arttıkça bulanıklık da artacaktır. Bu çalışmada ise bulanıklık katsayısı  $m = 2$  olarak kullanılmıştır.

$$u_{ij} = \frac{1}{\sum_{k=1}^C \left( \frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{\frac{2}{m-1}}}, c_j = \frac{\sum_{i=1}^N u_{ij}^m \cdot x_i}{\sum_{i=1}^N u_{ij}^m} \quad (2)$$

FCM, diğer birçok makine öğrenmesi algoritması gibi özyinelemeli bir algoritmadır.  $U_{ij}$  matrisinde hiç değişiklik olmayana ya da çok az değişiklik olana kadar yinelenir



(Bezdek, 1973). Denklem (2), her yineleme sırasında  $u_{ij}$  ve  $c_j$  değerlerini hesaplamak için kullanılmaktadır.

Algoritmanın bu eşitlikler kullanılarak ilerlediği temel akış:

1.  $U^0 = [u_{ij}]$  başlangıç matrisi oluşturulur.
2. Küme merkezleri hesaplanır.
3.  $U^{(k)}$  ve  $U^{(k+1)}$  değerleri güncellenir.
4.  $\|U^{(k+1)} - U^{(k)}\| < \mathcal{E}$  süreci sona erdirilir, aksi durumda 2. adıma tekrar dönülür.

U üyelik matrisi rastgele oluşturulduğundan, FCM algoritması her çalıştığında farklı minimumlarla sonuçlanabilmektedir (Flores-Sintas vd., 1999). Yineleme sona erdiğinde, bu değerler 0 veya 1'e yuvarlanabilir. Daha sonra, veriler en yüksek üyelik derecesine sahip kümeye atanır, netlik ortadan kaldırılır ve ardından kümeleme işlemi sonlandırılır. FCM algoritması, verilerin yalnızca bir kümeye değil iki veya daha fazla kümeye ait olmasına izin verir. Uygun küme sayısının belirlenmesi ve oluşan kümelerin kalitesini değerlendirmek için, Partition Entropy (Bezdek, 1975), Partition Coefficient (Bezdek, 1973) ve Xie Beni (Xie ve Beni, 1991) gibi doğrulama indeksleri kullanılmaktadır. Bu tez kapsamında da bu indeksler kullanılarak optimum küme sayısının elde edilmesi amaçlanmıştır.

#### - Xie Beni Index

Xie Beni indeksi (XB), kümeler arasındaki toplam varyasyon oranını ve kümelerin bulanık ayrışma oranını hesaplayarak değer üretmektedir. Xie Beni indeksinde optimum küme sayısı, indeksin minimum değerine karşı gelen küme sayısını ifade etmektedir (Xie ve Beni, 1991). XB indeksi değeri ne kadar düşükse, kümeleme kalitesi o kadar iyi olarak nitelendirilmektedir (Singh vd., 2018).

$$XB = \frac{(\sum_i^K \sum_j^N u_{ij}^2 \|x_j - c_i\|^m) / N}{(\min_{i \neq j} \|c_i - c_j\|^m)} \quad (3)$$

Denklem 3'te  $U_{ij}$ , her bir  $C_j$  kümesi için üyelik derecesini temsil etmektedir. FCM algoritması, her kaydı yalnızca bir kümeye atamamaktadır. Bulanıklık kavramı nedeniyle, her kaydın üretilen her küme için belirli bir üyelik derecesi bulunmaktadır. Üyelik matrisi ( $U_{ij}$ ) oluşturmasının nedeni budur. Sentetik ve simüle edilmiş MRI veri seti görüntülerinin kullanıldığı çalışmada küme geçerlilik indekslerinin karşılaştırılması yapılmış ve sonuçta, bir görüntüdeki optimum küme sayısını elde etmek için XB indeksi önerilmiştir (Zanaty, 2012).

- **Ayrırma Katsayısı (Partition Coefficient Index)**

Bulanık kümelemede, ayrırma katsayısı (Partition Coefficient Index: PCI) değeri hesaplanarak doğrulama yapılabilmektedir (Balasko vd., 2005). PCI, kümeler arasındaki örtüşme miktarını ölçmektedir. PCI, Bezdek tarafından şu şekilde tanımlanmıştır (Bezdek, 1981):

$$PCI = \frac{1}{N} \sum_{i=1}^c \sum_{j=1}^n U_{ij}^2 \quad (4)$$

Denklem 4'te  $U_{ij}$ ,  $i$  kümesindeki  $j$  veri noktasının üyeliğidir. PCI değeri  $[0,1]$  aralığı içinde değer almaktadır ve değerlerin 1'e yaklaşması küme kalitesinin iyileştiği anlamına gelmektedir (Iriawan vd., 2018).

- **Ayrırma Entropisi (Partition Entropy Index)**

Ayrırma entropisi (Partition Entropy Index: PEI) Bezdek tarafından (Wang ve Zhang, 2007) FCM algoritması için bir doğrulama indeksi olarak önerilmiş ve aşağıdaki denklemlerle tanımlanmıştır:

$$PEI = \frac{1}{N} \sum_{i=1}^c \sum_{j=1}^n U_{ij} \log_2 U_{ij} \quad (5)$$


PEI, küme ayrımlarının bulanıklığını ölçen indeks olarak tanımlanmıştır. Optimum küme sayısı, bu indeksin minimum değerine karşılık gelen küme sayısı olarak vurgulanmıştır (Rubio vd., 2011).

Tablo 4. Optimum küme sayısının belirlenmesinde kullanılan indeksler

İndeksler	Optimum için gerekli değer
Xie Beni	Minimum değer
Ayırma Katsayısı- Partition Coefficient	Maksimum değer
Ayırma Entropisi- Partition Entropy	Minimum değer

#### 4.5.1. Temel Bileşen Analizi

Temel bileşenler analizi (Principal Component Analysis: PCA) en popüler çok değişkenli istatistiksel tekniklerden biridir ve neredeyse tüm bilimsel disiplinler tarafından kullanılmaktadır. Örneğin sağlık bilimlerinde DNA mikrodizileri ve kütle spektrometreleri, yüzlerce örnekte binlerce mRNA veya proteinin seviyelerini ölçebilmektedir. Bu tür yüksek boyutluluk örneklerin görselleştirilmesini zorlaştırmakta ve verilerin basit bir şekilde araştırılmasını sınırlamaktadır. Yüksek boyutlu verilerde amaç, minimum bilgi kaybıyla daha düşük boyutlu bir alt uzayda orijinal verileri temsil eden azaltılmış bir dizi öznelik belirlenebilmesidir (Şekil 31) (Kherif ve Latypova, 2020). PCA, veri kümesindeki varyasyonların çoğunu korurken verilerin boyutunu azaltan matematiksel bir algoritmadır (Jolliffe, 2002).



Şekil 31. Temel bileşen analizi (PCA) projeksiyonları

PCA amacı, verilerin varyansını en iyi şekilde açıklayabilecek ortogonal projeksiyonları bulmaktır (A). V1, birinci ana eksen, verilerin varyansının çoğunu açıklar; V2, ikinci ana eksen ve V1 (B) tarafından açıklanmayan kalan varyansı açıklar. V1 ve V2, verilerin (C)'ye yansıtılabileceği yeni bir ortonormal koordinat sistemi oluşturur.

Orijinal yüksek boyutlu veriler yerine azaltılmış bir veri kümesiyle çalışmanın birçok avantajı bulunmaktadır. Bu avantajlar:

- Verileri 2D veya 3D olarak görselleştirme imkanı,
- Daha az depolama alanı,
- Eş doğrusallığın ortadan kaldırılması ve
- Gürültünün azalması

PCA ile değişkenlerin bileşkeleri olarak adlandırılan daha az sayıda yeni değişkenler ya da temel bileşenler oluşturulmaktadır. Temel bileşenler birbirinden bağımsızdır, bu nedenle değişkenler arası bağımlılık yapısı da bulunmamaktadır (Jolliffe, 2002:167). PCA amaçları;- veri tablosundan en önemli bilgileri çıkarmak, - yalnızca bu önemli bilgiyi tutarak veri kümesinin boyutunu sıkıştırmak, - veri kümesinin açıklamasını basitleştirmek, değişkenlerin yapısını analiz etmek olarak ifade edilmektedir (Abdi ve Williams, 2010). Çok değişkenli istatistiksel analizde n tane nesneye ilişkin p tane değişken incelenmektedir. Bu değişkenlerden çoğunun birbiriyle ilişkili ve değişken sayısının (p) çok fazla olması, bazı değerlendirmelerin yapılmasını zorlaştırmaktadır. Bu gibi durumlarda PCA, başvurulacak en önemli yöntemlerden biri olmaktadır. Değişkenlerin varyans kovaryans yapısını, bu değişkenlerin doğrusal birleşimleri vasıtasıyla açıklayarak, veri indirgenmesi ve yorumlanmasını sağlayan, çok değişkenli bir istatistik yöntemidir. Genel olarak değişkenler arasındaki bağımlılık yapısının yok edilmesi ve/veya boyut indirgeme amacıyla kullanılan bu yöntem başlı başına bir analiz olduğu gibi bazen de veri hazırlama tekniği olarak kullanılmaktadır (Mujica vd., 2008). PCA analizi belirtildiği gibi, boyutların büyüklüğünü azaltarak ya da iki boyutu birleştirip tek bir boyut yaparak verinin bir bakıma sıkıştırılmasını sağlamaktadır. Bunun için yapılacak işlemler aşağıdaki gibidir:

1. Veriler ortalamayla düzgünleştirilir. (Sadece gerekli durumlarda)
2. Kovaryans matrisi hesaplanır.
3. Eigen Value (öz değer) ve Eigen Vector (öz vektör) hesaplanır.

4. İndirgeme için özellik vektörü seçilir ve indirgeme çarpımı yapılır.

Düzgünleştirme işlemi her zaman yapılması zorunlu bir işlem değildir. İşlem ilk adım olarak da son adım olarak da gerçekleştirilebilmektedir. Bu yöntem (Denklem 1.) ile veri kümesinin ortalaması bulunmakta ve her bir veri ortalamadan çıkarılmaktadır.

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad (1)$$

Sonuçta yeni, düzgünleştirilmiş küme elde edilir ve PCA işlemine bu yeni düzgünleştirilmiş veriler ile devam edilir.

Kovaryans matrisi iki veri kümesi için hazırlanan bir matristir ve  $\text{cov}_{(x,y)}$   $x$  ve  $y$  arasındaki kovaryans matrisinin  $k$  ile gösterimi şu şekildedir:

$$k_{\text{cov}(x,y)} = \begin{bmatrix} \text{cov}_{x,x} & \text{cov}_{y,x} \\ \text{cov}_{x,y} & \text{cov}_{y,y} \end{bmatrix} \quad (2)$$

PCA analizinde amaç öz değer ve öz vektör yardımıyla (kovaryans matrisleri) ilgili verilerin boyutunu düşürmektir. İzlenecek yol ise iki veri setinin öncelikle (2x2)'lik kovaryans matrisinin hesaplanması, daha sonra bu matristen yararlanarak öz vektörün bulunmasıdır (Jolliffe, 2002). Son adıma gelindiğinde, iki vektör yani iki dizi bulunmaktadır. Bu vektörlerden büyük olanı seçildiğinde, iki veri dizisi tek bir dizi haline dönüşecek ve sonuçta her iki dizinin de ortak özelliklerini taşıyacaktır (Silahtaroglu, 2008:124). İndirgeme çarpım işlemi  $A = B * C$  şeklindedir. Burada; A: İndirgenmiş veri dizisini, B: Seçilen öz vektörün transpozisini, C: Düzgünleştirilmiş orijinal veri kümesini ifade etmektedir.

Çalışmada, elde edilen kümeler PCA algoritması kullanılarak iki boyuta indirgenmiş ve bu sayede kümelerin iki boyutlu görselleştirilerek monitörize edilmesi amaçlanmıştır.

#### 4.6. Model Mimarisi ve Bulgular

Veri setindeki hastaların ortak değerlerini analiz ederek homojen şekilde hastaların optimum kümelerine ayrılması amacıyla FCM algoritması kullanılmıştır. Araştırmaya başlamadan önce sepsis enfeksiyonu özelinde hazırlanmış ve veri ön işlemlerinden geçirilerek temizlenmiş veriler kullanılmıştır. Verilerin denetimsiz öğrenme analizlerinde açık kaynak kodlu; veri analizi, raporlama, entegrasyon platformu olan KNIME (versiyon 4.4.2) kullanılmıştır (Berthold vd., 2006). Her bir hastanın birden fazla değer içermesi nedeniyle kümeleme analizine başlanmadan önce hasta değerleri tek satıra indirgenmiştir. Bunun için her bir hastaya ait olan laboratuvar ve cihaz değişkenlerinin minimum, maksimum, ortalama ve standart sapma değerleri hesaplanmıştır. Şekil 32’de veri ambarının ilk halinden hasta bazında her bir değişken için hesaplanan minimum, maksimum, ortalama ve standart sapma değerlerinin hesaplanması sonucu elde edilen veri kümesinin dönüşüm özeti gösterilmiştir.

patient	HR	O2Sat	Temp	SBP	MAP	DBP	Resp	EtCO2	BaseExcess	HCO3	FIO2	pH	PaCO2	SaO2	AST	BUN	Alkalinephos	Calcium
p000001	97	95	36.11	98	75.33	0	19	-1	24	45	0.28	7.36	100	88	16	14	98	9.3
p000001	97	95	36.11	98	75.33	0	19	-1	24	45	0.28	7.36	100	88	16	14	98	9.3
p000001	89	99	36.11	122	86.00	0	22	-1	24	45	0.28	7.36	100	88	16	14	98	9.3
p000001	90	95	36.11	122	88.66	0	30	-1	24	45	0.28	7.36	100	88	16	14	98	9.3
p000001	103	88.5	36.11	122	91.33	0	24.5	-1	23.86	45	0.28	7.37	98	88	16	14	98	9.3
p000001	110	91	36.11	122.5	84.16	0	22	-1	23.71	45	0.2805	7.37	96	88	16	14	98	9.3
p000001	108	92	36.11	123	77	0	29	-1	23.57	45	0.281	7.38	94	88	16	14	98	9.3
p000002	61	99	36.44	124	65	43	17.5	-1	0	22	0	0	0	0	100	0	7.9	7.9
p000002	61	99	36.44	124	65	43	17.5	-1	0	22	0	0	0	0	100	0	7.9	7.9
p000002	64	98	36.39	125	64	41	27	-1	0	22	0	0	0	0	100	0	7.9	7.9
p000002	56	100	36.33	123	65	41	9	-1	0	22	0	0	0	0	100	0	7.9	7.9
p000002	66	99	36.28	120	67	43	23	-1	0	22	0	0	0	0	100	0	7.9	7.9
p000002	94	100	36.22	194	116	66	14	-1	0	22	0	0	0	0	100	0	7.9	7.9
p000002	58	99	36.19	133	68	43	13	-1	0	22	0	0	0	0	100	0	7.9	7.9
p000002	57	100	36.17	118	62	37	18	-1	0	22	0	0	0	0	100	0	7.9	7.9
p000002	62	100	36.14	126	66	37	12	-1	0	22	0	0	0	0	100	0	7.9	7.9
p000003	87	96	37.11	131	70.33	50	29	-1	8	32	0.5	7.51	41	0	31	0	11.1	11.1
p000003	87	96	37.11	131	70.33	50	29	-1	8	32	0.5	7.51	41	0	31	0	11.1	11.1



patient	Mean(HR)	Max*(HR)	Min*(HR)	Standard deviation (HR)	Mean(O2Sat)	Max*(O2Sat)	Min*(O2Sat)	Standard deviation (O2Sat)	Mean(Temp)	Max*(Temp)	Min*(Temp)
p000001	102.01	117	76	9.44	91.49	100	85	3.19	36.65	37.44	36.11
p000002	60.96	94	54	7.96	97.09	100	94	2.13	36.16	36.44	36
p000003	79.81	93	68	6.61	95.35	99	91	1.65	37.47	38.61	36.89
p000004	102.67	113	93	6.20	98.16	100	95.5	1.41	36.45	36.78	36.06
p000005	76.38	88	61	6.60	97.55	99	96	0.57	36.89	37.33	36.22
p000006	99.35	111	87	7.65	98.35	100	95	1.27	36.57	36.72	36.33
p000007	121.14	155.5	103	12.05	95.39	100	93	1.29	37.79	38.39	37.28
p000008	76.09	88	65	6.18	97.70	100	79	4.12	36.30	36.89	35.67
p000009	113.00	143	85	12.75	97.98	100	89.5	1.89	37.69	39.33	35.33
p000010	118.40	120	111	2.91	97.10	100	96	1.10	37.70	37.94	37.39
p000010	77.04	84	63	5.71	95.83	100	90	2.76	36.95	37.7	35.5

*Şekil 32. Hasta değerlerinin İndirgenmesi*

Hasta bazında her bir değişkene ait yapılan bu işlem sonucunda toplamda 140 değişken ve 42.842 hasta kaydı elde edilmiştir. Model genelinde 2.932 SP, 39.910 SN olan ve yoğun bakımda farklı hastalıklar nedeni ile tedavi görmekte olan hastalar eğitilmiştir. Bu veri kümesinde SP ve SN olan hastalara FCM algoritması uygulanarak kümeleme analizi gerçekleştirilmiştir. FCM kümeleme analizinde bulanıklık derecesinin optimum değeri  $m=2$  ve maksimum iterasyon sayısı 100 olarak belirlenmiştir. Uygun küme sayısının belirlenmesi için FCM algoritması kullanılarak veriler 2, 3, 4 ve 5 farklı kümeye ayrılmıştır.

Keşifsel bir analiz olan kümeleme analizinde herhangi bir etiket bulunmadığı için model performansında doğruluk, kesinlik, geri çağırma vb. (sınıflandırma) ve ortalama kare hatası vb. (regresyon) gibi performans ölçütleri kullanılamamaktadır. Ancak, denetimsiz öğrenme algoritmalarına özgü performans ölçütleri kullanılabilir. Bulanık C-Ortalamlar algoritması kullanılarak belirlenecek hasta kümelerinde küme kalitesinin ölçülmesi ve optimum küme sayısının belirlenebilmesi için PEI, PCI ve XB indeksleri kullanılmıştır. Buna göre SP ve SN olan hastalara yönelik uygulanan farklı küme sayılarının indeksleri Tablo 5. ve Tablo 6.'da gösterilmiştir.

*Tablo 5. Sepsis Pozitif hastaların küme indeksleri*


	Partition Entropy	Partition Coefficient	Xie Beni
Sepsis Pozitif    Küme Sayısı			
2	0,5141	0,6629	1,0140
3	0,8892	0,4557	2,8590
4	1,1978	0,3327	230,461
5	1,4405	0,2607	145,091

*Tablo 6. Sepsis Negatif hastaların küme indeksleri*

	Partition Entropy	Partition Coefficient	Xie Beni
Sepsis Negatif    Küme Sayısı			
2	0,6931	0,5	8,3760
3	1,0986	0,3333	8,0239
4	1,3862	0.2536	9,8229
5	1,6094	0,2	2,4572

PEI ve PCI, bulanık küme matrisi aracılığıyla nihai bölünmüş kümelerin bulanıklık derecesini ölçmektedir. Entropi değeri (PEI) minimum, katsayı değeri (PCI) ise maksimum değeri aldığı anda kümeleme başarılı olmaktadır (Liu vd., 2019). Kümelerin genel ortalamasını ve ayrıklığını ölçmek için kullanılan XB indeksi değerinin ise minimum olması optimum küme sayısının belirlenmesine öncülük etmektedir.

SP olan hastalarda en düşük PEI (0.51), en yüksek PCI (0.66) ve en düşük XB (1.01) değeri göz önünde bulundurulduğunda optimum küme sayısı iki olarak elde edilmiştir. Sepsis enfeksiyonu tanısı konan hastaların %20'si küme 0'da %80'i ise küme 1'de yer almaktadır (Şekil 33).

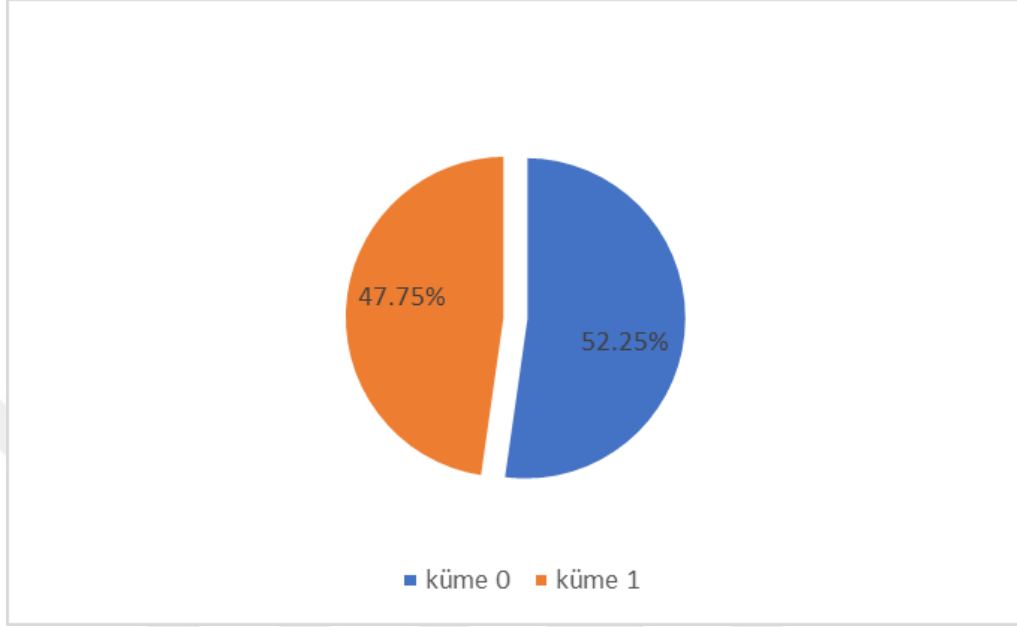


Şekil 33. Sepsis Pozitif hastaların kümelere yerleşim yüzdeleri

SN hastalarda en düşük PEI (0.69), en yüksek PCI (0.5), küme sayısının iki olduğu durumda elde edilmiştir. En düşük XB (2.45) değeri ise küme sayısı beş olduğunda



bulunmuştur. Bu durumda sepsis negatif hastalar için de optimum küme sayısının iki olduğu belirlenmiştir. Sepsis enfeksiyonu tanısı konmayan hastaların %52'sinin küme 0'da %48'inin ise küme 1'de yer aldığı görülmektedir (Şekil 34).



Şekil 34. Sepsis Negatif hastaların kümelere yerleşim yüzdeleri

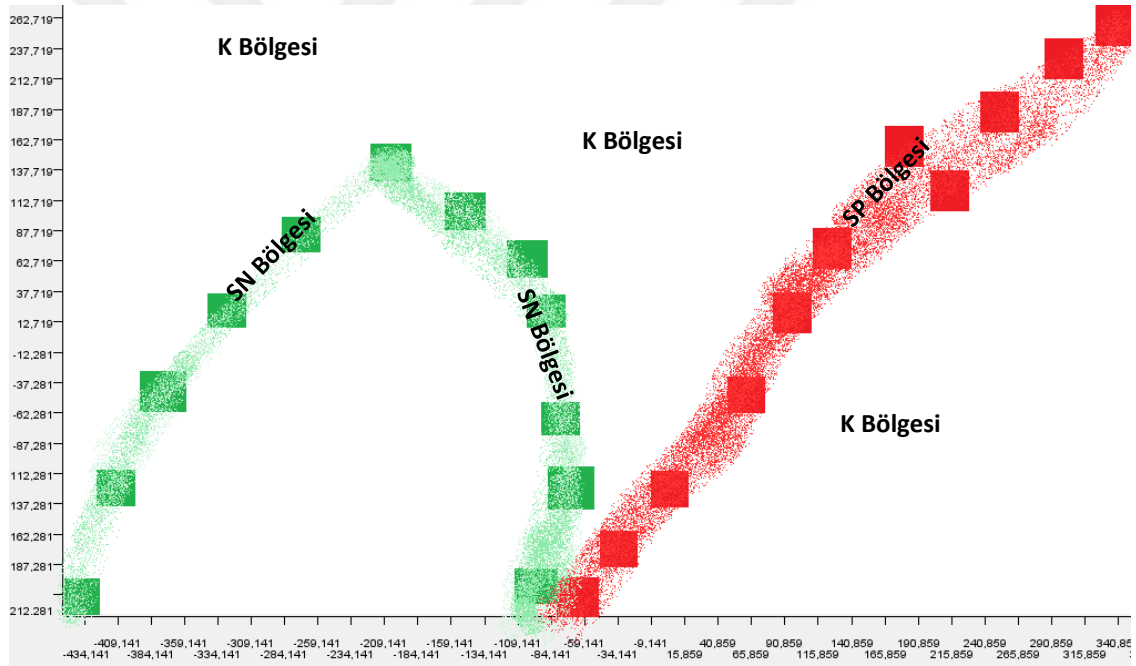
FCM algoritması kullanılarak gerçekleştirilen denetimsiz öğrenme sonucunda makine tarafından üretilen küme merkezlerinin kesiti Tablo 7'de gösterilmiştir.

Tablo 7. FCM Algoritması sonucu öğrenilen küme merkezleri

	Ortalama (HR)	Maks. (HR)	Min. (HR)	S.Sapma (HR)	Ortalama (WBC)	Maks. (WBC)	Min (WBC)	S.Sapma (WBC)
Sepsis PozitifCluster00	92.8	103.7	83.7	6.7	13.7	13.9	12.9	0.3
Sepsis PozitifCluster01	90.4	101.3	81.1	6.8	11.5	11.9	11.5	0.1
Sepsis NegatifCluster00	83.7	101.8	69.7	8,1	10.3	10.6	9.2	0.7
Sepsis NegatifCluster01	85.4	102.6	67.6	8,6	9,7	10.8	9.9	0.9

Modelde küme merkezlerini, kümeler arasındaki mesafeyi görselleştirebilmek ve modelin yoğun bakım ünitelerinde kullanılabilecek bir izleme sistemi ile entegre edilebilmesini sağlayabilmek için PCA ile veri boyutu ikiye indirgenmiştir. PCA ile

%18 kayıp göz ardı edilerek iki boyutlu olarak görselleştirilmesi sağlanmıştır. Sepsis izlemi iki boyutlu olarak gösterilmesi için %18 oranında temsil kaybı göz ardı edilmiştir. İki yeni vektörle temsil edilen küme temsilcileri, olası bir hasta monitörünün prototipini elde etmek için bir dağılım diyagramında görselleştirilmiştir. Şekil 35'te SN sepsis tanısı almayan hastaların bölgesini, SP sepsis tanısı alan hastaları ve K belirsiz/kararsız hastaları temsil etmektedir. SP ve SN bölgeleri birbirinden ayrık bir örüntü çizse de küme merkezlerinden de anlaşılacağı üzere SP Küme1 ile SN Küme0'ın küme merkezleri birbirlerine yakındır. Bu durumun aslında hekimlerin hastalığı tespit ederken yaşadığı zorluğu da ifade ettiği düşünülmektedir. Kesişen bölgede yaşanan bulanıklık nedeniyle, hekimlerin sepsis teşhisinde zorluk yaşandığı düşünülmektedir (Şekil 35).



Şekil 35. Küme merkezlerinin monitörize edilmesi

Çalışmada yapılan PCA boyut küçültme, sepsis tanısı alan ve sepsis tanısı almayan hastalar arasındaki farklı örüntüleri gözlemlemek amacıyla gerçekleştirilmiştir. Bu durumda, yeni bir hastanın benzer verileri monitörde haritalandırıldığında yeni hastanın SP veya SN olan alanlara ne kadar yakın olduğunu görmek mümkün olacaktır. Ayrıca hekim tedaviye başladıktan sonra hasta değerlerini anlık olarak

sistemden gözlemleyebilecek ve bu sayede SP olan bir hastanın SN bölgesine doğru bir yönelim gösterip göstermediğini anlık olarak izleyebilecektir. Bu da hekim ya da sağlık personeli müdahalede bulundu ise müdahalesinin hastada zaman içinde başarı gösterip göstermediğini de takip edebileceği bir izlem monitör sistemi olarak kullanılabilir.

#### 4.6.1. Sonuç

Bu araştırmada, yoğun bakım ünitesinde ölüm nedeni olarak bilinen, önemli bir hastalık olan sepsis enfeksiyonu hastalarının kümelenmesine yönelik bir model gerçekleştirilmiştir. Çalışmada MIMIC-III uluslararası klinik veri tabanı aracılığıyla yoğun bakım hasta verileri kullanılmıştır. Bu çalışmada hekim görüşleri ve literatür çalışmaları ile sepsis tanısında öneme sahip olduğu düşünülen laboratuvar, cihaz verileri ve hastalara ait demografik bilgiler kullanılmıştır. Toplamda yaklaşık bir buçuk milyon hasta verisi ile analize başlanmıştır. Sağlık verilerinde yaşanan en büyük problem verilerdeki eksik, kirlili ve gürültülü verinin fazlalığından kaynaklanmaktadır. Bu çalışmada da benzer sorunlarla karşılaşmış ancak eksik veriler hasta bazında doğrusal enterpolasyon, önceki değer, sonraki değer ve sabit değer metodları ile giderilmiştir. Veri setinde hastaların zamansal değerleri yer aldığından her bir hastaya ait değerler dönüştürülmüştür. Bunun için tek bir yöntem uygulanmamış her bir değer için minimum, maksimum, ortalama ve standart sapma değerleri hesaplanarak yerine konmuştur. Bu işlem sonrası toplamda 140 değişken ile denetimsiz öğrenme yöntemi olan FCM kümeleme algoritması ile analiz gerçekleştirilmiştir. Makine sepsis tanısı alan 2.932, sepsis tanısı olmayan 39.910 toplam 42.842 hasta verisi ile eğitilmiştir. FCM algoritmasının bulanıklık katsayısı  $m=2$  olarak belirlenmiştir. Çalışmada kurulan modelde toplam 140 değişken kullanılarak %18 temsil kaybı ile hastaların iki boyutta izlenebilmesi sağlanmıştır. Sepsis enfeksiyonu ile ilişkili birçok farklı parametre vardır ve bunlar yaşam koşullarına, genetik bilgiye ve yaşam öyküsüne bağlı olarak hastadan hastaya değişiklik gösterebilmektedir.

Analiz sonunda, model üzerinden öğrenme gerçekleştirilmiş, SP ve SN hastaların monitörize edilmesi sağlanmıştır. Bu bağlamda FCM algoritmasının oluşturduğu dört

farklı kümenin genel olarak birbirinden farklılaştığı, ancak bazı durumlarda bu ayrımın yapılmasının zor olduğu görülmektedir. Hekimlerin sepsis tanısını koymasında zorluk ya da gecikmenin de bu bulanıklıktan kaynaklanabildiği düşünülmektedir. Çalışmada FCM algoritmasının kullanılmasının nedenleri;

1. Etiketlenen veriler ışığında SP ve SN hastalarda küme merkezleri ve dağılımlarının görülebilmesi,
2. Bu dağılımı iki boyuta indirgeyerek (PCA ile), monitörde hekimin sepsis enfeksiyonuna gidecek olan hastanın örüntüsünü görüntüleyebilmesi,
3. Bu sayede yeni gelen hasta değerlerinin anlık olarak işlenmesi sayesinde (etiketsiz veri) hekimin hastanın hangi bölgeye yöneleceğini (SP, SN ya da K bölgesi) öngörebilmesi,
4. Hekim ya da sağlık personeli hastaya müdahalede bulunduğu yine hastaya özgü değerlerin anlık olarak işlenmesi sayesinde müdahalenin hastaya özgü başarısını değerlendirebilmesi,
5. Tüm bunların dışında sepsis enfeksiyonu doktorlar tarafından teşhis edilmesi zor bir hastalık olduğundan, diğer keskin sınırlara sahip kümeleme algoritmaları değil, FCM algoritması kullanılmıştır.

Bu araştırma, ölümcül bir enfeksiyon olan ve Dünya Sağlık Örgütü tarafından iyi araştırılan sepsis hastalığına dayalı bir makine öğrenme modeli olması açısından ülkemize katkı sağlamayı amaçlamaktadır. Çalışma yapay zeka algoritmaları kullanılarak hekimlerin karar verme süreçlerinin etkinlik ve verimliliğini de artırmayı amaçlamaktadır. Araştırma, hastanın birçok farklı cihaz, laboratuvar ve demografik parametresinin değerlendirilerek denetimsiz öğrenme gerçekleştirmiş olması ve modelin görselleştirilmesi sayesinde SP ve SN alanının tespitinin yapılmış olması sayesinde hastaların izlenerek hangi bölgeye doğru bir eğilimde olduklarını görebilme açısından önem taşımaktadır. Dijitalleşen sağlık verilerini kullanarak öğrenen sistemlerin modellenmesi, hekimlere ve sağlık personellerine kanıta dayalı önermelerde bulunan sistemlerin geliştirilmesi hekim performansını artıracak, hata oranını düşürecek, karar ve aksiyon süresini kısaltacak, hasta ölümlerini azaltacak ve bu sayede operasyonel ve stratejik anlamda verilen kararların verimliliğini

artıracağı düşünülmektedir. Ayrıca bu model sağlık merkezlerinde YBÜ haricinde farklı klinikler ya da farklı hastalıklar özelinde uygulanarak yaygınlaştırılması dijital izlem ve yapay zeka teknolojilerinin daha hızlı entegrasyonuna katkı sağlayacağı da savunulmaktadır.

## **4.7.Uygulama2: Uzun Kısa Süreli Bellek (LSTM) Algoritması ile Sepsis Enfeksiyonu Tahmini**

### **4.7.1. Araştırmanın Amacı**

Sepsis, yüksek insidans ve ölüm oranları ile dünya çapında zorlu sağlık sorunlarının başında gelmektedir Sepsisin önlenmesinin, geri dönüşü olmayan organ yetmezliğinden kaçınmanın anahtarı olduğu belirtilmiştir (Ramírez, 2013). Sepsis diğer sağlık sorunları ile benzer belirti ve semptomları taşıdığından, sepsisin veriye dayalı erken teşhisi hekim açısından zor olabilmektedir. Bu nedenler temelinde çalışmanın öncelikli amaçlarından biri, hayati derecede önem taşıyan sepsis enfeksiyonunun hastada gelişimini önceden öngörebilmek ve bu öngörüü saatler öncesinde hekim ya da sağlık personeline bildirerek hastaya erken müdahale edilmesini sağlamaktır. Bu kapsamda MIMIC-III 2001 ve 2012 yılları arasında Beth Israel Deaconess Tıp Merkezi'nin yoğun bakım ünitelerinde kalan 40.000'den fazla gerçek hastaya ilişkin, kimlik bilgileri şifrelenmiş verileri içeren geniş bir veri tabanı kullanılmıştır (Johnson, vd., 2016). Postgresql üzerine kurularak çalıştırılan MIMIC-III klinik veri tabanında sorgular gerçekleştirilerek çalışılacak olan tablolar ile veri ambarı kurulmuştur. Sepsis araştırmaları özelinde kurulan veri ambarı hem statik hem de dinamik verileri içermektedir. Statik veriler, hasta kaydı başına bir kez toplanan ve hastanın demografik verilerini içermektedir. Dinamik veriler, hastaların tüm yatış süresi boyunca düzensiz aralıklarla birden çok kez toplanan ve her kayıtla ilişkili bir

zaman damgasına sahiptir; dolayısıyla dinamik veriler bir zaman dizisi olarak ifade edilebilmektedir. Veri ambarı 6 statik, 34 dinamik değişken içermektedir. Sepsis enfeksiyonunun erken tahminlenmesi amacıyla zaman serisi formatında bulunan klinik verilere LSTM tabanlı derin öğrenme modeli uygulanmıştır. Uçtan uca veri analizinin gerçekleştirildiği bu çalışmada farklı klinik veri kaynakları kullanan model, saatlik girdi verisi olarak bir sonraki saat içinde septik şok geliştirip geliştirmeyeceğini tahmin etmeyi amaçlamaktadır. Sonuç olarak büyük verinin sağlık alanında kullanımının yaygınlaşması ve geliştirilen modeli kullanan YBÜ’nde mortalitenin en aza indirgenmesi amaçlanmaktadır.

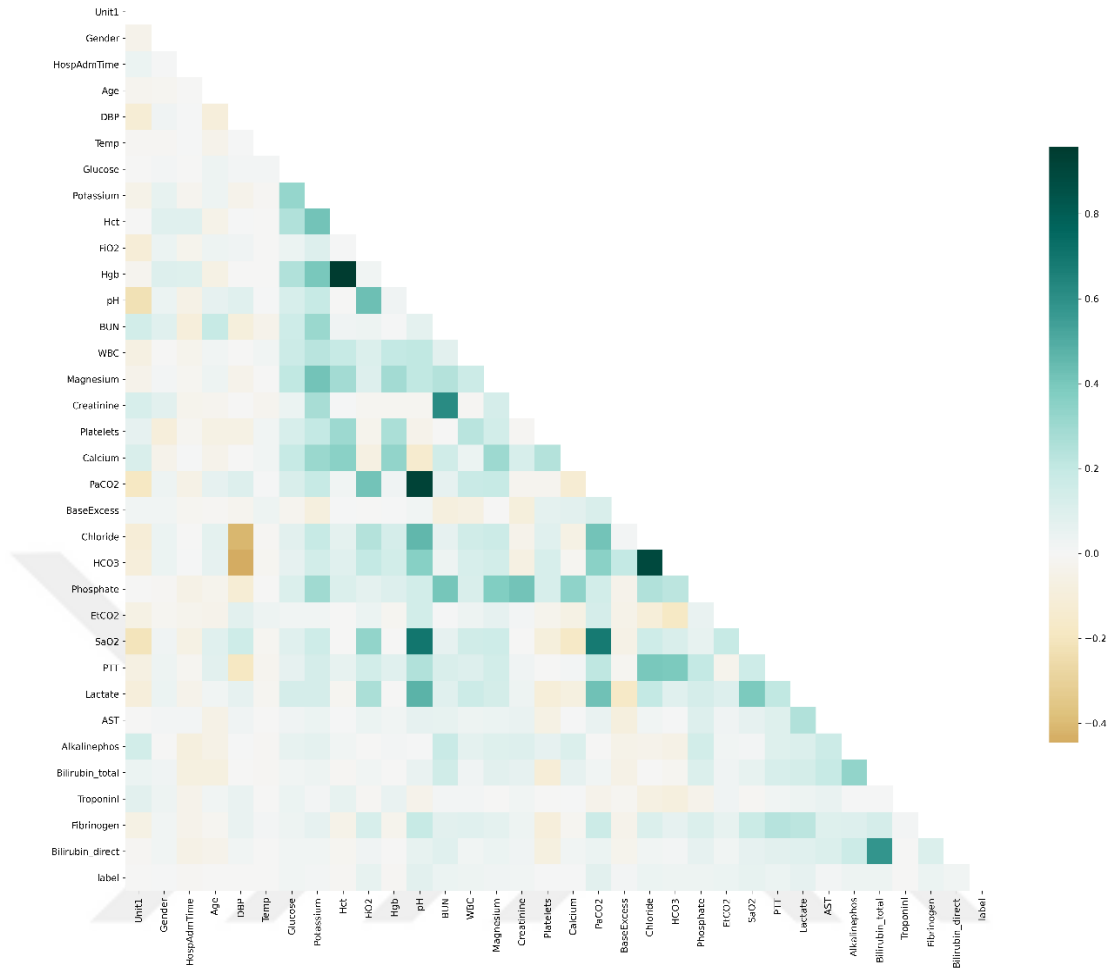
#### 4.7.2. Zaman Serisi Veri Ön İşlemleri

Sepsis enfeksiyonu kapsamında hazırlanan veri ambarındaki örneklerde eksik ve gürültülü veriler bulunmaktadır. Derin sinir ağı tabanlı yaklaşımlar, zaman serilerindeki eksik değerleri ve zaman düzensizliklerini ele almayı gerektirmektedir. Bu nedenle araştırmada her değişken için eksik veri oranı incelenmiş (Şekil 27), demografik verilerde eksik veri bulunmazken en fazla eksik verinin laboratuvar verilerinde (dinamik verilerde) olduğu gözlemlenmiştir. Eksik verilerin giderilme sürecinde her bir hasta kendi içinde değerlendirilerek doğrusal enterpolasyon yöntemi ile eksik veriler giderilmiştir. Daha sonra veri seti içinde eksik veri mevcut ise önceki değer, sonraki değer ve sabit değer yöntemleri ile eksik verilerin giderilme süreci tamamlanmıştır. Son aşamada veri setinde hasta değerlerine ait eksik veri kalmamıştır. Bu süreç tez kapsamında yapılan her iki araştırma için ortak olarak yürütülmüştür. Veri setinde toplam 1.524.924 değer bulunmaktadır. Ancak bunlar hastalara ait zaman serisi formatında bulunan çoklu hasta verileridir. Veri seti içinde benzersiz 39.910 SN, 2932 SP hasta değeri bulunmaktadır. Burada gözlemlenen veri dengesizliği LSTM modeli içinde giderilmek üzere veri ön işlemlerine devam edilmiştir.

Makine öğrenmesi algoritmaları, sorunsuz ve düzgün çalışması için belirli özelliklere sahip değişkenlere ihtiyaç duymaktadırlar. Bu aşamada, modele yönelik olarak özellik mühendisliği (feature engineering) süreci ele alınmıştır. Özellik mühendisliği, makine öğrenmesi algoritmalarının gereksinimleriyle uyumlu, uygun veri kümesinin

hazırlanması ve makine öğrenmesi modelinin performansını iyileştirilmesi amacıyla gerçekleştirilmektedir. Bu kapsamda araştırmaya konu olan veri seti eksik verilerin giderilmesi sonrası vital bulgu değerleri (cihaz verileri) ve laboratuvar test sonuçları min-maks normalizasyon yöntemi ile  $[0,1]$  değer aralığında normalleştirilmiştir. Hastanın cihaz (hayati) değerleri sürekli üretildiğinden bu sürekli veriler 10 saatlik zaman dilimi ile matrise çevrilerek yeni bir değişken adı altında tutulmuştur. Çalışmada 10 saatlik zaman diliminin kullanılmasının nedeni, hastaların ortak zaman paydasının 10 saat olmasından kaynaklanmaktadır. Bazı hastaların 100 saatlik verisi bulunmakta iken bazı hastaların 40, bazılarının ise 10 saatlik verisi elde edilmiştir. Çalışmada amaç en uzak zaman diliminde hastanın sepsis olup olmayacağını tespit edebilmektir. Bu nedenle ortak en uzak zaman dilimi 10 saat olduğu için 11. saatte sepsis enfeksiyonunun tahminlenmesi üzerine çalışılmıştır.

Değişkenler içinde gereksiz özniteliklerin olması; modelin eğitim süresini artırması, modelin yorumlanabilirliğini azaltması ve aşırı öğrenmeye neden olarak model başarısını yüksek göstermesi gibi olumsuz durumları doğurabilmektedir. Bu durumu en iyi açıklayan Basitlik Yasasına (Parsimony yasası) göre, *“bir problemin en iyi açıklaması, mümkün olan en az varsayımı içerendir”* (Occam’s razor). Bu nedenle özellik seçimi süreci yapay zeka modellemelerinin önemli bir adımı haline gelmiştir. Çalışmada, derin öğrenme modeline geçilmeden önce özellik seçimi için değişkenler arasındaki korelasyon değerlendirilmiş, yüksek oranda birbirleri ile ilişkili olan değişken/değişkenlerin veri setinden çıkarılması amaçlanmıştır (Şekil 36).



Şekil 36. Değişkenler arası korelasyon ısı haritası

Isı haritası ile ifade edilen özellik seçimi sürecinde %95 ve üzeri korelasyon gösteren değişkenler veri setinden ayıklanması hedeflenmiş, bu nedenle Hemoglobın (Hgb) ile Hematokrit (Hct) değişkenleri arasındaki 0.98 korelasyon değeri nedeniyle Hct değişkeni veri setinden çıkarılmıştır.


#### 4.8.LSTM Tabanlı Derin Öğrenme Algoritması

LSTM, uzun süreli bağımlılıkları öğrenebilen ve tekrarlayan bir sinir ağı türüdür. Hochreiter ve Schmidhuber (1997) “uzun süreli bağımlılıkları” ele almak için uzun kısa süreli bellek (LSTM) önermiş ve sonraki çalışmalarda birçok kişi tarafından geliştirilmesi sonucu popüler hale gelmiştir (Medsker ve Jain, 1999; Hochreiter ve Schmidhuber, 1997). LSTM ağları, standart birimlere ek olarak özel birimler kullanan



tekrarlayan bir sinir ağı türü özelliğindedir. LSTM birimleri, bilgileri uzun süre bellekte tutabilen bir “bellek hücresi” içermektedir. Bu bellek hücresi, daha uzun vadeli bağımlılıkların öğrenilmesine yardımcı olmaktadır (Yu vd., 2019).

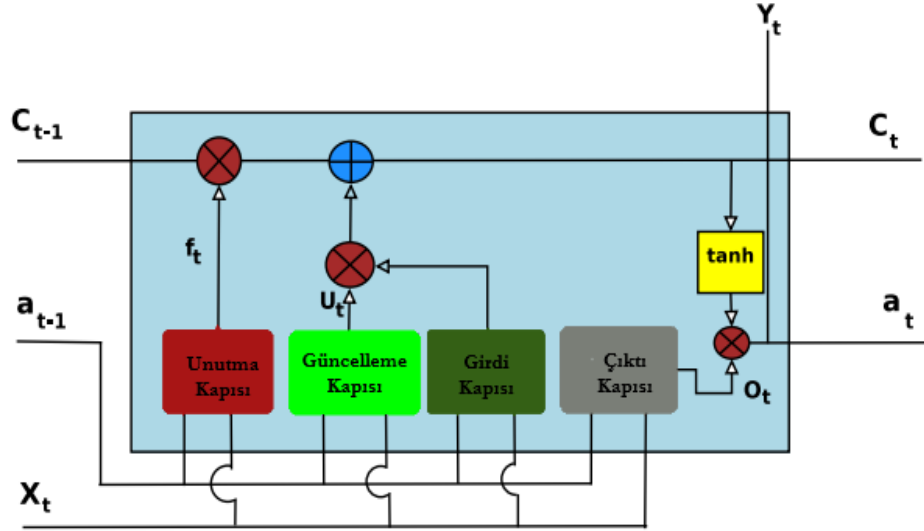
Tekrarlayan sinir ağları, kaybolan gradyan problemi nedeniyle uzun vadeli bağımlılıkları öğrenemediklerinden LSTM’in bellek hücresine sahip olması bu algoritmanın önem kazanmasına neden olmuştur. Tekrarlayan sinir ağlarına dayalı neredeyse tüm heyecan verici sonuçlar LSTM tarafından elde edilmiş ve bu nedenle de derin öğrenmenin odak noktası haline gelmiştir. Güçlü öğrenme kapasiteleri nedeniyle, LSTM'ler son derece iyi çalışmakta ve konuşma tanıma (He ve Droppo, 2016; Hsu vd., 2016), akustik modelleme (Sak vd., 2014; Qu vd., 2017), yörünge tahmini (Althé ve Fortelle, 2017), cümle yerleştirme (Palangi vd., 2015) ve korelasyon analizi (Mallinar ve Rosset, 2018) gibi birçok farklı alanda kullanılmıştır. LSTM hücrelerinin çalışma mantığı incelendiğinde, başlangıçta durum bilgisi modundadır, yani bir serideki her numunenin son durumu, serideki bir sonraki numune için başlangıç durumu olarak kullanılmaktadır. Yoğun (dense), tamamen bağlı bir katmandır, yani bu katmandaki her nöron, önceki katmandaki her LSTM hücresinden girdi almakta ve tek bir çıktı sağlamaktadır. Şekil 37, tek bir LSTM gizli katmanından ve yoğun katmandan oluşan model mimarisini ifade etmektedir.



*Şekil 37: Tahmin için LSTM Model Mimarisi*

Veri ön işleme aşamasında tek boyutlu zaman serisi elektrokardiyografi verileri (EKG) [5, 1, 9, 7, 8, z] incelendiğinde, burada z, tahmin edilmesi gereken eksik bir örnek olduğu görülmektedir. Bunu tahmin etmek için önce LSTM modeli, eğitim verileri kullanılarak eğitilmektedir. Verilen EKG verileri denetimli forma dönüştürülmekte yani [5, 1, 9, 7] ve [1, 9, 7, 8], burada {5, 1, 9} ve {1, 9, 7} pencere 3 boyutundaki eğitim verileri, {7} ve {8} sırasıyla karşılık gelen etiketler olmaktadır. Test aşamasında,

eđitilmiş LSTM modeline [9, 7, 8] girdisi verilerek  $\{z\}$  tahmini yapılabilir. Burada açıklama için yalnızca bir adım (veya bir eksik deęer) tahmin edilir, ancak çoklu adımlar da benzer şekilde kullanılabilir.



Şekil 38: LSTM algoritmasının hücre mimarisi

Şekil 38’de gösterilen diyagramın üstünden geçen yatay çizgi LSTM’lerin anahtarı olan hücre durumunu ifade etmektedir (Verma ve Kumar, 2019). Hücre durumu bir tür taşıma bandı gibidir. Sadece bazı küçük doğrusal etkileşimlerle, tüm zincir boyunca çalışmaktadır. Ayrıca LSTM’de bilgi akışını düzenleyebilen ve kapı (gate) adı verilen iç mekanizmalar bulunmaktadır. Bu kapılar, bir dizide hangi verilerin tutulması veya atılmasının önemli olduğunu öğrenebilmektedir. Bunu yaparak, tahminlerde bulunmak için ilgili bilgileri uzun diziler zincirinden aşağı iletebilmektedir. LSTM, kapılar adı verilen yapılar tarafından var olan hücre durumuna bilgi ekleme veya çıkarma yeteneğine sahiptir.

Unutma Kapısı (Forget Gate), hangi bilginin tutulacağı veya unutulacağına karar vermektedir. Sigmoid aktivasyonu ile kontrol edilmektedir. Bu işlem sonucu 0 ile 1 arasında deęer üretmektedir. Sonuçta deęer 0’a yaklaşırsa bilginin unutulacağı, 1’e

yaklaşırsa bilginin tutulacağı anlamına gelmektedir. Bu işlemler unutmama kapısında ( $f_t$ ) Denklem (1) kullanılarak yapılmaktadır:

$$f_t = \sigma [w_f (a_{t-1}, X_t) + b_f] \quad (1)$$

burada  $a_{t-1}$ ,  $X_t$ ,  $b_f$ ,  $\sigma[\cdot]$  ve  $w_f$  sırasıyla önceki çıktı, mevcut girdi, sapma, sigmoid aktivasyon fonksiyonu ve unutmama kapısındaki ağırlık matrisidir.

Girdi kapısı ( $i_t$ ), hücre durumunda saklanması gereken yeni bilgilere karar verme görevini üstlenmiştir. Bir tanh etkinleştirme işlevi kullanmakta ve güncelleme kapısı tarafından kontrol edilmektedir (Yu vd., 2019).

$$i_t = \tanh [w_i (a_{t-1}, X_t) + b_i] \quad (2)$$

Denklem 2'de  $b_i$  ve  $w_i$ , giriş kapısındaki sapma ve ağırlık matrisidir.

Güncelleme kapısı ( $u_t$ ), girdi kapısı tarafından saklanacak yeni bilgilere karar vermekte ve sigmoid aktivasyon fonksiyonunu kullanmaktadır.

$$u_t = \sigma [W_u (a_{t-1}, X_t) + b_u] \quad (3)$$

Denklem 3'te  $b_u$  ve  $W_u$ , sırasıyla güncelleme kapısındaki sapma ve ağırlık matrisidir.

$$c_t = u_t * i_t + f_t * c_{t-1} \quad (4)$$

Çıktı kapısı ( $o_t$ ), nihai bilgiye karar vermekte ve sigmoid aktivasyon fonksiyonu tarafından kontrol edilmektedir.

$$o_t = \sigma [W_o (a_{t-1}, X_t) + b_o] \quad (5)$$

$$a_t = o_t * \tanh(c_t) \quad (6)$$

Çıktı kapısında yapılan işlemlerde Denklem 5 ve 6 da ifade edilen  $a_t$ ,  $W_o$  ve  $b_o$  sırasıyla mevcut çıktı, ağırlık matrisi ve sapmayı temsil etmektedir (Verma ve Kumar, 2019).

#### **4.8.1. Yapay Zeka Algoritmalarında Model Performansının Değerlendirilmesi**

Makine öğrenmesi sürecinde en önemli adımlardan biri modelin performans ölçümünün yapılarak kullanılan algoritmanın başarısının ölçülmesidir. Makine öğrenmesi modeli oluşturulduğunda, bir modelin kalitesini veya performansını kontrol etmek için çeşitli değerlendirme ölçütleri kullanılmaktadır. Sınıflandırma modelleri için Doğruluk, Karışıklık Matrisi, Kesinlik, Geri Çağırma, F1 puanı ve AUC-ROC eğrisi gibi metrikler bulunmaktadır. Regresyon modellerinde ise RMSE, MAE, MAPE, MSE gibi metrikler kullanılmaktadır (Merghadi vd., 2020).

Karışıklık matrisi (confusion matrix), bir sınıflandırma (ayrıt edici) kuralının özelliklerinin göstergesi olarak kullanılmaktadır. Her sınıf için doğru veya yanlış sınıflandırılmış öğelerin sayısını içermektedir. Karışıklık matrisi, sistemin iki sınıfı karıştırıp karıştırmadığının (yani, genellikle birini diğeriyle yanlış etiketleme) anlaşılmasını sağlamaktadır. Test setindeki her örnek için, gerçek sınıfı, eğitilmiş sınıflandırıcı tarafından atanan sınıfla karşılaştırma imkanı sunmaktadır. Sınıflandırıcı tarafından doğru bir şekilde sınıflandırılan pozitif/negatif bir örneğe TP (gerçek negatif) denir; yanlış sınıflandırılmış bir pozitif/negatif örneğe FN (yanlış negatif) denmektedir. Örneğin, belirli laboratuvar testlerinin sonuçlarına dayanarak bir hastanın kanser olup olmadığını belirlemek için hangi sınıflandırıcıların en iyi olacağı belirlenmek istendiğinde dört olası sonuç vardır. Hasta kanserliyse ve sınıflandırıcıya göre kanser teşhisi konulursa, gerçek bir pozitif olarak kabul edilmekte; hasta sınıflandırıcı tarafından sağlıklı olarak beyan edilirse, ancak gerçekte kanser varsa, yanlış negatif olarak kabul edilmektedir. Hastanın kanseri yoksa ve sağlıklı ilan

edilirse, gerçek bir negatif olarak kabul edilir; gerçekten sağlıklıyken kanser teşhisi konulursa, yanlış pozitif olarak kabul edilmektedir (Jordan, 2017).

Tablo 8. Karışıklık matrisi

	Tahmin Edilen Değerler		
Gerçek Değerler		Pozitif	Negatif
	Pozitif	TP	FN
	Negatif	FP	TN

Metriklerin hesaplanmasında kullanılan TP: Doğru Pozitif, TN: Doğru Negatif, FP: Yanlış Pozitif, FN: Yanlış Negatif şeklinde değerlendirilmektedir (Tablo 8). Bir karışıklık matrisi, sınıflandırma modelinin performansını değerlendirmek için kullanılan  $N \times N$  bir matristir; burada  $N$ , hedef sınıfların sayısı olmaktadır. Matris, gerçek hedef değerleri makine öğrenmesi modeli tarafından tahmin edilen değerlerle karşılaştırılmaktadır. Bu, sınıflandırma modelinin ne kadar iyi performans gösterdiğine ve ne tür hatalar yapıldığına dair bütünsel bir görüş sağlamaktadır. Karışıklık matrisi, gerçek sınıflandırma ve yanlış sınıflandırma oranlarının tahminlerini vermektedir. Bunlar tahminlerdir ve yanlış olabilirler, ancak yeterince büyük bir veri seti var ise ve her iki sınıf dağılımı da dengeli ise, tahminlerin güvenilir olacağı ifade edilmektedir (Godbole, 2002).

- Doğruluk: Herhangi bir tahmin modeli için ikili karar problemleriyle uğraşırken ana değerlendirme parametresi olarak hareket etmektedir. Herhangi bir sınıflandırma modeli için, tüm olası örnekler arasında doğru tahmin edilen örneklerin sayısının ölçülmesidir. Doğru tahmin edilen örneklerin mevcut örneklerin toplam sayısına oranı olarak ifade edilmektedir. Yüksek düzeyde dengesiz veri bulunan durumlarda, azınlık ve çoğunluk sınıfının doğruluklarının geometrik ortalamasını dikkate almanın, yaygın doğrulukla karşılaştırıldığında daha etkili bir sınıflandırma yöntemi olduğu öne sürülmüştür (Du vd., 2017).

$$\text{Doğruluk (Accuracy)} = \frac{TP + TN}{TP + TN + FP + FN}$$

- Duyarlılık: Bir model tarafından doğru tahmin edilen olaylardan kaçının gerçekte pozitif olduğunu gösteren ifadedir. Gerçek pozitiflerin ne kadarı doğru bir şekilde tanımlanmıştır sorunun cevabını veren metrik duyarlılıktır. Duyarlılık mümkün olduğunca yüksek olmalıdır.

$$\text{Duyarlılık (Recall)} = \frac{TP}{TP + FN}$$

- Kesinlik: Modelin pozitif değerleri doğru bir şekilde sınıflandırma yeteneğini hesaplamak için kullanılmaktadır. Gerçek pozitiflerin, tahmin edilen pozitif değerlerin toplam sayısına bölümü ile hesaplanmaktadır.

$$\text{Kesinlik (Precision)} = \frac{TP}{TP + FP}$$

- F-Skor: Kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır. Bu sayede iki ölçüm hakkında kombine bir fikir vermeyi amaçlamaktadır (Han vd., 2012;366); (“Confusion Matrix in Machine Learning”, y.y.).

$$\text{F-Skor (F-Measure)} = \frac{2 * \text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}}$$

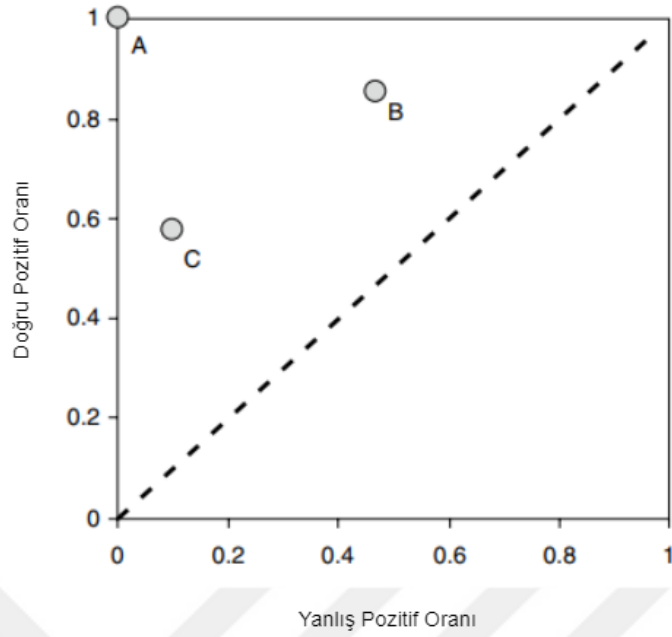
ROC–AUC Eğrisi, makine öğrenmesinde kullanılan bir diğer performans ölçüm metriğidir. Doğru pozitif ile yanlış pozitif oranları arasındaki dengeyi gösteren ROC eğrileridir (Provost ve Fawcett, 1998). Alıcı işletim karakteristiği (ROC) terimi, II. Dünya Savaşı sırasında radar kullanımında tespit doğruluğunu değerlendirmek için standart bir sisteme duyulan ihtiyaç ile ortaya çıkmıştır. ROC analizi, bir sinyal alıcısının ilgili nesnelere sistemdeki arka plan gürültüsünden doğru bir şekilde ayırtma yeteneğini ölçmek için standart bir metodoloji olarak geliştirilmiştir. ROC eğrisi ilk olarak sinyal algılama teorisinde isabet oranları ile yanlış alarm oranları arasındaki dengeyi temsil etmek için kullanılmıştır (Egan, vd., 1975:118). Bu performans metriği

1970'lerden beri tıbbi tanıda kapsamlı bir şekilde çalışılmış ve uygulanmıştır (Huang ve Ling, 2005). Son yıllarda, makine öğrenmesinde ROC hakkında kapsamlı araştırmalar yapılmaktadır (Bowers vd., 2019; Krupinski, 2021). ROC eğrisinin altında kalan alan AUC, ROC eğrilerinin performansı için iyi bir özet sağlamaktadır. ROC eğrisi iki parametre ekseninde üretilmektedir (Developers, y.y.):

$$\text{Doğru Pozitif Oranı} = \frac{TP}{TP + FN}$$

$$\text{Yanlış Pozitif Oranı} = \frac{FP}{FP + TN}$$

Şekil 39'da X ekseninin yanlış pozitif oranı ve Y ekseninin doğru pozitif oranı temsil ettiği bir ROC eğrisi gösterilmektedir. ROC eğrisindeki ideal nokta (0,100), tüm pozitif örneklerin doğru şekilde sınıflandırıldığı ve hiçbir negatif örneğin yanlış pozitif olarak sınıflandırılmadığı A noktasıdır. Eğrinin altındaki alan (AUC) bir parametrenin, örneğin kanserin meydana gelip gelmediğini ne kadar iyi ayırt edebileceğinin bir ölçüsüdür. AUC ne kadar yüksek olursa, model o kadar başarılıdır (örn: hastalığı olan ve olmayan hastaları ayırt etmede o kadar iyidir). AUC değeri 0 ile 1 arasındadır. 0,5'in altındaki AUC, başarısız bir test modelini göstermektedir. Mükemmel bir testin alanı 1.00'dir. Bu durum sıfır yanlış pozitif ve sıfır yanlış negatifi ifade etmektedir (Maimon vd., 2014:39).



Şekil 39. ROC eğrisi.

*A Noktası mükemmel performansı temsil eder. C'nin performansı ise B'den daha iyidir.*

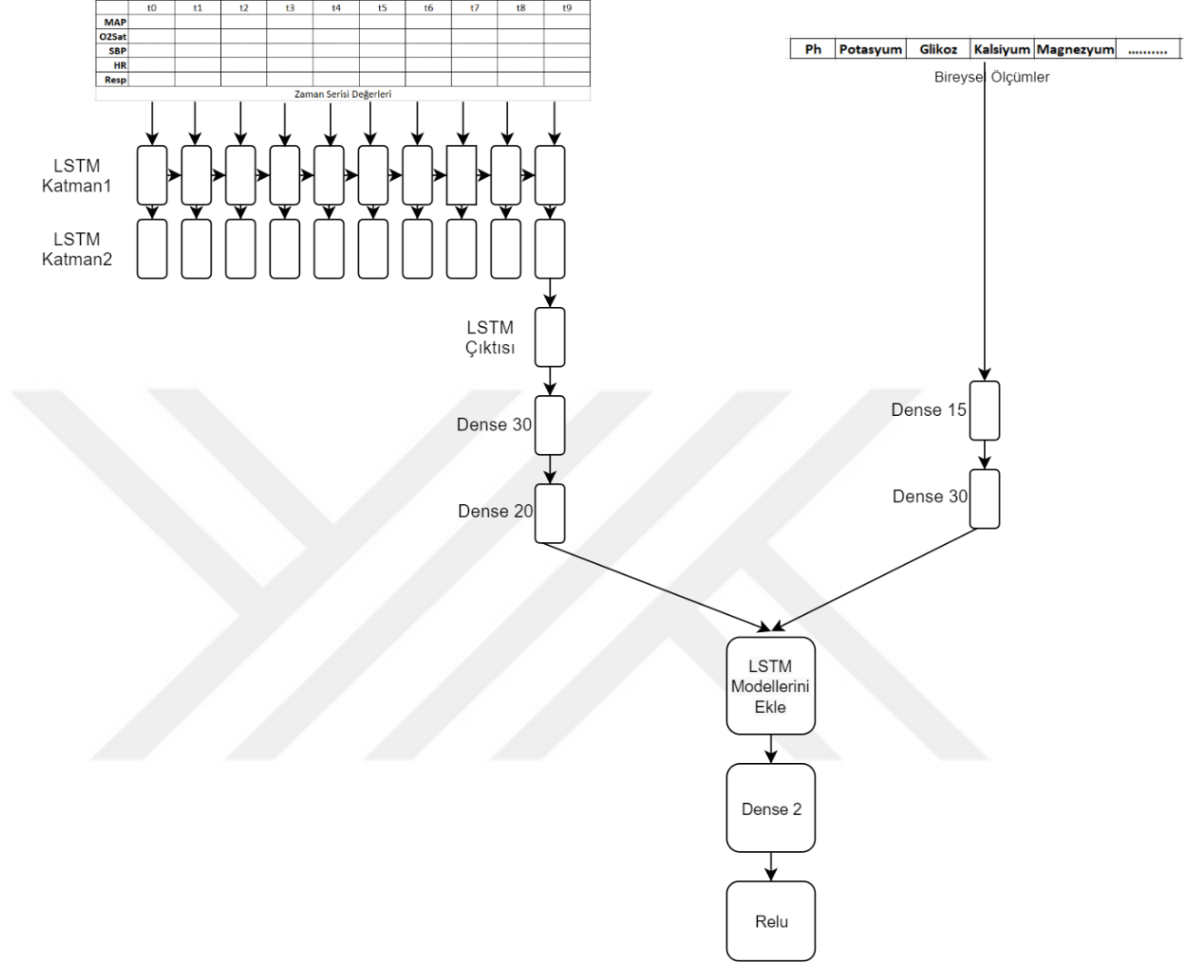
ROC eğrisindeki her nokta belirli bir karar eşiğine karşılık gelen bir duyarlılık / özgüllük çifti temsil etmektedir. Mükemmel ayrımcılıkla (iki dağılımda çakışma olmaz) yapılan bir test, sol üst köşeden geçen bir ROC eğrisine sahip olmaktadır (%100 hassasiyet, %100 özgüllük). Bu nedenle, ROC eğrisinin sol üst köşeye yaklaştıkça, testin genel doğruluğu artmaktadır (Şekil 39.) (Alther ve Reddy, 2015:57).

#### 4.9. LSTM Model Mimarisi ve Bulgular

Python'da keras, tensorflow, scikit-neural network, pytorch, pybrain kütüphaneleri LSTM modeli oluşturmak için kullanılabilir. Tez kapsamında geliştirilen LSTM ağ modeli, Anaconda Python Notebook üzerinde geliştirilmiş, tensorflow üzerinde çalışan keras kütüphanesinden faydalanılmıştır. Tüm veri seti eğitim, test ve doğrulama olmak üzere üç bölüme ayrılmıştır. Eğitim setinin rastgele ayrılmış olan %20'lik dilimi doğrulama verisi olarak ayrılmıştır. Çalışmada iki ayrı veri kategorisi bulunmaktadır: zaman serisi verileri (on dizi uzunluğunda) ve tek ölçümler (laboratuvar verileri ve demografik veriler). Tek ölçüm verileri basit bir ağ iken, zaman serisi verilerinin yapısı tekrarlayan bir sinir ağı yapısındadır. Bu nedenle, iki farklı LSTM



modeli eğitilmiş ve ardından tek bir çıktıda birleştirilmiştir. Kurgulanan LSTM modelinin işleyişi Şekil 40'ta gösterilmiştir.



Şekil 40. LSTM modeli

Cihaz verilerinde, çift yönlü yani bidirectional LSTM (BiLSTM) kullanılmıştır. Çift yönlü LSTM, ağda tekrarlayan ilk katmanın çoğaltılmasını, böylece yan yana iki katman olmasını, ardından girdi dizisini birinci katmana girdi olarak olduğu gibi sağlamayı ve ikinciye girdi dizisinin ters bir kopyasını sağlamayı içermektedir. Tek yönlü LSTM, gördüğü girdiler geçmişten olduğu için yalnızca geçmişin bilgilerini kullanabilmektedir. BiLSTM ise, girdilerin birini geçmişten geleceğe ve diğerini gelecekte geçmişe aktaracak şekilde çalışmaktadır. Bu yaklaşımı tek yönlüden farklı kılan, geriye doğru çalışan LSTM'de gelecekte gelen bilgileri korumak ve iki gizli

durumu bir araya getirebilme yeteneğidir. BiLSTM'ler, ağ için mevcut olan bilgi miktarını etkili bir şekilde arttırmakta, algoritma için mevcut olan bağlamın iyileşmesini sağlamaktadır (Conegruta vd. , 2016). Tek ölçümlü hasta verileri için ise basit LSTM modeli kurgulanmıştır:

```
model_vit = Bidirectional(LSTM(100, return_sequences=True))(input1)
model_vit = Bidirectional(LSTM(75))(model1)
model_vit = Dense(35, activation='relu')(model1)
model_vit = BatchNormalization()(model1)
model_vit = Dense(15, activation='relu')(model1)
model_lab = Dense(30, activation='relu')(model2)
model_lab = BatchNormalization()(model2)
model_lab = Dense(15, activation='relu')(model2)
```

Tüm kurulan modeller için aktivasyon fonksiyonu olarak “relu” kullanılmıştır. Relu aktivasyon fonksiyonunun seçilmesinin nedeni, şu sıralar tüm evrişimli sinir ağlarda ve derin ağlarda sıkça kullanılan popüler bir fonksiyon olmasıdır. Relu doğrusal olmayan bir fonksiyondur, yapay sinir ağları bağlamında, argümanının pozitif kısmı olarak tanımlanan bir aktivasyon fonksiyonudur:  $f(x)=\max(0, x)$ , (x nöronun girdisi). Modeli eğitmeden önce, kurgulanan her iki LSTM modeli tek bir model olarak birleştirilmiştir:

```
model_add = Add()(model_vit, model_lab)
output = Dense(2, kernel_regularizer=l2(0.001), activation='relu')(model_add)
```

Modelin eğitilmesi adımında dengesiz veri sorunu ele alınmıştır. Dengesiz bir dağılıma sahip olan veride (SP: 2932, SN:39.910) bu durum, modelin öğrenme sürecini ve tahmin başarısını etkileyecektir. Bu nedenle modeli eğitim verisine uygularken “class\_weight” parametresi yardımıyla sınıf dengesizliği sorunu giderilmiştir. Bu parametre yardımıyla (SP:SN oranı 1:53), azınlık sınıfına atanan ağırlık dengesizlik oranında arttırılarak, algoritmanın azınlık verisinin yanlış sınıflandırmasından kaynaklanan hata oranı azaltılmıştır. Dolayısıyla, modeli

oluştururken genel hata oranı (overall error rate) azaltılmaya çalışılmış, yani azınlık sınıfı dikkate alınarak performansın artması sağlanmıştır.

LSTM derin öğrenme algoritmasında kullanılan hiper parametreler nöron sayısı, aktivasyon fonksiyonu, optimizör, öğrenme hızı (learning rate), döngü sayısı (epoch) ve parti sayısı (batch\_size)dir. Döngü (Epoch) sayısı, eğitim esnasında tüm eğitim verilerinin ağı gösterilme sayısını ifade etmektedir. Eğitimin doğruluğu artsa dahi, doğrulama (validation) azalmaya başlayana kadar epoch sayısı azaltılmıştır. Parti boyutu (batch size), modelin dahili parametreleri güncellenmeden önce üzerinde çalışılacak eğitim örneklerinin sayısını kontrol eden hiper parametredir. Öğrenme oranı (learning rate) 0,1 olarak ayarlanmıştır. Araştırmalarda, daha küçük bir öğrenme oranı (0,01) eğitim süresini artırmakta ve hesaplama maliyetini yükselttiği görüldüğünden oran minimumda tutulmuştur. 0,3'ten büyük olan öğrenme oranı ise hızlı ancak optimal olmayan bir çözüme ulaşma eğilimi göstermektedir. Doğrulama ve test veri kümelerinde düşük performansa neden olmaktadır. Çalışmada, eğitim süresince hiper parametrelerde gerekli ayarlamalar yapılmıştır.

```
model_train = model.fit([X_train_cont, X_train_cat],
                        y_train,
                        batch_size=32,
                        epochs=20,
                        validation_data=(X_val_cont, X_val_cat), y_val),
                        class_weight=class_weights,
                        verbose=1)
```

Derin öğrenme LSTM ağı çalışması, saatlik yaşamsal verilerin, laboratuvar ve statik hasta tanımlarının bir kombinasyonundan oluşan veri seti ile yapılmıştır. Çalışma toplam 40 klinik değişken içeren yaklaşık 1,5 milyon hasta kaydı ile gerçekleştirilmiştir. Veri ön işlemleri kapsamında eksik veriler doğrusal enterpolasyon, önceki ve sonraki değer, sabit değer kullanılarak giderilmiştir. Özellik mühendisliği kapsamında ise değişkenler arasındaki korelasyon incelenmiş ve yüksek oranda birbirleri ile ilişkili olan (Hgb) ile Hematokrit (Hct) değişkenleri arasında yüksek korelasyon (0.98) görülmüştür. Burada bir değişken diğeri ile açıklanabildiğinden Hct değişkeni veri setinden çıkarılmıştır.

Veri ön işlemleri ve özellik çıkarımı sonrasında, kısa süreli belleğe çözüm olarak geliştirilen LSTM derin ağ yapısı analizi gerçekleştirilmiştir. LSTM algoritmasının zaman serilerinde geçmişe yönelik verileri hafızasında tutma yeteneğinden yararlanılarak hastalar 10 saatlik zaman dilimleri içinde değerlendirilmiş ve hastanın 11. saat içinde sepsis olup olmayacağına dair tahminlenmesi gerçekleştirilmiştir. Bu amaçla her bir hasta kendi içinde 10 saatlik dilimlere ayrılmış ve bu dizi formunda veri setinin içinde analize katılmıştır. Saatlik veri üretimi cihazlar üzerinden gerçekleştirildiğinden cihaz verileri için çift yönlü LSTM modeli geliştirilmiş, tek ölçümlü hasta verileri için ise tek yönlü LSTM modeli kurgulanmıştır (Şekil 40). Sonrasında bu iki model birleştirilmiştir.

```
model = Model(inputs=[input1, input2], outputs=output)
model.compile(optimizer='adam')
print(model.summary())
```

Layer (type)	Output Shape	Param #	Connected to
input_11 (InputLayer)	[(None, 10, 5)]	0	
bidirectional_10 (Bidirectional)	(None, 10, 200)	84800	input_11[0][0]
input_12 (InputLayer)	[(None, 33)]	0	
bidirectional_11 (Bidirectional)	(None, 150)	165600	bidirectional_10[0][0]
masking_5 (Masking)	(None, 33)	0	input_12[0][0]
dense_23 (Dense)	(None, 35)	5285	bidirectional_11[0][0]
dense_25 (Dense)	(None, 30)	1020	masking_5[0][0]
batch_normalization_20 (Batch Normalization)	(None, 35)	140	dense_23[0][0]
batch_normalization_22 (Batch Normalization)	(None, 30)	120	dense_25[0][0]
dense_24 (Dense)	(None, 15)	540	batch_normalization_20[0][0]
dense_26 (Dense)	(None, 15)	465	batch_normalization_22[0][0]
batch_normalization_21 (Batch Normalization)	(None, 15)	60	dense_24[0][0]
batch_normalization_23 (Batch Normalization)	(None, 15)	60	dense_26[0][0]
add_5 (Add)	(None, 15)	0	batch_normalization_21[0][0] batch_normalization_23[0][0]
dense_27 (Dense)	(None, 2)	32	add_5[0][0]

Total params: 258,122  
Trainable params: 257,932  
Non-trainable params: 190


Şekil 41. LSTM model çıktısı

Modelin eğitim aşamasında kullanılan hiperparametreler Tablo 9’da gösterilmiştir. Modelin eğitim sürecinde optimal hiperparametre ayarlamaları yapılmış, model performansının en başarılı olduğu durumda parametreler belirlenmiştir.

Tablo 9. LSTM ağında eğitim parametreleri


Parametre	Değer
Epochs	20
Batch Size	32
Seq_size	10
Learning Rate	0,01
Optimizer	Adam
Class_weights	1:52

LSTM modelinin değerlendirilmesinde hem test hem de doğrulama setleri için grafiklerinden yararlanılmıştır. ROC eğrisi, ikili sınıflandırma problemleri için bir değerlendirme metriği olması ve temelde "sinyali" "gürültüden" ayıran bir olasılık eğrisi olması nedeniyle hastanın sepsis olup olmayacağını tahmin eden modelin değerlendirilmesinde kullanılmıştır. Bu amaçla test veri setinde model başarısı değerlendirilmiş ve AUC değeri 0,77 olarak elde edilmiştir (Şekil 42). AUC değerinin 1’e yakın olması modelin başarılı olduğunu ifade etmektedir.



Şekil 42. Test veri seti ROC- AUC eğrisi

Veri seti içinde doğrulama verisi olarak ayrılan ve eğitilen modelin daha önce göremediği verileri, ilk kez görerek tahminlenme yeteneğinin ölçüldüğü verilerde başarı %82 olarak elde edilmiştir (Şekil 43). Model, YBÜ'ne yeni gelen bir hastanın 11. saatte sepsis olup olmayacağını %82 başarı ile tahmin edebilecektir.



Şekil 43. Doğrulama veri seti ROC- AUC eğrisi

#### 4.9.1. Sonuç

Kritik bir hastalık olan sepsis enfeksiyonu, doktor teşhis koyana kadar organ yetmezliğine neden olan bir hastalık olduğundan, teşhisin önceden konulabilmesi birincil önem taşımaktadır. Sepsisin mevcut yönetimi büyük ölçüde antibiyotik kullanımına dayanmaktadır; bir hasta kabul edildiğinde, antibiyotik kullanımını başlatmak için aerobik ve anaerobik kan kültürleri alınır. Antibiyotiklerin ve modern tedavilerin kullanılmasına rağmen, sepsis hala yoğun bakım ünitesi ölüm oranlarının ana nedenlerinden biridir. Covid-19 pandemisi ile önemi daha da katlanan sepsis enfeksiyonu, çoklu organ yetmezliğine neden olarak hastanın ölümüne neden olmaktadır. Covid-19 pozitif tanısı alarak yoğun bakıma yatan hastaların çoğunluğu sepsis enfeksiyonunun neden olduğu çoklu organ yetmezliği sonucu hayatlarını kaybetmektedir. Bu nedenle bu hastalığın erken tanısı şu günlerde ekstra önem taşımaktadır.

Tez çalışması, Medipol Mega Hastanesindeki Yoğun Bakım ve Enfeksiyon hastalıkları hekimleri ve Pusula HBYS Yazılım şirketi ile ortak gerçekleştirilen Tübitak 1501 Programı, «*Erken Teşhis ve Tanılamaya Yönelik Öngörücü-Önerici Klinik Platform Projesi*» kapsamında ilerlemiştir. Bu bağlamda sepsisin erken teşhis ve tanılmasının gerçekleştirilmesi için yapılan bu araştırmada yoğun bakım ünitelerinde kalan 40.000'den fazla gerçek hastaya ilişkin, kimlik bilgileri şifrelenmiş verileri içeren geniş bir veri tabanı olan MIMIC-III (v1.4) veri tabanı kullanılmıştır. MIMIC-III veri tabanı kullanılarak sepsis konusu odağında veri ambarı oluşturulmuştur. AzureCloud üzerine kurulan PostgreSQL (v.13) veri tabanına yaklaşık 50GB alanı kaplayan MIMIC-III kurulmuştur. PostgreSQL üzerinde gerekli sorgular yapılarak yoğun bakımda tedavi gören hastalara ait veri ambarı, veri modellemesinin yapılacağı makine üzerinde oluşturulmuştur. Bu veri ambarında 6 statik, 34 dinamik ve 1 hedef değişken olmak üzere toplamda 41 değişken ve 1.552.210 hasta kaydı bulunmaktadır. LSTM sinir ağı modelinde girdi olarak kullanılmak üzere hastaların laboratuvar sonuçları, yoğun bakımda zamansal olarak anlık veri üreten cihaz verileri ve hastalara ait demografik veriler kullanılmıştır.

Veri ön işlemenin en büyük zorluğu, büyük miktarda eksik veridir ve veri kümesinin bütünlüğü, sinir ağını eğitmek için çok önemlidir. Bu nedenle, eksik veri değerlerinin tahmini, modelin tahmin sonucu için çok önemli hale gelir. Zaman serilerinde yaygın olarak uygulanan doğrusal enterpolasyon, noktaları artan sırada düz bir çizgide birleştirilerek eksik bir değeri tahmin etmek anlamına gelir ve bilinmeyen değeri önceki değerlerden aynı artan sırada tahmin edebilme yeteneğine sahiptir. Hastadaki yaşamsal değerlerde zaman serileri aralıkları düzenli olduğundan eksik değerlerde

doğrusal enterpolasyon yöntemi kullanılmış, bu yöntemle eksik kalan satırlar için ise önceki ve sonraki değer, sabit değer ile eksik değerler giderilmiştir. Klinik verilerde uç değerler bir anlam taşıdığından ve hastanın bazı değerlerinin çok yükseldiği veya düştüğü anlamına gelebildiğinden veri ambarında uç değer temizleme işlemi gerçekleştirilmemiştir. Sepsis enfeksiyonu kapsamında veri ambarı incelemesi için, uluslararası tanı kodlarını içeren ICD-9 kodları kullanılmıştır. Veriler 42.842 benzersiz hasta gözleminde oluşmakta olup, bunların 2.932'si ICD-9 kodları ile septik hasta olarak belirlenmiştir. Tespit edilenlerin %59'u erkek (n=1739), %41'i kadın (n=1193) hastadır. SP olan hastaların %46'sı 60-80 yaş aralığındadır. Sepsis olmayan hastalarda, erkeklerin ve kadınların sırasıyla %56 ve %44 ile daha eşit dağıldığını gözlemlenmiştir.

Makine öğrenmesi algoritmalarında özellik mühendisliği, makine öğrenmesi algoritması gereksinimleriyle uyumlu, uygun veri kümesinin hazırlanması ve makine öğrenmesi modelinin performansını iyileştirme amacıyla gerçekleştirilir. Bu kapsamda araştırmaya konu olan veri setindeki sürekli değişkenler min-maks normalizasyon yöntemi ile [0,1] değer aralığında normalleştirilmiştir. Hastanın cihaz (hayati) değerleri sürekli üretildiğinden bu veriler 10 saatlik zaman dilimi ile matrise çevrilerek yeni bir değişken adı altında tutulmuştur.

Değişkenler içinde gereksiz özniteliklerin olması; modelin eğitim süresini artırması, modelin yorumlanabilirliğini azaltması ve aşırı öğrenmeye neden olarak model başarısını yüksek göstermesi gibi olumsuz durumları doğurabilmektedir. Bu nedenle araştırmada özellik seçimi için değişkenler arasındaki korelasyon değerlendirilmiş, Hemoglobin (Hgb) ile Hematokrit (Hct) değişkenleri arasında yüksek korelasyon (0.98) görülmüştür. Burada bir değişken diğeri ile açıklanabildiğinden Hct değişkeni



veri setinden çıkarılmıştır. Özellik seçimi sonrasında veri setinde analizde kullanılmak üzere toplam 40 değişken kalmıştır. Araştırmada uzun kısa süreli bellek (LSTM) adı verilen, geçmişe yönelik zamansal verileri hafızasında tutabilme yeteneğine sahip derin öğrenme algoritması kullanılmıştır. Tüm veri seti eğitim, test ve doğrulama olmak üzere üç bölüme ayrılmıştır. Eğitim setinin rastgele ayrılmış olan %10'luk dilimi doğrulama verisi olarak ayrılmıştır. LSTM algoritmasının zaman serilerinde geçmişe yönelik verileri hafızasında tutma yeteneğinden yararlanılarak hastalar 10 saatlik zaman dilimleri içinde değerlendirilmiş ve hastanın 11. saat içinde sepsis olup olmayacağına dair tahminlenmesi gerçekleştirilmiştir. Modelde hem çift yönlü hem de tek yönlü LSTM modeli kurulmuş ve sonrasında kurulan iki model RELU aktivasyon fonksiyonu kullanılarak tek bir model altında birleştirilmiştir.

LSTM ağı, klinik müdahaleleri daha erken ve daha etkili hale getiren septik başlangıca karşı oldukça hassas olacak şekilde ayarlanabilir, öte yandan uzun vadeli uygulamalarda potansiyel olarak yanlış alarm yorgunluğuna neden olabilir. İdeal ve pratik bir ağ, her yinelemede optimal karara yaklaşmalı ve sonunda optimale ulaşmalıdır. Bu nedenle geliştirilmiş olan modelin performansının değerlendirilmesi amacıyla ROC- AUC eğrisi kullanılmıştır. LSTM ağının test veri setindeki ROC eğrisine (Şekil 42.) göre AUC değeri 0,77 olarak bulunmuştur. AUC metriği, bir modelin sınıfları ne kadar iyi ayırt edebildiğini ölçümleyen bir metriktir ve değeri ne kadar yüksek ise model o kadar başarılı olarak değerlendirilir. Doğrulama veri seti için ROC eğrisi değerlendirildiğinde ise AUC=0,82 olarak elde edilmiştir. Buna göre modele onun daha önce hiç görmediği hasta değerleri verildiğinde hastanın 11. saatte sepsis olup olmayacağını %82 oranında tahmin edebilmektedir.

Modern tıp dünyasında büyük verilerin kullanımı ile doktorların kararlarına veya araştırmalarına yardımcı olmak için yapay zeka kullanımı konusunda büyük gelişimler yaşanmaktadır. Artık günümüzde kişiye özel tedavi planlarının uygulanması söz konusudur. Bu nedenle sepsisin yeni fenotiplerini keşfetmek ve kişiye özel tedavi planları tasarlamak artık bir ihtiyaç olmuştur. Böylesine kritik bir hastalığın erkenden tanısının konularak tedaviye başlanmasının sağlanması, hekimlerin risk altında verdiği kararların verimliliğini artırarak hekim kararlarını desteklenmesi sağlamayı amaçlamaktadır. Hastane yönetimi özelinde böyle bir sistemin kullanılabilirliği düşünüldüğünde ise yoğun bakımda ölüm oranlarını azaltacak hatta sepsis nedeniyle

gerçekleşen ölümlerin neredeyse sıfırlanacağına yönelik bir rekabet stratejisi geliştirilebilecektir. Bu çalışmada yoğun bakımda en önemli ölüm nedenlerinden biri olan sepsis enfeksiyonunu hekime ya da sağlık personeline bir saat öncesinde haber verilmesini sağlayan bir çalışma gerçekleştirilmiştir. Yapay zekaya dayanan bu çalışmada geliştirilen model, %82 başarı ile hastanın bir saat sonra sepsis enfeksiyonu geçirip geçirmeyeceğini tahmin edebilmektedir. Bu sayede hastaya erken müdahale yapılabilecek ve hastanın hayati tehlikesi daha hızlı fark edildiğinden yaşanacak olumsuz durum önlenilebilecektir. Günümüzde teknoloji rekabetinin her sektörde yaşandığı şu günlerde, tıp alanında da yapay zeka temelinde gerçekleşen dönüşüme sağlık merkezlerinin ayak uydurmaları ve yapay zeka teknolojilerinden yararlanmalarının önemli olduğu düşünülmektedir.

## V.BÖLÜM

### TARTIŞMA VE SONUÇ

Sürekli artan heterojen hasta verileri, insan yaşamı için tıbbi araştırmaları ve klinik uygulamaları yeniden araştırma imkanı sunmaktadır. Özellikle kritik hastalıkların erken aşamalarda öngörülememesi, hekimlerin yaşadığı zorluklardan biri olarak bilinmektedir. YBÜ'lerinde kritik hastalık olarak görülen ve yaşanan ölümlerin en önemli sebeplerinden biri olan sepsis enfeksiyonu ciddi bir küresel sağlık krizi olarak karşımıza çıkmaktadır (“Sepsis - A Global Health Crisis”, 2020). Sepsis enfeksiyonunun erken teşhisi yapılamaz ve hızla tedaviye başlanamaz ise çoklu organ yetmezliği sonucu ölüme neden olabilmektedir. Sepsisin önlenmesi ve tedavi edilmesi, morbidite, mortalite ve sağlık bakım maliyetleri açısından önemli bir halk sağlığı sorunu olarak görülmektedir (Angus vd., 2001; Stoller vd., 2015). Erken teşhis ve müdahale, septik hastaların sonuçlarını iyileştirmek için kritik önem arz etmekte; tedavide her geciken saat, %4 ila %8 daha yüksek mortaliteye neden olmaktadır (Seymour vd., 2017; V. X. Liu vd., 2017). Sepsisin geç teşhis edilmesi durumunda ya da ağır sepsis vakalarında tüm vücutta ağır iltihaplanmalar meydana gelmekte ve septik şok gelişebilmektedir. Bu durum beraberinde tansiyonda ciddi bir düşüşe yol açmakta ve ölümlerle sonuçlanabilmektedir (Bone vd., 2009). Hipotansiyon başlangıcından sonra tedavinin geciktiği her saat için septik şoka bağlı ölüm riski %7,6 artış gösterdiğinden sepsisin erken belirlenmesi hasta sonuçlarının iyileşmesinde önem arz etmektedir (Kumar vd., 2006). Sepsis tanısının konulması amacıyla SOFA ve qSOFA skorlama sistemleri kullanılmaktadır. SOFA skorlamasının sofistike ve zaman alıcı olması, qSOFA'nın ise düşük performans göstermesi nedeniyle bu denli kritik bir hastalığın erken teşhisi için daha doğru klinik tahmin modellerine gereksinim duyulmaktadır (Churpek ve Edelson, 2016; Askim vd., 2017; Lo vd., 2019). Yaşanan Covid-19 pandemisi ile sepsis enfeksiyonunun önemi tekrar gündeme gelmiştir. YBÜ'ne Covid nedeniyle kaldırılan hastaların ölüm oranının kabülden sonraki 24 saat içinde %25, 2-10 gün içinde %50 ve 10 günden sonraki süreçte %25 gibi bir örüntüye sahip olduğu belirtilmiştir. Ölümlerin daha çok birlikte var olan hastalıklar, sepsis ve

diğer olumsuz olaylarla ilişkili olduğu vurgulanmıştır. COVID-19'daki erken ölümler daha çok fizyolojik bozukluklarla ilişkilirken, geç ölümler (>10 gün) hastalık komplikasyonları veya çoklu organ yetmezliği ile sonuçlanan tedaviyle ilişkili morbiditeden kaynaklanmıştır. Bu nedenle erken dönemde sepsis ve diğer komplikasyonların önlenmesi bu hastaların sağ kalımını iyileştirmeye yardımcı olacağı vurgulanmıştır (Sohn vd., 2020; Modi ve Modi,2021). Yapılan bir çalışmada, sepsisli hastalara 3 saatlik bir bakım paketinin zamanında uygulanmasının (yani, kan kültürü istenmesi, geniş spektrumlu antibiyotiklerin uygulanması ve laktat ölçümü yapılması), daha düşük hastane içi mortalite ile ilişkili olduğu tespit edilmiştir (Seymour vd., 2017). Bu durum hızlı ve agresif tedavi ihtiyacını daha da vurgulamıştır. Tüm bunlar nedeniyle sepsisin erken teşhisi tıpta önemli bir sorun oluşturmaktadır. Sepsis ile ilişkili semptomlar diğer birçok klinik durumdan kaynaklanabileceğinden, deneyimli hekimler için bile sepsisin erken ve doğru tanımlanması zor olmaya devam etmektedir (Jones vd., 2010).

Bu tez araştırması kapsamında sepsis enfeksiyonunun gelişimini erkenden tahmin etmeye yönelik bir yapay zeka çalışması gerçekleştirilmiştir. Araştırma, Medipol Mega Hastanesindeki Yoğun Bakım ve Enfeksiyon hastalıkları hekimleri ve Pusula HBYS Yazılım şirketi ile ortak gerçekleştirilen Tübitak 1501 Programı, «*Erken Teşhis ve Tanılamaya Yönelik Öngörücü-Önerici Klinik Platform Projesi*» kapsamında ilerlemiştir. Projenin gelişimi sürecinde Medipol Üniversitesi Yoğun Bakım hekimleri ile görüşülmüş ve görüşme sonunda, hekimlerin erken tanıda zorlandıkları sepsis enfeksiyonu kapsamında çalışmanın ilerletilmesi kararlaştırılmıştır. Çalışmada yoğun bakım ünitesindeki hastalar özelinde yapay zeka algoritmaları kullanılarak sepsis enfeksiyonunun öngörülmesine yönelik bir model geliştirilmesi amaçlanmıştır. Sürekli öğrenen ve akıllı bir konsültasyon aracı olarak hekimlere yardımcı olması amaçlanan bu model, hekimlerin karar almasına katkı sağlaması, hastanenin veriye dayalı yeni yetenekler geliştirmesi, sepsis enfeksiyonunun tahminlenmesi sayesinde hekimin hastasına erken müdahale edebilmesi ve hastanenin stratejik yönetiminde yaşanabilecek dönüşüm açısından incelenmiştir. Öncelikle sepsis enfeksiyonuna sahip olan hastaların örüntülerinin çıkarılarak monitörize edilmesi ve bu sayede hekimin bir ekran üzerinden hastanın anlık ilerleyişini görmesi amaçlanmıştır. Bu amaç

doğrultusunda denetimsiz öğrenme algoritması olarak Bulanık C-Ortalamalar Algoritması kullanılmıştır. Ardından hastaya ait zaman serisi formatındaki veriler kullanılarak hastanın bir sonraki saatte sepsis olup olmayacağını öngören model, derin öğrenme algoritması LSTM kullanılarak geliştirilmiştir.

Tez araştırmasında, Beth Israel Deaconess Tıp Merkezi'nin 2001- 2012 yılları arasında yoğun bakım ünitelerinde kalan 40.000'den fazla gerçek hastanın verilerini içeren MIMIC-III veri tabanı (versiyon: v1.4) kullanılmıştır. MIMIC-III yatak başındaki zaman damgalı cihaz verilerini, verilen ilaçları, laboratuvar ölçümlerini, sağlık personelleri tarafından alınan gözlemleri ve notları, prosedür ve tanı kodlarını, görüntüleme raporlarını, hastanede kalış süresini, hayatta kalma verilerini, müdahaleleri, reçeteleri ve demografik verileri içeren büyük bir YBÜ veri tabanıdır (Johnson, vd., 2016). Tez kapsamında YBÜ'de tedavi gören hastaların demografik, laboratuvar ve yatak başı cihaz verileri kullanılarak sepsis enfeksiyonu özelinde yapay zeka uygulamaları gerçekleştirileceğinden MIMIC-III veri tabanı kullanılarak sepsis konusu odağında veri ambarı oluşturulmuştur. PostgreSQL üzerinde gerekli sorgular yapılarak, veri modellemesinin yapılacağı makine üzerinde veri ambarı oluşturulmuştur. Oluşturulan veri ambarındaki değişkenlerin bir kısmı (Resp, Creatinine, GCS, kalp ritmi vb.) sepsisin geleneksel skorlama sistemi olan SOFA, qSOFA da kullanılan değişkenlerdir. Bunların yanı sıra Tübitak projesi kapsamında Medipol Mega Hastanesi yoğun bakım ve enfeksiyon hastalıkları hekimleri ile yapılan görüşmelerde, hastanın laktat değeri, solunum, sistolik kan basıncı, Glaskow Coma Skalası ve Trombosit değerlerinin sepsis enfeksiyonunun teşhisinde önemli olduğu vurgulanmıştır. Ayrıca literatürde sepsis enfeksiyonu konusunda yapılan çalışmalar incelenmiş bu çalışmalarda değinilen değişkenler de veri setine eklenmiştir (Desautels vd., 2016; Nemati vd., 2018; Abbasi, 2018). Hastalara ait nabız, ateş, karbondioksit miktarı, ph, magnezyum, laktat, yaş, cinsiyet gibi float ve integer veri tipinde olan toplam 41 değişken yapay zeka algoritmalarında girdi olarak kullanılmıştır. Tez kapsamında oluşturulan nihai veri ambarında zaman serisi formatında 1.552.210 satır kayıt bulunmaktadır. Veri setini daha iyi anlamak amacıyla tanımlayıcı istatistiklerin dağılımı benzersiz hasta kayıtları (42.842 hasta) içinde incelenmiştir. Buna göre tüm veri setinin %56'sı erkek ve %44'ü kadın hastadır. Veri setindeki hastaların yaş

dağılımı incelendiğinde 20 yaş altının oranı %0,8, 20-35 yaş arası, %7, 35-45 yaş arası %9, 45-60 yaş arası %24, 60-80 yaş arası %45 ve 80 yaş üstünün %14 olduğu bulunmuştur.

Veri ambarında hastaların farklı zamanlarda ölçülen zaman serisi formatında klinik değerleri bulunmaktadır. Klinik verileri yapay zeka ya da makine öğrenmesi alanında modellerken karşılaşılan en sık problemlerden biri eksik, kirliliği ve gürültülü verilerdir. Sağlık personellerinin yoğun iş temposundan kaynaklı veri girişlerinin yapılamaması ya da eksik yapılması, cihazlarda yaşanan kesintiler veya sorunlardan kaynaklı veri akışlarında eksiklik, kirlilik ya da gürültü yaşanabilmektedir. Çalışmada kullanılan MIMIC-III veri tabanında da eksik veriler bulunmaktadır. Bu nedenle veri analizine geçmeden önce veri seti üzerinde veri ön işlemleri yapılmıştır. Veri setindeki eksik veriler tespit edilerek bunların farklı yöntemlerle giderilmesi sağlanmıştır. Zaman serisi formatında bulunan hasta kayıtları gruplandırılmış, böylece her hastanın eksik verisinin kendi içindeki değer ile doldurulması sağlanmıştır. Klinik verilerin veri ön işlemlerinde dikkate alınması gereken en önemli hususlardan biri, her hastanın kendi değer aralıkları içinde ele alınması gerektiğidir. Bu nedenle eksik verilerin giderilmesi ve kaliteli bir klinik veri ambarının oluşabilmesi için veri ön işlemleri oldukça önem arz etmektedir. Her bir hasta grubu içindeki eksik değerler giderilirken öncelikle doğrusal enterpolasyon yöntemi kullanılmış, ardından önceki ve sonraki değer ile eksik veriler giderilmiştir. Bu adımlardan sonra hastanın kayıtlarında eksik değer bulunuyor ise bu durumda numerik veriler için sabit değer (0) kullanılarak eksik veri giderme işlemi sonlandırılmıştır.

Tez kapsamında yapılan ilk çalışmada, sepsis enfeksiyonunun gelişimini etkileyen değişkenlerin yardımıyla SP ve SN tanısı konan hasta verilerine FCM algoritması uygulanmış ve hastalara ait örüntülerin monitörize edilerek hastalar arasındaki farkın anlaşılması amaçlanmıştır. Hastaların kümelere homojen şekilde dağıtılarak SP ve SN olan bölgelerin belirlenmesi ve böylece hastanın anlık değerleri ile hastanın hangi kümeye doğru yönelim gösterdiğinin hekime sunulması amaçlanmıştır. Bu sayede yeni gelen hastanın değerleri anlık olarak işlenerek hastanın hangi bölgeye yakın olduğu tespit edilebilme imkanı da sunulmuştur. Çalışmada FCM algoritmasının

kullanılmasının nedeni, bu hastaları ayıran kesin bir çizginin olmamasıdır. Hekimlerle yapılan toplantı ve görüşmeler esnasında sepsis enfeksiyonunun zor anlaşılması ve bu nedenle erken tespitinin yapılamadığı belirtildiğinden, bu hastaları kümelemek için kesin sınırları olan kümeleme algoritmaları değil, FCM algoritması kullanılmıştır. Bu algoritma sayesinde gözlem/gözlemler yalnızca bir kümeye değil iki veya daha fazla kümeye ait olmasına izin verilmektedir. Veri setinde FCM algoritması öncesinde hasta bazında değişkenlerin minimum, maksimum, ortalama ve standart sapma değerleri hesaplanarak zaman seri formatındaki kayıtlar tek bir satıra indirgenmiştir. Son durumda veri setinde modele girecek olan değişken sayısı 140, benzersiz hasta kaydı ise 42.842 satırdır. Makine, sepsis tanısı alan 2.932 ve sepsis tanısı almayan 39.910 hasta verisi ile eğitilmiştir. FCM algoritmasının bulanıklık katsayısı  $m=2$  ve maksimum iterasyon sayısı 100 olarak belirlenmiş ve veriler 2-5 arası 4 farklı kümeye ayrılmıştır. Optimum küme sayısının belirlenebilmesi ve oluşan kümelerin kalitesini değerlendirmek için, PE (Bezdek, 1975), PC (Bezdek, 1973) ve XB (Xie ve Beni, 1991) gibi doğrulama indeksleri kullanılmıştır. Buna göre SP olan hastalarda en düşük PE (0.51), en yüksek PC (0.66) ve en düşük XB (1.01) değeri göz önünde bulundurulduğunda optimum küme sayısı iki olarak elde edilmiştir. SN hastalarda en düşük PE (0,69), en yüksek PC (0,5), küme sayısının iki olduğu durumda elde edilmiştir. Bu durumda SN hastalar için de optimum küme sayısının iki olduğu belirlenmiştir. Modelde küme merkezlerini, kümeler arasındaki mesafeyi görselleştirebilmek ve modelin yoğun bakım ünitelerinde kullanılabilecek bir izleme sistemi ile entegre edilebilmesini sağlayabilmek için PCA ile veri boyutu ikiye indirgenmiştir. PCA, %82 doğrulukla iki boyutlu bir veri seti oluşturularak görselleştirilmiştir. Sepsis izlemi iki boyutlu olarak gösterilmesi için %18 oranında temsil kaybı göz ardı edilmiştir. SP ve SN bölgeleri birbirinden ayrık bir örüntü çizse de SP Küme1 ile SN Küme0'ın küme merkezlerinin birbirlerine yakın olduğu görülmüştür. Bu durumun hekimlerin hastalığı tespit ederken yaşadığı zorluğu ifade ettiği düşünülmektedir. Bu bölgelerde yaşanan bulanıklık nedeniyle, hekimlerin sepsis teşhisinde zorluk yaşandığı düşünülmektedir. Analiz sonunda, model üzerinden öğrenme gerçekleştirilmiş ve SP ve SN hastaların monitörize edilmesi sağlanmıştır. Bu model sağlık personelinin, hastaların hangi bölgeye doğru bir eğilimde olduklarını görebilmeleri açısından önem taşımaktadır. FCM algoritmasının oluşturduğu dört

farklı kümenin genel olarak birbirinden farklılaştığı, ancak bazı durumlarda bu ayrımın yapılmasının zor olduğu görülmektedir. Hekimlerin sepsis tanısını koymasında zorluk ya da gecikmenin de bu bulanıklıktan kaynaklandığı düşünülmektedir.

Tez araştırması kapsamında ele alınan sepsis enfeksiyonu, doktor teşhis koyana kadar organ yetmezliğine neden olan bir hastalık olduğundan, teşhisin önceden konulabilmesi birincil önem taşımaktadır. Sepsisin mevcut yönetimi büyük ölçüde antibiyotik kullanımına dayanmaktadır; bir hasta kabul edildiğinde, antibiyotik kullanımını başlatmak için aerobik ve anaerobik kan kültürleri alınmaktadır. Antibiyotiklerin ve modern tedavilerin kullanılmasına rağmen, sepsis hala yoğun bakım ünitesi ölüm oranlarının ana nedenlerinden biridir. Covid-19 pandemisi ile önemi daha da katlanan sepsis enfeksiyonu, çoklu organ yetmezliğine neden olarak hastanın ölümüne neden olmaktadır. Covid-19 pozitif tanısı alarak yoğun bakıma yatan hastaların çoğunluğu sepsis enfeksiyonunun neden olduğu çoklu organ yetmezliği sonucu hayatlarını kaybetmektedir(Coronado Munoz vd., 2020). Bu nedenle bu hastalığın erken tanısı bu günlerde ekstra önem taşımaktadır. Ancak bundan sonraki süreçlerde de Covid 19 pandemisi bitse dahi yeni virüs kaynaklı pandemilerin oluşumunun göz önüne alınması gerektiğinden bu tarz enfeksiyon temelli hastalıkların tahmin edilmesi gereklilik göstermektedir. Uçtan uca veri analizinin gerçekleştirildiği bu çalışmada farklı klinik veri kaynaklarını kullanan model, saatlik girdi verisi olarak bir sonraki saat içinde septik şok geliştirip geliştirmeyeceğini tahmin etmeyi amaçlamaktadır. Araştırma, büyük verinin sağlık alanında kullanımının yaygınlaşmasını ve geliştirilen modeli kullanan yoğun bakım ünitelerinde mortalitenin en aza indirgenmesini hedeflemektedir. Bu amaçla, zaman serisi şeklinde değerlendirilen klinik verilerde gelecek saatte sepsisi tahmin etmek için derin öğrenme modeli olan LSTM ile evrimsel bir ağ geliştirilmiştir.

MIMIC-III veri tabanı kullanılarak sepsis odağında oluşturulan veri ambarında 6 statik, 34 dinamik ve 1 hedef değişken olmak üzere toplamda 41 değişken ve 1.552.210 hasta kaydı bulunmaktadır. LSTM sinir ağı modelinde girdi olarak kullanılmak üzere hastaların laboratuvar sonuçları, yoğun bakımda zamansal olarak anlık veri üreten cihaz verileri ve hastalara ait demografik veriler kullanılmıştır. Araştırmaya konu olan



veri seti eksik verilerin giderilmesi sonrası vital bulgu değerleri (cihaz verileri) ve laboratuvar test sonuçları, min-maks normalizasyon yöntemi ile  $[0,1]$  değer aralığında normalleştirilmiştir. Hastanın cihaz değerleri sürekli üretildiğinden bu sürekli veriler 10 saatlik zaman dilimi ile matrise çevrilerek yeni bir değişken adı altında tutulmuştur. Çalışmada 10 saatlik zaman diliminin kullanılmasının nedeni, hastaların ortak zaman paydasının 10 saat olmasından kaynaklanmaktadır. Bazı hastaların 100 saatlik verisi bulunmakta iken bazı hastaların 40, bazılarının ise 10 saatlik verisi elde edilmiştir. Çalışmada amaç en uzak zaman diliminde hastanın sepsis olup olmayacağını tespit edebilmektir. Bu nedenle ortak en uzak zaman dilimi 10 saat olduğu için 11. saatte sepsis enfeksiyonunun tahminlenmesi üzerine çalışılmıştır. Değişkenler içinde gereksiz özniteliklerin olması; modelin eğitim süresini artırması, modelin yorumlanabilirliğini azaltması ve aşırı öğrenmeye neden olarak model başarısını yüksek göstermesi gibi olumsuz durumları doğurabilmektedir. Bu nedenle çalışmada, derin öğrenme modeline geçilmeden önce özellik seçimi için değişkenler arasındaki korelasyon değerlendirilmiş ve sınır değeri 0.95 ve üzeri olan değişkenler veri setinden çıkarılmıştır. Buna göre Hemoglobin (Hgb) ile Hematokrit (Hct) değişkenleri arasında 0.98 oranında korelasyon bulunmuştur. Burada bir değişken diğeri ile açıklanabildiğinden Hct değişkeni veri setinden çıkarılmıştır.

Veri ön işlemlerinin ardından ele alınan derin öğrenme algoritması LSTM ağ modeli, Anaconda Python Notebook (versiyon: 2.1.1.) üzerinde geliştirilmiş, Python 3.9.1 kullanılmıştır. Çalışmada Tensorflow (versiyon:2.3.0) üzerinde çalışan keras kütüphanesinden faydalanılmıştır. Tüm veri seti eğitim, test ve doğrulama olmak üzere üç bölüme ayrılmıştır. Eğitim setinin rastgele ayrılmış olan %10'luk dilimi doğrulama verisi olarak ayrılmıştır. LSTM algoritmasının zaman serilerinde geçmişe yönelik verileri hafızasında tutma yeteneğinden yararlanılarak hastalar 10 saatlik zaman dilimleri içinde değerlendirilmiş ve hastanın 11. saat içinde sepsis olup olmayacağına dair tahminlenmesi gerçekleştirilmiştir. Modelde hem çift yönlü hem de tek yönlü LSTM modeli kurulmuş ve sonrasında kurulan iki model RELU aktivasyon fonksiyonu kullanılarak tek bir model altında birleştirilmiştir.

Modelin eğitilmesi adımımda dengesiz veri sorunu ele alınmıştır. Dengesiz bir dağılıma sahip olan veride (SP: 2932, SN:39.910) bu durum, modelin öğrenme sürecini ve tahmin başarısını etkileyecektir. Bu nedenle modeli eğitim verisine uygularken “class\_weight” parametresi yardımıyla sınıf dengesizliği sorunu ele alınmıştır. Bu parametre yardımıyla, azınlık sınıfına atanan ağırlık dengesizlik oranında artırılarak, algoritmanın azınlık verisinin yanlış sınıflandırmasından kaynaklanan hata oranı azaltılmıştır. Dolayısıyla, modeli oluştururken genel hata oranı (overall error rate) azaltılmaya çalışılmış, yani azınlık sınıfı dikkate alınarak performansın artması sağlanmıştır. Geliştirilmiş olan modelin performansının değerlendirilmesi amacıyla ROC- AUC eğrisi kullanılmıştır. Eğitilen LSTM ağının test veri setindeki ROC eğrisinde AUC değeri 0,77 olarak bulunmuştur. Veri seti içinde doğrulama verisi olarak ayrılan ve eğitilen modelin daha önce görmediği verileri, ilk kez görerek tahminlenme yeteneğinin ölçüldüğü verilerde ise başarı %82 olarak elde edilmiştir. Bu durumda modelin yeni gelen bir hastanın bir sonraki saatte sepsis olup olmayacağını %82 başarı ile tahmin edebildiği söylenebilir. Yapay zekaya dayanan bu çalışmada geliştirilen model, %82 başarı ile hastanın bir saat sonra sepsis enfeksiyonu geçirip geçirmeyeceğini erken uyarı sistemi ile bildirecektir. Bu sayede hastaya erken müdahale yapılabilecek ve hastanın hayati tehlikesinin ilerlemesinin önüne geçilebilecektir.

Tez araştırması kapsamında araştırmasında geliştirilen yapay zeka modellerinin kullanımı sonucu (i) hekimin karar verme sürecine karar desteği perspektifinde yardımcı olmak; (ii) sağlık merkezine rekabet avantajı sağlayan dinamik yeteneklerin geliştirilebilmesi; (iii) yapay zeka teknolojileri ile kritik hastalıkların öngörülebilmesi ve müdahale edilebilmesi; (iv) ve tüm bunların gerçekleşmesi sayesinde sağlık merkezinin inovatif stratejiler belirleyebilmesi kapsamında farklı boyutlarda ele alınmıştır.

(i) Tıp mesleğinin en büyük başarılarından biri, hekimlerin karşılaştığı kararları yönetilebilir boyuta indirgeyen ve hekimlerin doğru yanıtlar elde etmelerini sağlayan yöntemlerin geliştirilebilmesidir. Ancak bu başarı beraberinde zorlukları da beraberinde getirmektedir. Hekimlerin karşı karşıya kaldığı kararların doğası

değişmekte ve geçmişe yönelik geliştirilen yöntemler geleceğe uygun olmayabilmektedir. Yakın tarihe kadar hekimlerin dar bir tanı yelpazesi, aralarından seçim yapabileceği bazı testler ve birkaç tedavi yöntemi bulunmakta idi. Ancak şimdilerde hastalık süreçleri anlayışı, verilere ulaşma şekli, yapılan testler ve detaylı görüntüleme süreçleri, genişleyen tanı yelpazesinde değişimler meydana gelmiş ve bunlarla birlikte sağlık hizmeti kararlarının karmaşıklığı da artmıştır. Tıbbi kararlar bilgiyi eyleme dönüştüren süreçler olup (Eddy, 1986), hangi önleme prosedürlerinin gerçekleştirildiğini, hangi teşhislerin yapıldığını, hangi testlerin istendiğini ve hangi tedavilerin gerçekleştirildiğini belirlemeye yardımcı olmaktadır. İçinde bulunduğumuz rekabet çağında, eylemin yükünü taşıyacak olan tıbbi karar vermedir ve tıbbi uygulamanın kalitesini belirleyecek olan tıbbi karar vermenin başarısı veya başarısızlığı olacaktır. Çoğu durumda sayısız test, laboratuvar ya da görüntüleme sonucunu, çok sayıda faktörü, yüzlerce ilişkiyi içermekte ve her unsur hakkında belirsizlikler bulunmaktadır. Sağlık hizmetlerinde yapay zeka algoritmalarının kullanımı sonucunda tüm bu belirsizliklerin anlamlandırılması sağlanırken hekimin deneyim ve tecrübelerinden de yararlanılarak sistemin tahminlerinin hekim tarafından denetlenmesi sağlanabilecektir. Bu tez araştırmasında ele alınan sepsis enfeksiyonu hali hazırda geleneksel Sofa ve qSofa skorlama ölçütleri ile tespit edilmektedir. Ancak bu skorlama ölçütlerinin sepsisin erken teşhisine yardımcı olamadığı, bu kriterlerin mevcut puanlamasının ciddi şekilde düşük performans gösterdiği yapılan çalışmalarda vurgulanmıştır (Askim vd., 2017); (Lo vd., 2019). Bu nedenle gelişen yeni teknolojilerden destek alınmasının gerekliliği ortaya çıkmış ve bu çalışma kapsamında yapay zeka kullanımı ile hekimlerin efektif ve verimli kararları daha hızlı almalarını sağlayabilecek ve hastaya erken müdahale imkanı tanıyabilecek bir model önerilmiştir.

(ii) Dış çevre ortamında artan kargaşayla yüzleşmek, ayakta kalabilmek ve rekabet avantajı elde edebilmek için temel güç kaynağı olarak işletmelerin iç kaynaklarına ve yeteneklerine odaklanmaları gerekmektedir (Chahal vd., 2020). Bu rekabet üstünlüğü, stratejik amaçlar için bir zorunluluktur ve taklit edilemez olmalıdır. Örgütlerin rekabet avantajı elde edebilmeleri için öncelikle iç kaynaklarını en iyi şekilde kullanmaları ve ardından yeni kaynaklara yönelmeleri gerekmektedir (Steininger vd., 2022). Veri,

günümüzde yapay zeka dönüşümüne güç sağlayan en büyük yakıt olarak görülmektedir. Sağlık sektörü de diğer birçok sektörde olduğu gibi kendi ürettikleri verinin önemini bu zamana dek fark edememiş ve eksik, yanlış ya da gürültülü veriler tutulmuştur. Dijital dönüşümü önemseyen sağlık merkezleri geçmişe yönelik verilerini depolamaya başlamış, ancak yine de bu veriyi kullanma konusunda yeteneklerini geliştirememişlerdir. Yapay zeka teknolojilerinin en önemli yakıtı olan veriyi kaliteli ve doğru şekilde depolamayı başaran hastaneler sürdürülebilir rekabet avantajı anlamında rakiplerine fark atmayı başarabileceklerdir.

Kaynak temelli görüş, bir şirketin başarısını belirlemek için iç kaynakları baz almaktadır. Bu başarı, kaynak-davranış-performans olarak tanımlanmaktadır (Engert vd., 2016). Tez kapsamında sağlık hizmetlerinde sürdürülebilir rekabetin sağlanması için kaynak temelli görüşün baz alınarak, öncelikle hastanenin kendi iç kaynaklarını kullanması önerilmektedir. Bilgiye sahip olma veya erişilebilirlik, firmaya değer katması, taklit edilmesi zor, organize edilebilirliği yüksek olması özellikleri ile firmalara sürdürülebilir rekabet avantajı sağlamaktadır (Arend ve Lévesque, 2010). Dinamik yetenekler, firmaların yeni yetenekler oluşturma ya da çevresel belirsizlik karşısında var olan örgütsel yeteneklerini dönüştürme yetkinlikleridir. Bu yetenekler, işletmenin mevcut işletme yetenekleri üzerine inşa edilmekte ve firmanın rekabet avantajının temeli olarak kullanılmaktadır (Leih ve Teece, 2016). Kaynaklara dayalı yaklaşım politikası çerçevesinde bilgi temelli ve dinamik yetenekler görüşünü benimseyen hastaneler kendi verilerini, sermayelerini, örgüt içi bilgilerini ve insan kaynağını kullanarak yapay zeka teknolojilerine daha hızlı uyum sağlayabileceklerdir. Yine bu kapsamda Chicago Okulu politikası ele alınarak düşük maliyetler ile gerçekleştirilen üretim, firma ünü ve kaliteli ürün çıktısı gibi firmaya özgü kaynakların verimlilik getirisi sağlayacağı da söylenebilir. Hastanelerin kendi ürettiği veriler ve çalışan sağlık personellerin eğitilmesi ve katkısı sayesinde yapay zeka teknolojileri ile donatılmış bir sağlık merkezi inşa ederek rekabet avantajı sağlayabileceklerdir.

(iii) Sepsis enfeksiyonu gibi kritik bir hastalığın erken dönemlerde öngörülmesi hekimi hızlı bir tedavi sürecine yönlendirecek olması açısından önem taşımaktadır. Bu durum hastanın iyileşme sürecine katkıda bulunarak hem sürecin kısılmasını ve

hastanın hayati tehlikesinin giderilmesini hem de hastaya ya da devlete yüklenecek olan maliyetin düşmesine olanak sağlayacağı öngörülmektedir. Aynı zamanda yanlış bir tanının önüne geçilmesi sağlanarak kaynak israfı da önlenebilecektir. Araştırma kapsamında sunulan yapay zeka modelleri hızlı tanıya imkan sunarak hekimin hastaya erken müdahale etmesini, bu sayede hem hastanın hayati tehlikesi giderilirken hem de hastaya ya da devlete yüklenecek olan maliyetin azalmasına katkı sağlayacağı düşünülmektedir. Yapay zeka teknolojilerinin sağlık personellerinin tamamen yerini alması yakın zamanda pek olası olmasa da belirli görevleri insanlardan daha fazla tutarlılık, hız ve tekrarlanabilirlikle gerçekleştirebildiği kanıtlanmıştır (Tang vd., 2018; Fauw vd., 2018; Slomka vd., 2017). Teorik olarak karmaşık olmayan ancak emek ve zaman gerektirebilecek görevleri otomatikleştirmek amacıyla kullanılacak olan yapay zeka teknolojileri sayesinde, insan sermayesinin daha verimli kullanımı da sağlanabilecektir. Bu kapsamda yapılan çalışma hem insan kaynağı hem de maddi kaynaklar açısından tasarruf edilmesine katkı sunacaktır.

(iv) Teknolojik yenilikler, şirketlerin/kurumların paydaşlarla ve müşterileri ile ilişki kurma şeklini kademeli olarak değiştirmekte ve bu değişiklikler ilişkilere odaklanan yeni bir bakış açısı oluşturmaktadır. YZ çok paydaşlı ve rekabetçi ortamlarda bu zorlukların üstesinden gelmeye yardımcı olabilecek analitik bir araçtır ve özellikle makine öğrenmesindeki gelişmelerle birlikte son on yılda literatürde ve sektörde yoğun ilgi görmektedir. YZ teknolojilerinin sorunları çözme konusundaki potansiyeli, işe ve süreçlere katma değer sunması ve karar vermeyi desteklemesi nedeniyle yapay zekanın stratejik kullanımı önemsenmektedir. YZ teknolojileri, organizasyonel bağlamda önemli bir konuma sahiptir ancak en büyük beklenti, iş rekabet senaryosu ile ilgili görülmektedir. Bu nedenle, rekabet avantajı elde etmek için yapay zekanın stratejik kullanımına yönelik araştırmalara artan bir talep olduğu gözlemlenmektedir (Borges vd., 2021).

Sağlık kurumları, büyük ve küçük ölçekli hastaneler artık yapay zeka destekli ütopik stratejik planlar yapabilmektedir. Örneğin, hastanemizin yapay zeka ile donatılmış yoğun bakım ünitesinde hasta ölümleri %80 oranında azalmıştır. Bunu gerçekleştirebilmek için kurumun insan kaynağı, eğitim ve teknoloji ayağından oluşan

üç önemli varlığa ihtiyacı bulunmaktadır. Bu doğrultuda teknoloji ayağı tez kapsamında ele alınmış ve dünya çapında kullanılan veri setleri ile bu entegrasyonun yapılabileceği kanıtlanmıştır. Bilim kümülatif olarak ilerlemektedir. Bu sayede bugünkü imkanlar ile geliştirilen algoritma, model ya da ürünler yarına ışık tutabilmektedir. Öğrenen bir organizasyon yapısında, var olan dinamik yetenekler teknoloji ile geliştirildiğinde rekabet avantajı oluşturulabilecektir. Aksi takdirde teknolojiden uzak, öğrenmeye kapalı ve kendi varlık ve yeteneklerini kullanamayan tüm organizasyonlar yok olma tehlikesi ile karşı karşıya kalacaktır. Şu an YZ ile donatılmış bir hastane yıllar içinde oluşumunu tamamlayabilecek, Metaverse de yerini alabilecek ve süreçlerini sanal dünyada ilerletebilecektir. Verinin önemini kavrayan ve stratejik yönetim çerçevesinde hastanenin tüm birimlerini yapay zeka teknolojileri ile yönetebilen bir hastane yakın gelecekte polikliniklerini Metaverse dünyasına taşıyabilecek hasta muayenelerini ya da ameliyatlarını Metaverse’de gerçekleştirme gücüne sahip olabilecektir.

Tez kapsamında geliştirilmiş olan model kritik ve yaygın hastalıkları yüksek oranda öngörebilme yeteneğine sahiptir ve bu sayede insan sağlığına katkı sağlayacağı, hekimin karar verme süresini kısaltacağı, hastanın hayatının kurtarılması ile hekimin motivasyonunun yükseleceği ve iş gücünden tasarruf edileceği düşünülmektedir. Sağlık bağlamında geliştirilen yapay zeka temelli bu model, ülkemizde yapılacak olan sağlıkta yapay zeka araştırmalarına öncülük ederek motivasyonun kazanılmasını sağlayacağı düşünülmektedir. Hekimlerin deneyimleri ve YZ’nin güçlü öngörü yeteneği, doğru hastalık teşhisi için en iyi başarıyı elde etmek için birleştirilecektir. Sağlık merkezlerinin bu modeli yoğun bakım ünitelerine entegre etmeleri halinde, kendi kaynaklarını kullanarak dinamik yeteneklerini geliştirebileceklerdir. Bu sayede sürdürülebilir rekabet avantajı kazanılabileceklerdir. Yapılan tez çalışması kapsamında geliştirilen model ülkemizde sağlık alanında öğrenen akıllı bir konsültasyon aracı olmanın yanında sağlık kurumunun tüm verilerini kullanarak, bir Kurumsal Kaynak Planlama çalışma prensibi dahilinde, tüm birimlerden yararlanan ve tüm birimlere hizmet veren bir model olabilme potansiyeli açısından öncü olacak ve tespiti yapılan kritik hastalıklarda başarı sağlandıktan sonra diğer tıbbi komplikasyonların da öngörülmesi için sistemin geliştirilmesi devam edebilecektir.

Sağlık alanında yapılan Tübitak projesi ve tez araştırması sürecinde bazı zorluklarla karşılaşmıştır. Öncelikli olarak donanımsal yeterlilikler önemli bir sorun idi ancak, CPU ve RAM hızlarının yükselmesi sayesinde bu zorluklar gerekli yatırımlar ve sistemlerin alınması ile aşılmıştır. Proje kapsamında iş birliği yapılan sağlık kurumu, hastaneler zinciridir. Bu tarz zincir hastanelerin ana problemlerinin başında, hastaneler arası veri entegrasyonu gerçekleşmemiş olabilmektedir. Zincir hastanelerin yönetimi birbirinden farklı olmakta bu nedenle süreçleri ve dijitalleşme hızları farklılık gösterebilmektedir. Hastaneler arası ve hastane içi verilerin entegrasyonu sağlanmış olsa dahi yatak başı cihazlardan üretilen veriler farklı marka ya da kalibrasyona sahip cihazlar olabilmekte ve bunların entegrasyonunun sağlanması büyük bir zorluk teşkil etmektedir. Cihaz entegrasyonu sağlanmadığında, yapay zeka algoritmalarının üzerinde çalışacağı büyük veri havuzu oluşamamaktadır. Şu an ülkemizde bulunan diğer kamu ve özel hastanelerde de yapay zeka gelişiminin önündeki en büyük engellerden biri cihaz entegrasyonunun eksikliği, çalışma boyunca gözlemlenmiştir. Bir diğer sorun kaliteli veriye ulaşılamamasıdır. Sağlık personelleri tarafından bazı verilerin gereksiz görülerek kaydedilmemesi, iş yoğunluğu nedeniyle sisteme girilememesi ya da sigorta ödeme kaygıları nedeniyle verilerin yanlış ya da çarpıtılarak sisteme girilmesi sonucu elde edilen verilerde yüksek oranda yanlış, gürültülü ya da eksik veri ile karşı karşıya kalınmaktadır. YZ stratejik yönetim amacı ile kullanmak isteyen hastaneler ve diğer tüm kuruluşlar veri tabanlarını oluşturup sağlıklı veri girişleri ile başlamaları gerekmektedir. Eğer bu işlemler yapılmazsa bugün anlatılan YZ algoritmaları ve derin öğrenme algoritmaları uygulamaları gerçekleşmeyecektir. Örneğin, araştırma kapsamında sepsis teşhisi hekim ve hasta açısından çok önemlidir. Hekim görevini yerine getirmek amacıyla hastasına konsantre olmakta ve müdahaleyi geciktirmemeye çalışmaktadır. Bu nedenle sisteme giriş yapması gereken sepsis başlangıç saatini o an giremeyebilmekte iki ya da üç saatlik zaman kaybı ile sisteme girmektedir. Bu da YZ algoritmaları modellerinin doğru eğitilmesine engel teşkil etmektedir. Bu nedenle hekimlere bu durumun önemini anlatılması ve konu ile ilgili eğitimler verilerek hekimlerin ve sağlık personellerinin bilgilendirilmeleri gerekmektedir. Bu sayede verinin önemi anlaşılacak ve tutulan verideki kalite artacağından YZ modelleri daha başarılı ve doğru sonuçlar üretebilecektir. YBÜ'lerinde çarşaf adı verilen belgelere hasta ile ilgili saatlik kayıtlar yapılmakta ve

sağlık personelleri hastayı bu çarşaf üzerindeki değerler ile takip etmektedir. Bu durum saatlik, dakikalık ya da saniyelik akan verinin depolanmasına engel olmakta bu da YZ araştırmalarını engellemektedir. Özellikle yoğun bakım özelinde çarşaf belgesinin dijitalleştirilmesi hem iş yükünün hafiflemesini sağlayacak hem de verilerin daha sistemli ve düzenli depolanmasını sağlayacaktır. İleride yapılması planlanan sonraki çalışmalar için öneriler ise,

- Bu tez araştırmasında, hastaların verileri için 10 saatlik pencere boyutu kullanılmıştır, bu boyutun değiştirilmesi (örn:6, 8, 12, ya da 24) modelin performansı üzerinde önemli bir etki yaratabilir.
- Araştırmada zaman serisi verileri LSTM algoritması kapsamında ele alınmıştır, bu anlamda farklı algoritmalar ARIMA, DeepAR, XGBoost kullanılarak performans karşılaştırılması yapılabilir ve en iyi performansa sahip algoritma ile model hayata geçirilebilir.
- Enfeksiyonun zor tespit edilmesi nedeniyle FCM kümeleme algoritması kullanılmıştır, ancak farklı kümeleme algoritmaları ile de kümelerin örüntüleri elde edilerek en uygun kümeleme algoritması seçilebilir,
- Modeldeki değişkenler değiştirilerek sağlıkta kritik olan diğer hastalıklar için de modelin uygulanabilir, bu sayede sağlık merkezlerinde YZ ile uyumlu çalışan departman sayısı artırılabilir,
- Sağlıkta YZ ile ilgili yapılan çalışmalar başarı ile tamamlansa dahi ürün gelişimi ve uygulamada kullanımı uzun süreçler gerektirmekte ya da hayata geçirilememektedir. Bu nedenle cihaz entegrasyonları ve sağlık merkezlerinde veri ambarlarının kurulumu ile ilgili detaylı bir araştırmanın gerçekleştirilmesi alana katkı sunacaktır,

Sonuçta, YZ teknolojilerinin sağlık sektöründe uygulamaları kapsamında ele alınan özgün tez çalışmamızda veriyi segmente edebilen ve veriden öğrenebilen bir model geliştirilmiştir. Geliştirilen bu modeller, hastalığı öngörebilmesi ve bu sayede hekimin erken müdahalede bulunabilmesini hedeflerken, YZ'nın stratejik anlamda sağlık merkezinde kullanılabilirliğini de ifade ederek bilime katkı sağlaması amaçlanmıştır.



## KAYNAKÇA

- Abbasi, J. (2018). *Artificial Intelligence Tools for Sepsis and Cancer*. *JAMA* (C. 320). NLM (Medline). <https://doi.org/10.1001/jama.2018.19383>
- Abdi, H., & Williams, L. J. (2010). Principal component analysis. *John Wiley & Sons*, 433–459. <https://doi.org/10.1002/wics.101>
- Abou Elasad, Z. E., Mousannif, H., & Al Moatassime, H. (2020). A proactive decision support system for predicting traffic crash events: A critical analysis of imbalanced class distribution. *Knowledge-Based Systems*, 205. <https://www.sciencedirect.com/science/article/pii/S0950705120304822>
- Ada, Ş., & Ghaffarzadeh, M. (2015). Decision Making Based On Management Information System and Decision Support System. *European Researcher*, 93(93), 260–269. <https://doi.org/10.13187/er.2015.93.260>
- Aggarwal, C. C. (2015). *Data mining: the textbook*. Springer.
- Agrawal, P. (2018). Artificial intelligence in drug discovery and development. *J Pharmacovigil*, 6(2). <https://doi.org/10.4172/2329-6887.1000e173>
- Ahamed, T., Lederman, R., Bosua, R., Verspoor, K., Buntine, W., & Hart, G. (2016). Towards a Methodology for Nursing-Specific Clinical Decision Support Systems (CDSS). *Journal of Decision Systems*, 25(s1), 23–34. <https://doi.org/10.1080/12460125.2016.1187387>
- Alam, S., Dobbie, G., Koh, Y. S., Riddle, P., & Ur Rehman, S. (2014). Research on particle swarm optimization based clustering: A systematic review of literature and techniques. *Swarm and Evolutionary Computation*, 17, 1–13. <https://doi.org/10.1016/j.swevo.2014.02.001>
- Ali, O., Crvenkovski, P., & Johnson, H. (2016). Using a business intelligence data analytics solution in healthcare. *IEEE 7th Annual Information Technology, Electronics and Mobile Communication Conference*, 1–6.
- Alkhafaji, A., & Nelson, R. A. (2013). *Strategic Management*. Routledge. <https://doi.org/10.4324/9780203862582>
- Allen, R. S., & Helms, M. M. (2006). Linking strategic practices and organizational performance to Porter's generic strategies. *Business Process Management Journal*.

- Almomani, A., Gupta, B. B., Atawneh, S., Meulenberg, A., & Almomani, E. (2013). A survey of phishing email filtering techniques. *IEEE Communications Surveys and Tutorials*, 15(4), 2070–2090. <https://doi.org/10.1109/SURV.2013.030713.00020>
- Alther, M., & Reddy, C. K. (2015). *Clinical decision support systems. Healthcare Data Analytics*. <https://doi.org/10.1201/b18588>
- Ameen, I. (2022). Metaverse in Healthcare – New Era is Coming True. 313.12.2021 Tarihinde <https://healthcarebusinessclub.com/articles/healthcare-provider/technology/metaverse-in-healthcare/> adresinden erişildi
- Andrews, P. B. (1971). Resolution in type theory. *Journal of Symbolic Logic*, 36(3), 414–432. <https://doi.org/10.2307/2269949>
- Angus, D. C., Linde-Zwirble, W. T., Lidicker, J., Clermont, G., Carcillo, J., & Pinsky, M. R. (2001). Epidemiology of severe sepsis in the United States: Analysis. : Critical Care Medicine. *Critical Care Medicine/ Society of Critical Care Medicine*, 29(7), 1303-1310. 11.11.2019 Tarihinde [https://journals.lww.com/ccmjournal/Abstract/2001/07000/Epidemiology\\_of\\_severe\\_sepsis\\_in\\_the\\_United.2.aspx](https://journals.lww.com/ccmjournal/Abstract/2001/07000/Epidemiology_of_severe_sepsis_in_the_United.2.aspx) adresinden erişildi
- Ansoff, H. I. (1965). *Corporate Strategy*. New York: McGraw-Hill.
- Aquino, R. P., Barile, S., Grasso, A., & Saviano, M. (2018). Envisioning smart and sustainable healthcare: 3D Printing technologies for personalized medication. *Futures*, 103, 35–50. <https://doi.org/10.1016/J.FUTURES.2018.03.002>
- Arend, R. J., & Lévesque, M. (2010). Is the resource-based view a practical organizational theory?. *Organization Science*, 21(4), 913–930.
- Arnott, D., Pervan, G., & Dodson, G. (2005). *Decision Support Systems Research 1990 to 2003: A Descriptive Analysis. Australasian Journal of Information Systems (C. 12)*. AJIS.
- Askim, Å., Moser, F., Gustad, L. T., Stene, H., Gundersen, M., Åsvold, B. O., ... Solligård, E. (2017). Poor performance of quick-SOFA (qSOFA) score in predicting severe sepsis and mortality - a prospective study of patients admitted with infection to the emergency department. *Scandinavian Journal of Trauma, Resuscitation and Emergency Medicine*, 25(1), 56. <https://doi.org/10.1186/s13049-017-0399-4>
- Assensoh-Kodua, A. (2019). The resource-based view: A tool of key competency for competitive advantage. *Problems and Perspectives in Management*, 17(3), 143.

- Athanasiadis, I. N., Kaburlasos, V. G., Mitkas, P. A., & Petridis, V. (2003). Applying Machine Learning Techniques on Air Quality Data for Real-Time Decision Support. *In First International Symposium on Information Technologies in Environmental Engineering*, (June), 2–7.
- Atuahene-Gima, K., & De Luca, L. M. (2008). Marketing's lateral influence strategies and new product team comprehension in high-tech companies: A cross-national investigation. *Industrial Marketing Management*, 37(6), 664-676.
- Augier, M., & Teece, D. J. (2009). Dynamic capabilities and the role of managers in business strategy and economic performance. *Organization science*, 20(2), 410-421.
- Awoyemi, J. O., Adetunmbi, A. O., & Oluwadare, S. A. (2017). Credit card fraud detection using machine learning techniques: A comparative analysis. *Proceedings of the IEEE International Conference on Computing, Networking and Informatics, ICCNI 2017, 2017-Janua*, 1–9. <https://doi.org/10.1109/ICCNI.2017.8123782>
- Bağış, M., & Öztürk, O. (2020). Stratejik Yönetim Araştırmalarının Evrimi: Yaklaşımlar ve Mikro Görüşler Üzerinden Bir Değerlendirme. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 15(1), 347–370. <https://doi.org/10.17153/oguiibf.496482>
- Bain, J. S. (1956). Advantages of the Large Firm: Production, Distribution, and Sales Promotion. *Journal of Marketing*, 20(4), 336–346. <https://doi.org/10.1177/002224295602000402>
- Bakator, M., & Dragica, R. (2018). Deep Learning and Medical Diagnosis: A Review of Literature. *Multimodal Technologies and Interact*, 2(3).
- Bakoğlu, R., & Dinç, E. (2010). İŞLETME Düzeyinde Strateji Paradokslarının Mintzberg'in on Stratejik Yönetim Okulu Açısından Değerlendirilmesi - Evaluation of Business Level Strategy Paradoxes in Terms of Mintzberg's Ten Strategic Management Schools. *Öneri Dergisi*, 9(34), 57–69. <https://doi.org/10.14783/od.v9i34.1012000230>
- Balasko, B., Abonyi, J., & Feil, B. (2005). *Fuzzy clustering and data analysis toolbox; for use with matlab*. Hungary, University of Veszprem (C. 1). Department of Process Engineering.
- Baldi, P., & Hatfield, G. W. (2002). *DNA Microarrays and Gene Expression: From Experiments to Data Analysis and Modelings*. Cambridge University Press. <https://doi.org/10.1093/hmg/ddg053>
- Barney, J. (1991). Firm Resources and Sustained Competitive Advantage. *Journal of*

*Management*, 17(1), 99–120. <https://doi.org/10.1177/014920639101700108>

- Barney, J. B. (2018). Why resource-based theory's model of profit appropriation must incorporate a stakeholder perspective. *Strategic Management Journal*, 39(13), 3305–3325.
- Barney, J. B., & Clark, D. N. (2007). *Resource-based theory: Creating and sustaining competitive advantage*. OUP Oxford.
- Barton, C., Chettipally, U., Zhou, Y., Jiang, Z., Lynn-Palevsky, A., Le, S., ... Das, R. (2019). Evaluation of a machine learning algorithm for up to 48-hour advance prediction of sepsis using six vital signs. *Computers in Biology and Medicine*, 109, 79–84. <https://doi.org/10.1016/j.compbiomed.2019.04.027>
- Barzegar, R., Aalami, M. T., & Adamowski, J. (2020). Short-term water quality variable prediction using a hybrid CNN–LSTM deep learning model. *Stochastic Environmental Research and Risk Assessment*, 1–19.
- Basgall, M. J., Hasperu , W., Naiouf, M., Fern ndez, A., & Herrera, F. (2019). An analysis of local and global solutions to address big data imbalanced classification: A case study with smote preprocessing. *I inde Communications in Computer and Information Science* (C. 1050 CCIS, ss. 75–85). [https://doi.org/10.1007/978-3-030-27713-0\\_7](https://doi.org/10.1007/978-3-030-27713-0_7)
- Beam, A. L., & Kohane, I. S. (2017). Big Data and Machine Learning in Health Care. *JAMA*, 319(13).
- Begley, T. M., & Boyd, and D. (2003). For an interesting perspective on the need for strategists to maintain a global mind-set. *MIT Sloan Management Review*, 44(2), 25–32.
- Bellodi, E., Vagnoni, E., Bonvento, B., & Lamma, E. (2017). Economic and organizational impact of a clinical decision support system on laboratory test ordering. *BMC Medical Informatics and Decision Making*, 17(1), 179. <https://doi.org/10.1186/s12911-017-0574-6>
- Bendoly, E. (2013). *Excel Basics to Blackbelt: An Accelerated Guide to Decision Support Designs*.
- Bener, A., Alayoglu, N.,  atan, F., Torun, P., & Yilmaz, E. S. (2019). Health services management in Turkey: Failure or success?. *International journal of preventive medicine*, 10.
- Berger, T., Birnbaum, A., Bijur, P., Kuperman, G., & Gennis, P. (2010). A computerized alert screening for severe sepsis in emergency department patients increases lactate testing but

- does not improve inpatient mortality. *Applied Clinical Informatics*, 1(4), 394–407. <https://doi.org/10.4338/ACI-2010-09-RA-0054>
- Berisha- Namani, D. S. M., & Qehaja, M. S. A. (2013). Improving Decision Making with Information Systems Technology – A theoretical approach. *ILIRIA International Review*, 3(1), 49. <https://doi.org/10.21113/iir.v3i1.96>
- Berner, E. S., & La Lande, T. J. (2007). Overview of Clinical Decision Support Systems (ss. 3–22). Springer, New York, NY. [https://doi.org/10.1007/978-0-387-38319-4\\_1](https://doi.org/10.1007/978-0-387-38319-4_1)
- Berthold, M. R., Cebron, N., Dill, F., Di Fatta, G., Gabriel, T. R., Georg, F., ... Wiswedel, B. (2006). KNIME: The konstanz information miner. İçinde *4th International Industrial Simulation Conference 2006, ISC 2006* (ss. 58–61). EUROSIS. <https://doi.org/10.1145/1656274.1656280>
- Bezdek, C. J. (1973). *Fuzzy Mathematics in Pattern Classification*. Fuzzy mathematics in pattern classification. Cornell University. 28.03.2021 Tarihinde <https://ci.nii.ac.jp/naid/10006528387/adresinden> erişildi
- Bezdek, J C. (1981). Objective Function Clustering. İçinde *Pattern Recognition with Fuzzy Objective Function Algorithms* (ss. 43–93). Springer US. [https://doi.org/10.1007/978-1-4757-0450-1\\_3](https://doi.org/10.1007/978-1-4757-0450-1_3)
- Bezdek, James C. (1973). Cluster validity with fuzzy sets. *Journal of Cybernetics*, 3(3), 58–73. <https://doi.org/10.1080/01969727308546047>
- Bezdek, James C., Ehrlich, R., & Full, W. (1984). FCM: The fuzzy c-means clustering algorithm. *Computers and Geosciences*. [https://doi.org/10.1016/0098-3004\(84\)90020-7](https://doi.org/10.1016/0098-3004(84)90020-7)
- Bezdek, James C. (1975). Mathematical models for systematics and taxonomy. İçinde *8th International Conference on Numerical Taxonomy* (ss. 143–166).
- Bhatia, P. (2019). *Data Mining And Data Warehousing: Principles and Practical Techniques* (Cambridge).
- Bi, W. L., Hosny, A., Schabath, M. B., Giger, M. L., Birkbak, N. J., Mehrtash, A., . & Aerts, H. J. (2019). Artificial intelligence in cancer imaging: clinical challenges and applications. *CA: a cancer journal for clinicians*, 69(2), 127–157.
- Blagus, R., & Lusa, L. (2017). Gradient boosting for high-dimensional prediction of rare events. *Computational Statistics and Data Analysis*, 113, 19–37. <https://doi.org/10.1016/j.csda.2016.07.016>

- Bone, R., Balk, R., Cerra, F., Dellinger, R., Fein, A., Knaus, W., ... Sibbald, W. (2009). Definitions for sepsis and organ failure and guidelines for the use of innovative therapies in sepsis. The ACCP/SCCM Consensus Conference Committee. American College of Chest Physicians/Society of Critical Care Medicine. 1992. *undefined*.
- Bongomin, O., Yemane, A., Kembabazi, B., Malanda, C., Mwape, C., & M., Sheron Mpofo, N., Tigalana, D. (2020). Industry 4.0 disruption and its neologisms in major industrial sectors: A state of the art. *Journal of Engineering*.
- Bonini, C. (1963). Simulation of Information and Decision System in the Firm.
- Boon Som Ong, J., I-Cheng Chen, M., Cook, A. R., Chyi Lee, H., Lee, V. J., Tzer Pin Lin, R., ... Gan Goh, L. (2010). Real-Time Epidemic Monitoring and Forecasting of H1N1-2009 Using Influenza-Like Illness from General Practice and Family Doctor Clinics in Singapore. *PloS one*, 5(4). <https://doi.org/10.1371/journal.pone.0010036>
- Bora, D. J., & Gupta, D. A. K. (2014). A Comparative study Between Fuzzy Clustering Algorithm and Hard Clustering Algorithm. 30.04.2021 Tarihinde <http://arxiv.org/abs/1404.6059> adresinden erişildi
- Borges, A. F., Laurindo, F. J., Spínola, M. M., Gonçalves, R. F., & Mattos, C. A. (2021). The strategic use of artificial intelligence in the digital era: Systematic literature review and future research directions. International. *Journal of Information Management*, 57.
- Bourgeois, D. (2014). *Information Systems for Business and Beyond*. (T. S. Academy, Ed.), *Information Systems for Business and Beyond*.
- Bowers, A. J., & Zhou, X. (2019). Receiver operating characteristic area under the curve (AUC), 20–46.
- Bright, T. J., Wong, A., Dhurjati, R., Bristow, E., Bastian, L., Coeytaux, R. R., . & Wing, L. (2012). Effect of Clinical Decision-Support Systems: A Systematic Review. *Annals of Internal medicine*, 157(1), 29–43.
- Buch, V. H., Ahmed, I., & Maruthappu, M. (2018). Artificial intelligence in medicine: current trends and future possibilities. *British Journal of General Practice*.
- Bucholc, M., Ding, X., Wang, H., Glass, D. H., Wang, H., & Prasad, G. (2019). A practical computerized decision support system for predicting the severity of Alzheimer's disease of an individual. *Expert systems with applications*, 157-171.
- Burgess, M. (2017). The NHS is trialling an AI chatbot to answer your medical questions. 22.01.2022 Tarihinde <http://www.wired.co.uk/article/babylonnhs-chatbot-app>

adresinden erişildi

- Burnard, K., & Bhamra, R. (2011). Organisational resilience: development of a conceptual framework for organisational responses. *International Journal of Production Research*, 49(18), 5581–5599. <https://doi.org/10.1080/00207543.2011.563827>
- Burnes, B. (2004). *Managing Change: A Strategic Approach to Organisational Dynamics* (4th editio). Harlow: Prentice Hall.
- Callaway, D. W., Shapiro, N. I., Donnino, M. W., Baker, C., & Rosen, C. L. (2009). Serum lactate and base deficit as predictors of mortality in normotensive elderly blunt trauma patients. *Journal of Trauma - Injury, Infection and Critical Care*, 66(4), 1040–1044. <https://doi.org/10.1097/TA.0b013e3181895e9e>
- Canbolat, Z. N., & Silahtaroglu, G. (2020). An early prediction and diagnosis of sepsis in intensive care units: An unsupervised machine learning model. *Mugla Journal of Science and Technology*, 6(1), 32–40.
- Canbolat, Z. N., Silahtaroglu, G., Doguc, Ö., & Yilmaztürk, N. (2020). A machine learning approach to predict creatine kinase test results. *Emerging Science Journal*, 4(4), 283–296.
- Cao, Z. (2021). Mobile Phone GPS and Sensor Technology in College Students' Extracurricular Exercises. *Advances in Intelligent Systems and Computing*, 1283, 103–108. [https://doi.org/10.1007/978-3-030-62746-1\\_15](https://doi.org/10.1007/978-3-030-62746-1_15)
- Castaldo, S. (2007). Trust in market relationships. *Edward Elgar Publishing*.
- Chahal, H., Gupta, M., Bhan, N., & TCE, C. (2020). Operations management research grounded in the resource-based view: A meta-analysis. *International Journal of Production Economics*.
- Chandler, J. A. D. (1962). *Strategy and Structure: Chapters in the History of the American Industrial Enterprise*. BEARD GROUP INC.
- Chawla, N. V, Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). *SMOTE: Synthetic Minority Over-sampling Technique*. *Journal of Artificial Intelligence Research* (C. 16).
- Chen, Z., Zhang, X., & Zhang, Z. (2016). Clinical risk assessment of patients with chronic kidney disease by using clinical data and multivariate models. *International Urology and Nephrology*, 48(12), 2069–2075. <https://doi.org/10.1007/S11255-016-1346-4>
- Cheng, J. Z., Ni, D., Chou, Y. H., Qin, J., Tiu, C. M., Chang, Y. C., ... Chen, C. M. (2016).

- Computer-Aided Diagnosis with Deep Learning Architecture: Applications to Breast Lesions in US Images and Pulmonary Nodules in CT Scans. *Scientific Reports* 2016 6:1, 6(1), 1–13. <https://doi.org/10.1038/srep24454>
- Choi, E., Bahadori, M. T., Song, L., Stewart, W. F., & Sun, J. (2017). GRAM: graph-based attention model for healthcare representation learning. *Proceedings of the 23rd ACM SIGKDD international conference on knowledge discovery and data mining, Part F1296*, 787–795. <https://doi.org/10.1145/3097983.3098126>
- Choi, Edward, Bahadori, M. T., Schuetz, A., Stewart, W. F., & Sun, J. (2016). Doctor AI: Predicting Clinical Events via Recurrent Neural Networks. *JMLR Workshop and Conference Proceedings*, 56, 301–318.
- Churpek, M. M., & Edelson, D. P. (2016, Aralık 1). Moving beyond Single-Parameter Early Warning Scores for Rapid Response System Activation\*. *Critical Care Medicine*. Lippincott Williams and Wilkins. <https://doi.org/10.1097/CCM.0000000000002105>
- CodCoddington, D. C., Palmquist, L. E., & Trollinger, W. V. (1985). Strategies for survival in the hospital industry. *Harvard business review*, 63(3), 129-138. 03.03.2022 Tarihinde <https://europepmc.org/article/med/10300259> adresinden erişildi
- Coiera, E. (2003). *Guide to Health Informatics, 2Ed. Guide to Health Informatics, 2Ed.* <https://doi.org/10.1201/b13618>
- Collobert, R., & Weston, J. (2008). A unified architecture for natural language processing: Deep neural networks with multitask learning. İçinde *Proceedings of the 25th International Conference on Machine Learning* (ss. 160–167).
- Confusion Matrix in Machine Learning - Javatpoint. (y.y.). 27 Şubat 2022 Tarihinde <https://www.javatpoint.com/confusion-matrix-in-machine-learning> adresinden erişildi
- Contreras, I., & Vehi, J. (2018). Artificial intelligence for diabetes management and decision support: literature review. Journal of medical Internet research. *Journal of medical Internet research*, 20(5).
- Cornegruta, S., Bakewell, R., Withey, S., & Montana, G. (2016). Modelling radiological language with bidirectional long short-term memory networks. 24.09.2021 Tarihinde <https://www.himss.org/who-we-are> adresinden erişildi
- Coronado Munoz, A., Nawaratne, U., McMann, D., Ellsworth, M., Meliones, J., & Boukas, K. (2020). Late-Onset Neonatal Sepsis in a Patient with Covid-19. *New England Journal of Medicine*, 382(19), e49. <https://doi.org/10.1056/NEJMC2010614>



- COVID19 — Global Sepsis Alliance. (y.y.). Tarihinde 25 Nisan 2021, adresinden erişildi  
<https://www.global-sepsis-alliance.org/covid19>
- Curado, C., & Bontis, N. (2006). The knowledge-based view of the firm and its theoretical precursor. *International Journal of Learning and Intellectual Capital*, 3(4), 367–381.  
<https://doi.org/10.1504/IJLIC.2006.011747>
- Çürükoğlu, N. (2019). Imbalanced Dataset Problem in Classification Algorithms. *In 2019 1st International Informatics and Software Engineering Conference*, 1–5.
- Cyert, R., & March, J. (1963). *Organizational Behavior 2: Essential theories of process and structure*.
- Daft, R. L. (2004). *Organization theory and design*. South-Western Pub.
- Daft, Richard L., & Marcic, D. (2009). *Management: The New Workplace*. Florida: Evans Publishing Group.
- Dankwa-Mullan, I., Rivo, M., Sepulveda, M., Park, Y., Snowdon, J., & Rhee, K. (2019). Transforming diabetes care through artificial intelligence: the future is here. *liebertpub.com*, 22(3), 229–242. <https://doi.org/10.1089/pop.2018.0129>
- Dasgupta, M., & Gupta, R. K. (2009). Innovation in Organizations. *Global Business Review*, 10(2), 203–224. <https://doi.org/10.1177/097215090901000205>
- Davenport, T. H. (2005). *Thinking for a living: how to get better performances and results from knowledge workers*. Harvard Business Press.
- Davenport, T. H. (2018). From analytics to artificial intelligence. *Journal of Business Analytics*, 1(2), 73–80.
- Davenport, T., & Review, R. B. (2018). Big companies are embracing analytics, but most still don't have a data-driven culture. *Harvard Business*. 12 Kasım 2021 Tarihinde [https://www.academia.edu/download/60889812/Big\\_Companies\\_Embracing\\_Analytics\\_20191013-23253-pty110.pdf](https://www.academia.edu/download/60889812/Big_Companies_Embracing_Analytics_20191013-23253-pty110.pdf) adresinden erişildi
- Davis, G. B. (1974). *Management information systems: Conceptual foundations, structure and development*. New York: McGraw-Hill Book Company.
- Della Mea, V. (2001). What is e-Health (2): The death of telemedicine? *J Med Internet Res* 2001;3(2):e22 <https://www.jmir.org/2001/2/e22>, 3(2), e834.  
<https://doi.org/10.2196/JMIR.3.2.E22>
- Deloitte Life Sciences & Healthcare Group. (2015). “Connected health: How digital

technology is transforming health and social care”.

- Demsetz, H. (1973). Industry Structure, Market Rivalry, and Public Policy. *The Journal of Law and Economics*, 16(1), 1–9. <https://doi.org/10.1086/466752>
- Desautels, T., Calvert, J., Hoffman, J., Jay, M., Kerem, Y., Shieh, L., ... Das, R. (2016). Prediction of Sepsis in the Intensive Care Unit With Minimal Electronic Health Record Data: A Machine Learning Approach. *JMIR Medical Informatics*, 4(3), e28. <https://doi.org/10.2196/medinform.5909>
- Developers, G. (y.y.). Classification: ROC Curve and AUC. Tarihinde 28 Şubat 2022, adresinden erişildi <https://developers.google.com/machine-learning/crash-course/classification/roc-and-auc>
- Dong, Y., Xu, L., Fan, Y., Xiang, P., Gao, X., Chen, Y., ... Ge, Q. (2019). A novel surgical predictive model for Chinese Crohn's disease patients. *Medicine*, 98(46), e17510. <https://doi.org/10.1097/MD.00000000000017510>
- Dorsett, M., Kroll, M., Smith, C. S., Asaro, P., Liang, S. Y., & Moy, H. P. (2017). qSOFA Has Poor Sensitivity for Prehospital Identification of Severe Sepsis and Septic Shock. *Prehospital Emergency Care*, 21(4), 489–497. <https://doi.org/10.1080/10903127.2016.1274348>
- Du, W., Wang, Y., & Qiao, Y. (2017). Rpan: An end-to-end recurrent pose-attention network for action recognition in videos. *In Proceedings of the IEEE international conference on computer vision*, 3725–3734.
- Dunn, J. C. (1973). A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters. *Journal of Cybernetics*. <https://doi.org/10.1080/01969727308546046>
- Dunning, J. H., & Lundan, S. M. (2008). Institutions and the OLI paradigm of the multinational enterprise. *Asia Pacific Journal of Management*, 25(4), 573–593. <https://doi.org/10.1007/s10490-007-9074-z>
- Dyer, J. H., & Singh, H. (1998). The relational view: Cooperative strategy and sources of interorganizational competitive advantage. *Academy of management review*, 23(4), 660–679.
- Eddy, D. M. (1986). Successes and challenges of medical decision making. *Health affairs (Project Hope)*, 5(2), 108–115. <https://doi.org/10.1377/hlthaff.5.2.108>
- Eden, R., Ballantine, C., Burton-Jones, A., Staib, A., & Sullivan, C. (2021). The

transformation of Australia's first large digital hospital: A teaching case. İçinde *International Conference on Information Systems, ICIS 2020 - Making Digital Inclusive: Blending the Local and the Global*. 10.03.2022 Tarihinde <https://eprints.qut.edu.au/206852> /adresinden erişildi

- Egan, J. P., & Egan, J. P. (1975). *Signal detection theory and ROC-analysis*. Academic press.
- Eisenhardt, K. M., & Martin, J. A. (2000). Dynamic capabilities: what are they? *Strategic management journal*, 21(10–11), 1105–1121.
- El-bastawissy, A., Nyo Aye, K., Saddam, E., El-Bastawissy, A., O Mokhtar, H. M., & Hazman, M. (2020). Lake Data Warehouse Architecture for Big Data Solutions. *IJACSA International Journal of Advanced Computer Science and Applications*, 11(8). 11.02.2021 Tarihinde [https://www.academia.edu/download/68340269/Paper\\_54-Lake\\_Data\\_Warehouse\\_Architecture.pdf](https://www.academia.edu/download/68340269/Paper_54-Lake_Data_Warehouse_Architecture.pdf) adresinden erişildi
- El-Ebiary, Y. A. B., Al-Sammarraie, N. A., Al Moaiad, Y., & Alzubi, M. M. S. (2017). The impact of Management Information System in educational organizations processes. *2016 IEEE Conference on e-Learning, e-Management and e-Services, IC3e 2016*, 166–169. <https://doi.org/10.1109/IC3e.2016.8009060>
- Elhassan, T., & Aljurf, M. (2016). Classification of Imbalance Data using Tomek Link (T-Link) Combined with Random Under-sampling (RUS) as a Data Reduction Method. *Global Journal of Technology and Optimization*, 01(S1). <https://doi.org/10.4172/2229-8711.s1111>
- Elsheikh, A., Sharshir, S., Elaziz, M. A., & Energy, A. K. (2019). Modeling of solar energy systems using artificial neural network: A comprehensive review. *Solar Energy*, 180, 622–639.
- Engert, S., Rauter, R., & Baumgartner, R. J. (2016). Exploring the integration of corporate sustainability into strategic management: a literature review. *Journal of cleaner production*, 112, 2833-2850. <https://doi.org/10.1016/j.jclepro.2015.08.031>
- Esfahani, P., Mosadeghrad, A. M., & Akbarisari, A. (2018). The success of strategic planning in health care organizations of Iran. *emerald.com*. <https://doi.org/10.1108/IJHCQA-08-2017-0145>
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *nature*, 542(7639), 115–118.

- Eynard, B., & Cherfi, Z. (2020). Digital and organizational transformation of industrial systems. *Computers & Industrial Engineering*, 139.
- Fagerström, J., Bång, M., Wilhelms, D., & Chew, M. S. (2019). LiSep LSTM: a machine learning algorithm for early detection of septic shock. *Scientific Reports*, 9(1), 1–8.
- Fairchild, K. D., Lake, D. E., Kattwinkel, J., Moorman, J. R., Bateman, D. A., Grieve, P. G., ... Sahni, R. (2017). Vital signs and their cross-correlation in sepsis and NEC: A study of 1,065 very-low-birth-weight infants in two NICUs. *Pediatric Research*, 81(2), 315–321. <https://doi.org/10.1038/pr.2016.215>
- Fang, W., Love, P., Luo, H., & Ding, L. (2020). Computer vision for behaviour-based safety in construction: A review and future directions. *Advanced Engineering Informatics*, (43). <https://www.sciencedirect.com/science/article/pii/S1474034619305531>
- Farboodi, M., Mihet, R., Philippon, T., & Veldkamp, L. (2019). Big data and firm dynamics. *n AEA papers and proceedings*, 109, 38–42. <https://www.aeaweb.org/doi/10.1257/pandp.20191001>
- Fennell, M. L., & Alexander, J. A. (1993). Perspectives on Organizational Change in the US Medical Care Sector. *Annual Review of Sociology*, 19(1), 89–112. <https://doi.org/10.1146/ANNUREV.SO.19.080193.000513>
- Fernández, A., García, S., Galar, M., Prati, R. C., Krawczyk, B., & Herrera, F. (2018). *Learning from Imbalanced Data Sets. Learning from Imbalanced Data Sets*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-98074-4>
- Figuroa-Perez, J. F., Leyva-Lopez, J. C., Santillan, L. C., Contreras, E. O. P., & Sánchez, P. J. (2019). The use of marketing decision support systems for new product design: a review. *International Journal of Computational Intelligence Systems*, 12(2), 761.
- Figuroa, C. A., Harrison, R., Chauhan, A., & Meyer, L. (2019). Priorities and challenges for health leadership and workforce management globally: A rapid review. *BMC Health Services Research*, 19(1), 1–11. <https://doi.org/10.1186/S12913-019-4080-7/TABLES/3>
- Flores-Sintas, A., Cadenas, J. M., & Martin, F. (1999). Membership functions in the fuzzy C-means algorithm. *Fuzzy Sets and Systems*, 101(1), 49–58. [https://doi.org/10.1016/S0165-0114\(97\)00062-6](https://doi.org/10.1016/S0165-0114(97)00062-6)
- Fogel, A. L., & Kvedar, J. C. (2018). Artificial intelligence powers digital medicine. *NPJ digital medicine*, 1(1), 1–4.
- Forbes Insights. (2019). AI And Healthcare: A Giant Opportunity. 18.01.2021 Tarihinde

<https://www.forbes.com/sites/insights-intelai/2019/02/11/ai-and-healthcare-a-giant-opportunity/?sh=49a9b3404c68adresinden> erişildi

Ford, M. (2020). *Rise of the Robots: Technology and the Threat of a Jobless Future* (8. Edition).

Fotouhi, S., Asadi, S., & Kattan, M. W. (2019). A comprehensive data level analysis for cancer diagnosis on imbalanced data. *Journal of Biomedical Informatics*.  
<https://doi.org/10.1016/j.jbi.2018.12.003>

Franceschetti, D. R. (2018). *Principles of Robotics & Artificial Intelligence*.

Frank, A. G., Dalenogare, L. S., & Ayala, N. F. (2019). Industry 4.0 technologies: Implementation patterns in manufacturing companies. *International Journal of Production*, (210), 15–26. <https://doi.org/10.1016/j.ijpe.2019.01.004>

Frantz, R. (2003). (2003). Herbert Simon. Artificial intelligence as a framework for understanding intuition. *Journal of Economic Psychology*, 24(2), 265-277.  
[https://doi.org/10.1016/S0167-4870\(02\)00207-6](https://doi.org/10.1016/S0167-4870(02)00207-6)

Fred Guyton. (2021). *Feature Selection on Permissions, Intents and APIs for Android Malware Detection*. *Journal of Chemical Information and Modeling*. College of Computing and Engineering Nova Southeastern University.

Freeman, K., Dinnes, J., Chuchu, N., Takwoingi, Y., Bayliss, S. E., Matin, R. N., & Deeks, J. J. (2020). Algorithm based smartphone apps to assess risk of skin cancer in adults: systematic review of diagnostic accuracy studies. *bmj*. <https://doi.org/10.1111/bjd.19502>

Frigui, H., & Krishnapuram, R. (1999). A robust competitive clustering algorithm with applications in computer vision. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 21(5), 450–465. <https://doi.org/10.1109/34.765656>

Garbuio, M., & Lin, N. (2019). Artificial intelligence as a growth engine for health care startups: Emerging business models. *California Management Review*, 61(2), 59-83.

García, S, Luengo, J., & Herrera, F. (2015). *Data preprocessing in data mining*. 10.09.2020 Tarihinde <https://link.springer.com/content/pdf/10.1007/978-3-319-10247-4.pdf> adresinden erişildi

García, Salvador, Luengo, J., & Herrera, F. (2015). *Data Preprocessing in Data Mining*. *Intelligent Systems Reference Library* (C. 72).

García, Salvador, Ramírez-Gallego, S., Luengo, J., Benítez, J. M., & Herrera, F. (2016). Big

- data preprocessing: methods and prospects. *Big Data Analytics*, 1(1), 1–22. <https://doi.org/10.1186/s41044-016-0014-0>
- Garg, A. X., Adhikari, N. K., McDonald, H., R.-A., M. P., D., P. J., Beyene, J., Haynes, R. B., & Haynes, R. B. (2005). Effects of computerized clinical decision support systems on practitioner performance and patient outcomes: a systematic review. *Jama*, 293(10), 1223–1238. <https://doi.org/10.1186/1748-5908-5-12>
- Gell-Mann, M. (2002). What Is Complexity? (ss. 13–24). [https://doi.org/10.1007/978-3-642-50007-7\\_2](https://doi.org/10.1007/978-3-642-50007-7_2)
- Géron, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. O'Reilly Media.
- Ginter, P., Duncan J., W., & Swayne, L. (2018). *Strategic Management of Health Care Organizations* (8.). WILEY.
- Glauner, P., Plugmann, P., & Lorzynski, G. (2021). *Digitalization in Healthcare* (Springer I).
- Godbole, S. (2002). Exploiting confusion matrices for automatic generation of topic hierarchies and scaling up multi-way classifiers. *Annual Progress Repo.*
- Goldenberg, S. L., Nir, G., & Salcudean, S. E. (2019). A new era: artificial intelligence and machine learning in prostate cancer. *Nature Reviews Urology*, 16(7), 391–403.
- Goldsmith, S., & Crawford, S. (2014). *The responsive city: Engaging communities through data-smart governance*. John Wiley & Sons.
- Gorry, G. A., & Morton, M. S. S. (1971). A FRAMEWORK FOR MANAGEMENT INFORMATION SYSTEMS. 30.03.2019 Tarihinde [https://dspace.mit.edu/bitstream/handle/1721.1/47936/frameworkformana00gorr.pdf?sequence=adresinden eriřildi](https://dspace.mit.edu/bitstream/handle/1721.1/47936/frameworkformana00gorr.pdf?sequence=adresinden%20eriřildi)
- Granovetter, M. (1985). Economic Action and Social Structure: The Problem of Embeddedness. *American Journal of Sociology*, 91(3), 481–510. <https://doi.org/10.1086/228311>
- Granovetter, M. S. (1973). The Strength of Weak Ties. *American Journal of Sociology*, 78(6), 1360–1380. <https://doi.org/10.1086/225469>
- Grant, R. M. (1996). Toward a knowledge-based theory of the firm. *Strategic management journal*, 17(S(2)), 109-122.
- Grant, Robert M. (1991). Porter's 'competitive advantage of nations': An assessment.

*Strategic Management Journal*, 12(7), 535–548.  
<https://doi.org/10.1002/smj.4250120706>

- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., & Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern Recognition*, (77), 354–377.
- Guan, W., Ni, Z., Hu, Y., Liang, W., Ou, C., He, J., ... Zhong, N. (2020). Clinical Characteristics of Coronavirus Disease 2019 in China. *New England Journal of Medicine*, 382(18), 1708–1720. <https://doi.org/10.1056/NEJMoa2002032>
- Gulati, R., Nohria, N., & Zaheer, A. (2000). Strategic networks. *Strategic m. anagement journal*, 21(3), 203–215.
- Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., ... Webster, D. R. (2016). Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. *JAMA*, 316(22), 2402–2410. <https://doi.org/10.1001/JAMA.2016.17216>
- Gultepe, E., Green, J. P., Nguyen, H., Adams, J., Albertson, T., & Tagkopoulos, I. (2014). From vital signs to clinical outcomes for patients with sepsis: A machine learning basis for a clinical decision support system. *Journal of the American Medical Informatics Association*, 21(2), 315–325. <https://doi.org/10.1136/amiajnl-2013-001815>
- Guo, S., Liu, Y., Chen, R., Sun, X., & Wang, X. (2019). Improved SMOTE Algorithm to Deal with Imbalanced Activity Classes in Smart Homes. *Neural Processing Letters*, 50(2), 1503–1526. <https://doi.org/10.1007/s11063-018-9940-3>
- Guo, Y., Hao, Z., Zhao, S., Gong, J., & Yang, F. (2020). Artificial intelligence in health care: bibliometric analysis. *Journal of Medical Internet Research*, 22(7).
- Gupta, S., Justy, T., Kamboj, S., Kumar, A., & Kristoffersen, E. (2021). Big data and firm marketing performance: Findings from knowledge-based view. *Technological Forecasting and Social Change*, 171.
- Ha, T. M., & Bunke, H. (1997). Off-line, handwritten numeral recognition by perturbation method. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(5), 535–539. <https://doi.org/10.1109/34.589216>
- Halm, E. A., Fine, M. J., Marrie, T. J., Coley, C. M., Kapoor, W. N., Obrosky, D. S., & Singer, D. E. (1998). Time to clinical stability in patients hospitalized with community-acquired pneumonia: implications for practice guidelines. *Jama*, 279(18), 1452-1457
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2019). *Multivariate Data Analysis*

(Eighth Edi).

- Haixiang, G., Yijing, L., Shang, J., Mingyun, G., Yuanyue, H., & Bing, G. (2017). Learning from class-imbalanced data: Review of methods and applications. *Expert Systems with Applications*. <https://doi.org/10.1016/j.eswa.2016.12.035>
- Han, Didi, Zhang, L., Zheng, S., Xu, F., Li, C., Yang, R., ... Lyu, J. (2021). Prognostic Value of Blood Urea Nitrogen/Creatinine Ratio for Septic Shock: An Analysis of the MIMIC-III Clinical Database. *BioMed Research International*, 2021. <https://doi.org/10.1155/2021/5595042>
- Han, Jiawei, Kamber, M., & Pei, J. (2012). *Introduction. Data Mining*. <https://doi.org/10.1016/b978-0-12-381479-1.00001-0>
- Harrison, J. S., & Thompson, S. (2014). *Strategic management of healthcare organizations: A stakeholder management approach*. Business Expert Press.
- Hasan, F. F. (2018). A Review Study of Information Systems. *International Journal of Computer Applications*, 179(18), 15–19. <https://doi.org/10.5120/ijca2018916307>
- Hayek, F. A. (1945). The use of knowledge in society. *The American economic review*, 35(4).
- Helfat, C. E., & Raubitschek, R. S. (2018). Dynamic and integrative capabilities for profiting from innovation in digital platform-based ecosystems. *Research policy*, 47(8), 1391-1399.
- Hemens, B. J., Holbrook, A., Tonkin, M., Mackay, J. A., Weise-Kelly, L., Navarro, T., ... Brian Haynes, R. (2011). Computerized clinical decision support systems for drug prescribing and management: A decision-maker-researcher partnership systematic review. *Implementation Science*, 6(1). <https://doi.org/10.1186/1748-5908-6-89>
- Henry, K. E., Hager, D. N., Pronovost, P. J., & Saria, S. (2015). A targeted real-time early warning score (TREWScore) for septic shock. *Science Translational Medicine*, 7(299). <https://doi.org/10.1126/scitranslmed.aab3719>
- HIMSS Analitik. Nedir? (2021). 22.09.2020 Tarihinde <https://himsseurasia.com/himss-analitik-nedir/adresinden-erişildi>
- Hinton, G., Deng, L., Yu, D., & Dahl, G. (2012). Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. *ieeexplore.ieee.org*, 29(6), 82–97.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8),



1735–1780.

- Holley, K. L., & Becker, S. (2021). *AI-First Healthcare: AI Applications in the Business and Clinical Management of Health*. O'Reilly Media.
- Horowitz, M. C., Allen, G. C., Kania, E. B., & Scharre, P. (2018). *Strategic competition in an era of artificial intelligence*. Center for a New American.
- Hu, J., Ray, B. K., & Singh, M. (2007). Statistical methods for automated generation of service engagement staffing plans. *IBM Journal of Research and Development*, 51(3.4), 281–193.
- Huang, B.-N., Hwang, M. J. J., & Yang, C. W. W. (2008). Causal relationship between energy consumption and {GDP} growth revisited: A dynamic panel data approach. *Ecological Economics*, 67(1), 41–54. <https://doi.org/10.1016/j.ecolecon.2007.11.006>
- Huang, J., & Ling, C. X. (2005). Using AUC and accuracy in evaluating learning algorithms. *IEEE Transactions on knowledge and Data Engineering*, 17(3), 299–310.
- Hunink, M. M., Weinstein, M. C., Wittenberg, E., Drummond, M. F., & Pliskin, J. S., Wong, J. B. Glasziou, P. P. (2014). *Decision making in health and medicine: integrating evidence and values*. (Cambridge).
- Hunt, J., & Gauthier-Loiselle. (2010). M. How much does immigration boost innovation? *American Economic Journal: Macroeconomics*, 2(2), 31–56.
- Iansiti, M., & Review, K. L. (2020). From Disruption to Collision: The New Competitive Dynamics. *MIT Sloan Management*, 61(3), 34–39.
- Ilić, D., & Marković, B. (2015). The possibility of applying artificial intelligence in the modern environment.
- Iriawan, N., Pravitasari, A. A., Fithriasari, K., Irhamah, Purnami, S. W., & Ferriastuti, W. (2018). Comparative study of Brain Tumor Segmentation using Different Segmentation Techniques in Handling Noise.
- Islam, M. M., Poly, T. N., Walther, B. A., Nasrin, T., Walther, B. A., Wu, C.-C., ... Jack, (. (2019). Prediction of Sepsis Patients Using Machine Learning Approach: A Meta-Analysis. *Computer Methods and Programs in Biomedicine*, 170, 1–9. <https://doi.org/10.1016/j.cmpb.2018.12.027>
- Iyer, D. N., & Miller, K. D. (2008). Performance feedback, slack, and the timing of acquisitions. *Academy of Management Journal*, 51(4), 808-822.

- J.Sousa, K., & Oz, E. (2014). *Management information systems for the information age seventh edition*.
- Jain, A. K., & Flynn, P. J. (1996). Image segmentation using clustering. *IEEE Press, Piscataway, NJ*, 65–83.
- Jain, A. K. (2010). Data clustering: 50 years beyond K-means. *Pattern recognition letters*, 31(8), 651–666.
- Jain, A. K., Murty, M. N., & Flynn, P. J. (1999). Data clustering: A review. *ACM Computing Surveys*, 31(3), 264–323. <https://doi.org/10.1145/331499.331504>
- Janani, R., & Vijayarani, S. (2019). Text document clustering using Spectral Clustering algorithm with Particle Swarm Optimization. *Expert Systems with Applications*, 134, 192–200. <https://doi.org/10.1016/j.eswa.2019.05.030>
- Jarzabkowski, P. (2005). Strategy as practice: An activity based approach.
- Jarzabkowski, P., Kaplan, S., Seidl, D., & Whittington, R. (2016). On the risk of studying practices in isolation: Linking what, who, and how in strategy research. *Strategic Organization*, 14(3), 248–259.
- Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., ... Wang, Y. (2017). Artificial intelligence in healthcare: Past, present and future. *Stroke and Vascular Neurology*, 2(4), 230–243. <https://doi.org/10.1136/svn-2017-000101>
- Jo. (2021). *Machine Learning Foundations: Supervised, Unsupervised, and Advanced Learning*.
- Johnson, A., Pollard, T., & Mark, R. (2016). No Title. *MIMIC-III, a freely accessible critical care database*. <https://doi.org/https://doi.org/10.13026/C2XW26>
- Johnson, G., Langley, A., Melin, L., & Whittington, R. (2003). *Strategy as practice: research directions and resources*. .
- Johnson, A. E. W., Pollard, T. J., Shen, L., Lehman, L.-W. H., Feng, M., Ghassemi, M., ... Mark, R. G. (2016). Data Descriptor: MIMIC-III, a freely accessible critical care database. <https://doi.org/10.1038/sdata.2016.35>
- Johnson, K. W., Torres Soto, J., Glicksberg, B. S., Shameer, K., Miotto, R., Ali, M., & Dudley, J. T. (2018). Artificial intelligence in cardiology. *Journal of the American College of Cardiology*, 71(23), 2668–2679.
- Jolliffe, I. T. (2002). Principal Component Analysis for Special Types of Data. *Principal*

*Component Analysis*, 338–372. [https://doi.org/10.1007/0-387-22440-8\\_13](https://doi.org/10.1007/0-387-22440-8_13)

- Jones, B. V., Begley, M., Hill, C., Gahan, C. G. M., & Marchesi, J. R. (2008). Functional and comparative metagenomic analysis of bile salt hydrolase activity in the human gut microbiome. *Proceedings of the National Academy of Sciences*, *105*(36), 13580–13585. <https://doi.org/10.1073/pnas.0804437105>
- Jordan, J. (2017). Evaluating a machine learning model. Tarihinde 27 Kasım 2021, adresinden erişildi <https://www.jeremyjordan.me/evaluating-a-machine-learning-model/>
- Kam, H. J., & Kim, H. Y. (2017). Learning representations for the early detection of sepsis with deep neural networks. *Computers in Biology and Medicine*, *89*, 248–255. <https://doi.org/10.1016/j.compbiomed.2017.08.015>
- Kamei, Y., Monden, A., Matsumoto, S., Kakimoto, T., & Matsumoto, K. I. (2007). The effects of over and under sampling on fault-prone module detection.
- Kansal, T., Bahuguna, S., Singh, V., & Choudhury, T. (2018). Customer Segmentation using K-means Clustering. İçinde *Proceedings of the International Conference on Computational Techniques, Electronics and Mechanical Systems, CTEMS 2018* (ss. 135–139). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/CTEMS.2018.8769171>
- Kaplan, A., & Haenlein, M. (2019). Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*, *62*(1), 15–25. <https://doi.org/10.1016/j.bushor.2018.08.004>
- Kaukonen, K.-M., Bailey, M., Pilcher, D., Cooper, D. J., & Bellomo, R. (2015). Systemic Inflammatory Response Syndrome Criteria in Defining Severe Sepsis. *New England Journal of Medicine*, *372*(17), 1629–1638. <https://doi.org/10.1056/nejmoa1415236>
- Kaul, V., Enslin, S., & Gross, S. A. (2020). History of artificial intelligence in medicine. *Gastrointestinal endoscopy*, *92*(4), 807-812.
- Kaur, H., Pannu, H. S., & Malhi, A. K. (2019, Ağustos 1). A systematic review on imbalanced data challenges in machine learning: Applications and solutions. *ACM Computing Surveys*. Association for Computing Machinery. <https://doi.org/10.1145/3343440>
- Kawamoto, K, Houlihan, C., Balas, E., & Lobach, D. (2005). Improving clinical practice using clinical decision support systems: a systematic review of trials to identify features critical to success. *bmj.com*, *330*(7494).
- Kelleher, J. D., Mac Namee, B., & D'arcy, A. (2020). *Fundamentals of machine learning for*

*predictive data analytics: algorithms, worked examples, and case studies*. MIT Press.

- Kent, J. (2020). How Machine Learning is Transforming Clinical Decision Support Tools. 21 Kasım 2021 Tarihinde <https://healthitanalytics.com/features/how-machine-learning-is-transforming-clinical-decision-support-tools> adresinden erişildi
- Kermany, D. S., Goldbaum, M., Cai, W., Valentim, C. C. S., Liang, H., Baxter, S. L., ... Zhang, K. (2018). Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning. *Cell*, 172(5), 1122-1131.e9. <https://doi.org/10.1016/J.CELL.2018.02.010>
- Keskin, H., İpek, K., & Akgün, A. E. (2016). *Örgüt Teorisi*. Ankara: Nobel Yayınevi.
- Khan, S., & Yairi, T. (2018). A review on the application of deep learning in system health management. *Mechanical Systems and Signal Processing*, 107, 241–265.
- Kherif, F., & Latypova, A. (2020). Principal component analysis. *Machine Learning: Methods and Applications to Brain Disorders*, 209–225. <https://doi.org/10.1016/B978-0-12-815739-8.00012-2>
- Kimball, J. . R. (2004). *The Data Warehouse ETL Toolkit Practical Techniques for Extracting, Cleaning, Conforming and Delivering Data*. Canada: Wiley Publishing.
- Kimberly, J. R., & Zajac, E. J. (1985). Strategic adaptation in health care organizations: Implications for theory and research. *Medical care review*, 42(2), 267-302.
- King, R. S. (2016). *Cluster Analysis And Data Mining*.
- Kingston, A., Robinson, L., Booth, H., Knapp, M., & Jagger, C. (2018). Projections of multi-morbidity in the older population in England to 2035: estimates from the Population Ageing and Care Simulation (PACSim) model., 47(6), 374–380.
- Kiron, D., & Review, M. S. (2019). Strategy for and with AI. *MIT Sloan Management*, 4, 30–35.
- Koçel, T. (2013). *İşletme Yöneticiliği*. Beta Basım Yayım.
- Kogut, B., & Zander, U. (1992). Knowledge of the firm, combinative capabilities, and the replication of technology. *Organization Science*, 3(3), 383–397. <https://doi.org/10.1002/smj.360>
- Kohn, L. T., Corrigan, J. M., & Donaldson, M. S. (2000). *To Err Is Human: Building a Safer Health System*. 23.02.2022 Tarihinde <http://www.nap.edu/catalog/9728.html> adresinden erişildi

- Kreps, G., & Counseling, L. N. (2013). Artificial intelligence and immediacy: designing health communication to personally engage consumers and providers. *Patient education and counseling*, 92(2), 205–210. <https://doi.org/10.1016/j.pec.2013.04.014>
- Krittanawong, C., Virk, H., Bangalore, S., & Reports, Z. W. (2020). Machine learning prediction in cardiovascular diseases: a meta-analysis. *nature.com*, 10(1), 1–11. 20.02.2021 Tarihinde <https://www.nature.com/articles/s41598-020-72685-1> adresinden erişildi
- Krittanawong, C., Zhang, H., Wang, Z., Aydar, M., & Kitai, T. (2017). Artificial Intelligence in Precision Cardiovascular Medicine. *Journal of the American College of Cardiology*, 69(21), 2657–2664. <https://doi.org/10.1016/J.JACC.2017.03.571>
- Krizhevsky, A., Sutskever, I., & ACM, G. H. (2012). ImageNet classification with deep convolutional neural networks. *Advances in neural information processing systems*, (25), 1097–1105. <https://doi.org/10.1145/3065386>
- Krupinski, E. A. (2021). Evaluating AI Clinically—It’s Not Just ROC AUC!. *Radiology*, 298(1), 47-48. *Radiology*, 298(1), 47–48.
- Kumar, A., Roberts, D., Wood, K. E., Light, B., Parrillo, J. E., Sharma, S., ... Cheang, M. (2006). Duration of hypotension before initiation of effective antimicrobial therapy is the critical determinant of survival in human septic shock. *Critical Care Medicine*, 34(6), 1589–1596. <https://doi.org/10.1097/01.CCM.0000217961.75225.E9>
- Lakhani, Paras, & Sundaram, B. (2017). Deep learning at chest radiography: Automated classification of pulmonary tuberculosis by using convolutional neural networks. *Radiology*, 284(2), 574–582. <https://doi.org/10.1148/RADIOL.2017162326>
- Langston, J. (2017). New app could use smartphone selfies to screen for pancreatic cancer. 15.04.2020 Tarihinde <https://www.washington.edu/news/2017/08/28/new-app-uses-smartphone-selfies-to-screen-for-pancreatic-cancer/> adresinden erişildi
- Laudon, K. C., & Laudon, J. P. (2018). *Management information systems: managing the digital firm*. (15.). Pearson.
- Lave, J., & Wenger, E. (1991). *Situated Learning: Legitimate Peripheral Participation*. Cambridge university press.
- Lee, T., & Porter, M. (2013). *The strategy that will fix healthcare*. *Harvard Business Review*. (C. 2). 19.03.2021 Tarihinde <https://pdfs.semanticscholar.org/21d0/2c9895327f4413a63bba7215507e5e598ed2.pdf>

adresinden erişildi

- Leih, S., & Teece, D. (2016). Campus leadership and the entrepreneurial university: A dynamic capabilities perspective. *Academy of management Perspectives*, 30(2), 182-210.
- Li, H., Deng, Z., & Chiang, H. (2020). Lightweight and resource-constrained learning network for face recognition with performance optimization. *Sensors*, 20(21), 6114.
- Licklider, J. C. R. (1960). Man-Computer Symbiosis. *IRE Transactions on Human Factors in Electronics, HFE-1*(1), 4–11. <https://doi.org/10.1109/THFE2.1960.4503259>
- Lim, W. Y., Chen, C. H. J., Ma, Y., Chen, M. I. C., Lee, V. J. M., Cook, A. R., ... Chia, K. S. (2011). Risk factors for pandemic (H1N1) 2009 seroconversion among adults, Singapore, 2009. *Emerging Infectious Diseases*, 17(8), 1455–1462. <https://doi.org/10.3201/eid1708.101270>
- Lin, H. (2008). Method of image segmentation on high-resolution image and classification for land covers. İçinde *Proceedings - 4th International Conference on Natural Computation, ICNC 2008* (C. 5, ss. 563–566). <https://doi.org/10.1109/ICNC.2008.870>
- Lin, Y., & Wu, L. Y. (2014). Exploring the role of dynamic capabilities in firm performance under the resource-based view framework. *Journal of business research*, 67(3), 407-413.
- Lison, P. (2015). An introduction to machine learning. *Language Technology Group*, 1–35.
- Liu, J., Pan, Y., Li, M., Chen, Z., & L, T. (2018). Applications of deep learning to MRI images: A survey. *ieeexplore.ieee.org*, 1(1), 1–18.
- Liu, V. X., Fielding-Singh, V., Greene, J. D., Baker, J. M., Iwashyna, T. J., Bhattacharya, J., & Escobar, G. J. (2017). The timing of early antibiotics and hospital mortality in sepsis. *American Journal of Respiratory and Critical Care Medicine*, 196(7), 856–863. <https://doi.org/10.1164/rccm.201609-1848OC>
- Liu, Y., Zhang, X., Chen, J., & Chao, H. (2019). A Validity Index for Fuzzy Clustering Based on Bipartite Modularity. *Journal of Electrical and Computer Engineering*, 2019. <https://doi.org/10.1155/2019/2719617>
- Lo, R. S. L., Leung, L. Y., Brabrand, M., Yeung, C. Y., Chan, S. Y., Lam, C. C. Y., ... Graham, C. A. (2019). qSOFA is a Poor Predictor of Short-Term Mortality in All Patients: A Systematic Review of 410,000 Patients. *Journal of Clinical Medicine*, 8(1), 61. <https://doi.org/10.3390/jcm8010061>
- López-Collazo, E., Avendaño-Ortiz, J., Martín-Quirós, A., & Aguirre, L. A. (2020). Immune

- Response and COVID-19: A mirror image of Sepsis. *International Journal of Biological Sciences*, 16(14), 2479–2489. <https://doi.org/10.7150/ijbs.48400>
- Lovejoy, C. A. (2019). Technology and mental health: the role of artificial intelligence. *European Psychiatry*, 55, 1–3.
- Luftman, J., & Kempaiah, R. (2007). An Update on Business-IT Alignment: "A Line" Has Been Drawn. *MIS Quarterly Executive*, 6(3).
- M., B., & Esen, S. (2012). Strategic approaches to create and sustainable for competitive advantage. *Social Sciences*, 7(2), 89–107.
- Madani, S. (2009). Mining changes in customer purchasing behavior : a data mining approach. 03.06.2021 Tarihinde <http://urn.kb.se/resolve?urn=urn:nbn:se:ltu:diva-52716> adresinden erişildi
- Mahoney, J. T., & Pandian, J. R. (1992). The resource-based view within the conversation of strategic management. *Strategic Management Journal*, 13(5), 363–380.
- Maimon, O. Z., & Rokach, L. (2014). *Data mining with decision trees: theory and applications*. World scientific.
- Makridakis, S. (2017). The forthcoming Artificial Intelligence (AI) revolution: Its impact on society and firms. *Futures*, 46–60. <https://doi.org/10.1016/j.futures.2017.03.006>
- Mamoshina, P., Vieira, A., Putin, E., & Zhavoronkov, A. (2016). Applications of Deep Learning in Biomedicine. *Molecular Pharmaceutics*, 13(5), 1445–1454. <https://doi.org/10.1021/ACS.MOLPHARMACEUT.5B00982>
- Mangano, D. T. (2004). Perioperative medicine: NHLBI working group deliberations and recommendations. *Journal of cardiothoracic and vascular anesthesia*, 18(1), 1–6.
- Marakas, G. M. (2003). *Decision Support Systems in the 21st Century*.
- Marshall, J., & Creery, D. (1998). Pre-Clinical Models of Sepsis. *Sepsis*, 2(3), 187–197. <https://doi.org/10.1023/A:1009873527659>
- Mayr, F. B., Yende, S., & Angus, D. C. (2014). Epidemiology of severe sepsis. *Virulence*. <https://doi.org/10.4161/viru.27372>
- Mazo, C., Kearns, C., Mooney, C., & Gallagher, W. M. (2020). Clinical Decision Support Systems in Breast Cancer: A Systematic Review. *Cancers*, 12(2), 369. <https://doi.org/10.3390/cancers12020369>
- Mazor, I., Heart, T., & Even, A. (2016). Simulating the impact of an online digital dashboard

in emergency departments on patients length of stay.

- McGlynn, E. A., Asch, S. M., Adams, J., Keeseey, J., Hicks, J., DeCristofaro, A., ... Eam, C. (2003). *The quality of health care delivered to adults in the United States*. *New England journal of medicine* (C. 26).
- McLymont, N., & Glover, G. W. (2016). Scoring systems for the characterization of sepsis and associated outcomes. *Annals of Translational Medicine*, 4(24), 1–5. <https://doi.org/10.21037/atm.2016.12.53>
- Mediacenter, I. (2020). Cloud Adoption and Opportunities Will Continue to Expand Leading to a \$1 Trillion Market in 2024, According to IDC. 29 Nisan 2021 Tarihinde, <https://www.idc.com/getdoc.jsp?containerId=prUS46934120> adresinden erişildi
- Medical Association, A. (2014). Hospital Deaths in Patients With Sepsis From 2 Independent Cohorts. *jamanetwork.com*. <https://doi.org/10.1001/jama.2014.5804>
- Medicine, S. (2018). Stanford Medicine. White Paper: The Future of Electronic Health Records.
- Medsker, L., & Jain, L. C. (1999). *Recurrent neural networks: design and applications*. Crc Press.
- Merghadi, A., Yunus, A. P., Dou, J., Whiteley, J., ThaiPham, B., Bui, D. T., & Abderrahmane, B. (2020). Machine learning methods for landslide susceptibility studies: A comparative overview of algorithm performance. *Earth-Science Reviews*.
- Merriam-Webster Online Dictionary, 2008. Cluster analysis. (2008). Merriam-Webster Online Dictionary. 18.12.2021 Tarihinde <http://www.merriamwebster-online.com> adresinden erişildi
- Mesci, Y. (2020). Kümeleme Teknikleri ve Python'da K-Means. 28 Nisan 2022 Tarihinde, <https://medium.com/deep-learning-turkiye/kümeleme-teknikleri-ve-pythonda-k-means-62d93c624e5c> adresinden erişildi
- Metzger, J., Macdonald, K., Drazen, E., Kendall, B., Lee, T., & Karp, S. (2002). *Clinical Decision Support for the Independent Physician Practice*.
- Meyer, J. W., & Rowan, B. (1977). Institutionalized Organizations: Formal Structure as Myth and Ceremony. *American Journal of Sociology*, 83(2), 340–363.
- Miles, J. A. (2012). *Management and Organization Theory: A Jossey-Bass Reader*. John Wiley & Sons.



- Minsky, M. (1961). Steps toward artificial intelligence, *49*(1), 8–30.
- Mintzberg, Henry; Quinn, J. B. (1996). *Readings in the strategy process*. New Jersey. Prentice Hall,.
- Mintzberg, H. (1978). Patterns in Strategy Formation. *Management Science*, *24*(9), 934–948.  
<https://doi.org/10.1287/mnsc.24.9.934>
- Modi, R., & Modi, S. (2021). COVID-19 and cardiovascular complications-A review on thromboembolic phenomenon. *Journal of Cardiovascular Disease Research*, *12*(1), 44-48.
- Mojjada, R. K., Yadav, A., Prabhu, A. V., & Natarajan, Y. (2020). Machine learning models for covid-19 future forecasting. *Materials Today: Proceedings*.
- Mokris, I., & Skovajsova, L. (2008). Comparison of Document Clustering Techniques, 75–78.
- Mosadeghrad, A. M. (2014). Essentials of total quality management: a meta-analysis. *International journal of health care quality assurance*.
- Mueller, J., & Massaron, L. (2016). *Machine learning for dummies. For dummies*.
- Mujica, L. E., Vehí, J., Ruiz, M., Verleysen, M., Staszewski, W., & Worden, K. (2008). Multivariate statistics process control for dimensionality reduction in structural assessment. *Mechanical Systems and Signal Processing*, *22*(1), 155-171.
- Naamati Schneider, L. (2020). Strategic management as adaptation to changes in the ecosystems of public hospitals in Israel. *Israel Journal of Health Policy Research*, *9*(1), 1–11. <https://doi.org/10.1186/S13584-020-00424-Y/METRICS>
- Nadikattu, R. R. (2019). Data Warehouse Architecture–Leading the Next Generation Data Science. *International Journal of Computer Trends and Technology*, *67*(2019), 78–80.  
<https://doi.org/10.14445/22312803/IJCTT-V67I9P113>
- Nasraoui, O., & Ben N’Cir, C.-E. (2019). Clustering Methods for Big Data Analytics: Techniques, Toolboxes and Applications.
- Nayak, J., Naik, B., & Behera, H. (2015). Fuzzy C-means (FCM) clustering algorithm: a decade review from 2000 to 2014. *Computational intelligence in data mining*, *2*, 133-149.
- Nemati, Shamim, Holder, A., Razmi, F., Stanley, M. D., Clifford, G. D., & Buchman, T. G. (2018). An Interpretable Machine Learning Model for Accurate Prediction of Sepsis in

the ICU HHS Public Access. *Crit Care Med*, 46(4), 547–553.  
<https://doi.org/10.1097/CCM.0000000000002936>

Neurologic Winter, Johns Hopkins Performs Its First Augmented Reality Surgeries in Patients.  
(2021). 03 Haziran 2021 Tarihinde  
<https://www.hopkinsmedicine.org/news/articles/johns-hopkins-performs-its-first-augmented-reality-surgeries-in-patients> adresinden erişildi

Ng, I., & Wakenshaw, S. (2018). *Service ecosystems: a timely worldview for a connected, digital and data-driven economy. Handbook of Service-Dominant Logic. Thousand Oaks, CA: SAGE.*

Nguyen, H. B., Corbett, S. W., Steele, R., Banta, J., Clark, R. T., Hayes, S. R., ... Wittlake, W. A. (2007). Implementation of a bundle of quality indicators for the early management of severe sepsis and septic shock is associated with decreased mortality. *Critical Care Medicine*, 35(4), 1105–1112. <https://doi.org/10.1097/01.CCM.0000259463.33848.3D>

Nguyen, H. D., & Poo, D. C. C. (2016). Analysis and design of mobile health interventions towards informed shared decision making: an activity theory-driven perspective. *Journal of Decision Systems*, 25, 397–409. <https://doi.org/10.1080/12460125.2016.1187399>

Nokhbatolfoghahaayee, H., Menhaj, M. B., & Shafiee, M. (2010). Fuzzy decision support system for crisis management with a new structure for decision making. *Expert Systems with Applications*, 37(5), 3545–3552. <https://doi.org/10.1016/j.eswa.2009.10.011>

North, D. C. (1990). A Transaction Cost Theory of Politics. *Journal of Theoretical Politics*, 2(4), 355–367. <https://doi.org/10.1177/0951692890002004001>

Ocasio, W., & Joseph, J. (2005). An attention-based theory of strategy formulation: Linking micro-and macroperspectives in strategy processes. In *Strategy process. Emerald Group Publishing Limited.*

Ocasio, W. (1997). Towards an attention-based view of the firm. *Strategic management journal*, 18(1), 187–206.

Olavarrieta, S., & Friedmann, R. (2008). Market orientation, knowledge-related resources and firm performance. *Journal of business research*, 61(6), 623–630. <https://doi.org/10.1016/j.jbusres.2007.06.037>

Oliver, C. (1997). Sustainable competitive advantage: Combining institutional and resource-based views. *Strategic Management Journal*, 18(9), 697-713.

Oord, V. Den, A., Dieleman, S., & Schrauwen, B. (2013). Deep content-based music

recommendation. *In Neural Information Processing Systems Conference*

- Oppenheim, M. (2016). Stephen Hawking: artificial intelligence could be the greatest disaster in human history. 03.01.2022 Tarihinde <https://www.independent.co.uk/news/people/stephen-hawking-artificial-intelligence-disaster-human-history-leverhulme-centre-cambridge-a7371106.html> adresinden erişildi
- Osheroff, J. A. (2012). *Improving outcomes with clinical decision support: an implementer's guide*. Himss.
- Otola, I., Ostraszewska, Z., & Tylec, A. (2013). New directions of development of resource-based view in creating a competitive advantage. *Business Management Dynamics*, 3(2), 26.
- Ouammi, A., Ghigliotti, V., Robba, M., Mimet, A., & Sacile, R. (2012). A decision support system for the optimal exploitation of wind energy on regional scale. *Renewable Energy*, 37(1), 299–309. <https://doi.org/10.1016/j.renene.2011.06.027>
- Owens, D. K., Lohr, K. N., Atkins, D., Treadwell, J. R., Reston, J. T., Bass, E. B., ... Helfand, M. (2010). AHRQ Series Paper 5: Grading the strength of a body of evidence when comparing medical interventions-Agency for Healthcare Research and Quality and the Effective Health-Care Program. *Journal of Clinical Epidemiology*, 63(5), 513–523. <https://doi.org/10.1016/j.jclinepi.2009.03.009>
- Ozalp, M. A., Yildirak, K., Aladag, C. H., Zor, I., & ... (2019). Prognostic Performance of Statistical and Machine Learning Methods on MIMIC-III Clinical Database.
- Ozaydin, B., Hardin, J. M., & Chhieng, D. C. (2016). Data Mining and Clinical Decision Support Systems (ss. 45–68). Springer, Cham. [https://doi.org/10.1007/978-3-319-31913-1\\_3](https://doi.org/10.1007/978-3-319-31913-1_3)
- Palaz, D., Magimai-Doss, M., & Collobert, R. (2019). End-to-end acoustic modeling using convolutional neural networks for HMM-based automatic speech recognition. *Speech Communication*, (108), 15–32. <https://doi.org/10.1016/j.specom.2019.01.004>
- Pelcyger, B. (2017). Artificial intelligence in healthcare: Babylon Health & IBM Watson take the lead.
- Peng, M. W., Sun, S. L., Pinkham, B., & Chen, H. (2009). The institution-based view as a third leg for a strategy tripod. *Academy of management perspectives*, 23(3), 63-81.
- Peng, Mike W., Wang, D. Y. L., & Jiang, Y. (2008). An institution-based view of international business strategy: A focus on emerging economies. *Journal of International Business*

*Studies*, 39(5), 920–936. <https://doi.org/10.1057/PALGRAVE.JIBS.8400377>

Penrose, R. (1959). The apparent shape of a relativistically moving sphere. *Mathematical Proceedings of the Cambridge Philosophical Society*, 55(1), 137–139. <https://doi.org/10.1017/S0305004100033776>

Pereira, V., & Bamel, U. (2021). Extending the resource and knowledge based view: A critical analysis into its theoretical evolution and future research directions. *Journal of Business Research*, 132(April), 557–570. <https://doi.org/10.1016/j.jbusres.2021.04.021>

Perez, J., Deligianni, F., Ravi, D., & Yang, G. z. (2018). Artificial intelligence and robotics, 56. 08.07.2021 Tarihinde [http://ganj-  
ie.iust.ac.ir:8081/images/8/81/Artificial\\_intelligence\\_and\\_Robotics.pdf](http://ganj-ie.iust.ac.ir:8081/images/8/81/Artificial_intelligence_and_Robotics.pdf) adresinden erişildi

Peter, J. P. (1981). Construct Validity: A Review of Basic Issues and Marketing Practices. *Journal of Marketing Research*, 18(2), 133–145. <https://doi.org/10.1177/002224378101800201>

Peteraf, M. A. (1993). The cornerstones of competitive advantage: A resource-based view. *Strategic Management Journal*, 14(3), 179–191. <https://doi.org/10.1002/smj.4250140303>

Petrány, M. (2014). Why Volvo Thinks It Can Eliminate All Deaths In Its Cars By 2020. Tarihinde 12 Nisan 2022, adresinden erişildi [https://jalopnik.com/this-is-volvos-bold-  
plan-to-eliminate-all-deaths-in-its-1668747230](https://jalopnik.com/this-is-volvos-bold-plan-to-eliminate-all-deaths-in-its-1668747230)

Phdungsilp, A. (2010). Integrated energy and carbon modeling with a decision support system: Policy scenarios for low-carbon city development in Bangkok. *Energy Policy*, 38(9), 4808–4817. <https://doi.org/10.1016/j.enpol.2009.10.026>

Poole, D., Mackworth, A., & Goebel, R. (1998). *Computational Intelligence*.

Porter, M.E. (2008). The Five Competitive Forces That Shape Strategy. *Harvard Business Review*, 1, 24–41.

Porter, Michael E. (1979). *How Competitive Forces Shape Strategy*. Harvard Business Review on Knowledge Management.

Porter, Michael E. (1980). Industry Structure and Competitive Strategy: Keys to Profitability. *Financial Analysts Journal*, 36(4), 30–41. <https://doi.org/10.2469/faj.v36.n4.30>

Porter, Michael E. (1985). *Competitive advantage: creating and sustaining superior*

*performance*. New York: FreePress.

- Portugal, I., Alencar, P., & Cowan, D. (2018). The use of machine learning algorithms in recommender systems: A systematic review. *Expert Systems with Applications*, (97), 205–227. 14 Mart 2020 Tarihinde <https://www.sciencedirect.com/science/article/pii/S0957417417308333>adresinden erişildi
- Power, Daniel J., Heavin, C., & Keenan, P. (2019). Decision systems redux. *Journal of Decision Systems*, 28(1), 1–18. <https://doi.org/10.1080/12460125.2019.1631683>
- Probert, W. J. M., Jewell, C. P., Werkman, M., Fonnesebeck, C. J., Goto, Y., Runge, M. C., ... Tildesley, M. J. (2018). Real-time decision-making during emergency disease outbreaks. *PLoS Computational Biology*, 14(7), e1006202. <https://doi.org/10.1371/journal.pcbi.1006202>
- Provost, F., & Fawcett, T. (1998). *Robust classification systems for imprecise environments*. In AAAI/IAAI.
- Qin, F., Lv, Z., Wang, D., Hu, B., And, C. W.-A. of gerontology, & 2020, U. (2020). Health status prediction for the elderly based on machine learning. *Archives of gerontology and geriatrics*, (90).
- Quadrana, M., Karatzoglou, A., & ... B. H. (2017). Personalizing session-based recommendations with hierarchical recurrent neural networks. *Proceedings of the Eleventh ACM Conference on Recommender Systems*, 130–137.
- Rafiei, M. (2013). *A Perioperative Medicine Clinical Decision Support System: Foundation, Design, Development, Evaluation, and the Standards*.
- Ralston, P. M., Blackhurst, J., Cantor, D. E., & Crum, M. R. (2015). A Structure-Conduct-Performance Perspective of How Strategic Supply Chain Integration Affects Firm Performance. *Journal of Supply Chain Management*, 51(2), 47–64. <https://doi.org/10.1111/jscm.12064>
- Ramírez-Gallego, S., Krawczyk, B., García, S., Woźniak, M., & Herrera, F. (2017). A survey on data preprocessing for data stream mining: Current status and future directions. *Neurocomputing*, 239, 39–57. <https://doi.org/10.1016/j.neucom.2017.01.078>
- Randhawa, K., Wilden, R., & Gudergan, S. (2021). How to innovate toward an ambidextrous business model? The role of dynamic capabilities and market orientation. *Journal of Business Research*, 130, 618-634.

- Ravi, D., Wong, C., & ... F. D. (2016). Deep learning for health informatics. *IEEE journal of biomedical and health informatics*, 21(1), 4–21. 26 Nisan 2021 Tarihinde <https://ieeexplore.ieee.org/abstract/document/7801947/>adresinden erişildi
- Ray, G., Barney, J. B., & Muhanna, W. A. (2004). Capabilities, business processes, and competitive advantage: choosing the dependent variable in empirical tests of the resource-based view. *Strategic management journal*, 25(1), 23–37.
- Razmak, J., Bélanger, C. H., & Farhan, W. (2018). Managing patients' data with clinical decision support systems: a factual assessment. *Journal of Decision Systems*, 27(3), 123–145. <https://doi.org/10.1080/12460125.2018.1533159>
- Rendón, E., Alejo, R., Castorena, C., Isidro-Ortega, F. J., & Granda-Gutiérrez, E. E. (2020). Data sampling methods to deal with the big data multi-class imbalance problem. *Applied Sciences (Switzerland)*, 10(4). <https://doi.org/10.3390/app10041276>
- Rhee, C., Gohil, S., & Klompas, M. (2014). Regulatory Mandates for Sepsis Care — Reasons for Caution. *New England Journal of Medicine*, 370(18), 1673–1676. <https://doi.org/10.1056/nejmp1400276>
- Rhee, C., Jones, T. M., Hamad, Y., Pande, A., Varon, J., O'Brien, C., ... Klompas, M. (2019). Prevalence, Underlying Causes, and Preventability of Sepsis-Associated Mortality in US Acute Care Hospitals. *JAMA network open*, 2(2), e187571. <https://doi.org/10.1001/jamanetworkopen.2018.7571>
- Ritter, T., & Pedersen, C. L. (2020). Digitization capability and the digitalization of business models in business-to-business firms: Past, present, and future. *Industrial Marketing Management*, 86, 180–190. <https://doi.org/10.1016/J.INDMARMAN.2019.11.019>
- Robinson, R. B., & Pearce, J. A. (1984). Research Thrusts in Small Firm Strategic Planning. *Academy of Management Review*, 9(1), 128–137. <https://doi.org/10.5465/amr.1984.4278109>
- Ron, R., & Harefuah, Y. W. (2020). The implications of reducing elective activity in hospitals during the Corona crisis Insights following a webinar sponsored by the Assuta Health
- Roshanov, P. S., Misra, S., Gerstein, H. C., Garg, A. X., Sebaldt, R. J., Mackay, J. A., ... Haynes, R. B. (2011). Computerized clinical decision support systems for chronic disease management: A decision-maker-researcher partnership systematic review. *Implementation Science*, 6(1). <https://doi.org/10.1186/1748-5908-6-92>
- Rubio, E., Castillo, O., & Melin, P. (2011). A new validation index for fuzzy clustering and

- its comparisons with other methods. İçinde *Conference Proceedings - IEEE International Conference on Systems, Man and Cybernetics* (ss. 301–306). IEEE. <https://doi.org/10.1109/ICSMC.2011.6083682>
- Rudd, K., Johnson, S., Agesa, K., Lancet, K. S.-T., & 2020, undefined. (y.y.). Global, regional, and national sepsis incidence and mortality, 1990–2017: analysis for the Global Burden of Disease Study. *Elsevier*.
- Russell, S. J., & Norvig, P. (2022). *Artificial intelligence: a modern approach* (4. Edition). Pearson.
- Sahama, T., & Croll, P. (2007). A data warehouse architecture for clinical data warehousing. İçinde *Proceedings of 5th Australasian Symposium on Grid Computing and e-Research, 5th Australasian Information Security Workshop (Privacy Enhancing Technologies), and Australasian Workshop on Health Knowledge Management and Discovery* (ss. 227–232).
- Sahota, N., Lloyd, R., Ramakrishna, A., Mackay, J. A., Prorok, J. C., Weise-Kelly, L., ... Brian Haynes, R. (2011). Computerized clinical decision support systems for acute care management: A decision-maker-researcher partnership systematic review of effects on process of care and patient outcomes. *Implementation Science*, 6(1). <https://doi.org/10.1186/1748-5908-6-91>
- Saifi, S., Taylor, A. J., Allen, J., & Hendel, R. (2013). The Use of a Learning Community and Online Evaluation of Utilization for SPECT Myocardial Perfusion Imaging. *JACC: Cardiovascular Imaging*, 6(7), 823–829. <https://doi.org/10.1016/J.JCMG.2013.01.012>
- Sajda, P. (2006). Machine Learning for Detection and Diagnosis of Disease. *Annu. Rev. Biomed. Eng.*, 8, 537–565. <https://doi.org/10.1146/ANNUREV.BIOENG.8.061505.095802>
- Sauter, V. L. (2011). *Decision Support Systems for Business Intelligence: Second Edition. Decision Support Systems for Business Intelligence: Second Edition.* <https://doi.org/10.1002/9780470634431>
- Savić, D. (2019). From Digitization, through Digitalization, to Digital Transformation. *Online searcher*, 43(1), 36–39.
- Saxena, A., Brault, N., & Rashid, S. (2021). *Big Data and Artificial Intelligence for Healthcare Applications* (CRC Press).
- Schilke, O. (2014). On the contingent value of dynamic capabilities for competitive advantage:

- The nonlinear moderating effect of environmental dynamism. *Strategic management journal*, 35(2), 179–203. <https://doi.org/10.1002/smj.2099>
- Schurer Coldiron, J. (2012). Strategic management in nonprofit mental health service organizations: Understanding processes and impact on performance. *Dissertation Abstracts International Section A: Humanities and Social Sciences*, 72(12-A), 4649.
- Scott Morton. (2007). Reflections on Decision Support.
- Sebastiani, F. (2002). Machine learning in automated text categorization. *ACM Computing Surveys (CSUR)*, 34(1), 1–47. <https://doi.org/10.1145/505282.505283>
- Sepsis - A Global Health Crisis. (2020). 18.03.2020 Tarihinde <https://www.global-sepsis-alliance.org/sepsis> adresinden erişildi
- Sepsis nedir? Belirtileri ve tedavi yöntemleri nelerdir? (y.y.). 18 Ekim 2020 Tarihinde <https://www.medicalpark.com.tr/sepsis/hg-2169> adresinden erişildi
- Seymour, C. W., Liu, V. X., Iwashyna, T. J., Brunkhorst, F. M., Rea, T. D., Scherag, A., ... Angus, D. C. (2016). Assessment of clinical criteria for sepsis for the third international consensus definitions for sepsis and septic shock (sepsis-3). *JAMA - Journal of the American Medical Association*, 315(8), 762–774. <https://doi.org/10.1001/jama.2016.0288>
- Shaikh, K., Krishnan, S., & Thanki, R. (2021). *Artificial Intelligence in Breast Cancer Early Detection and Diagnosis*. *Artificial Intelligence in Breast Cancer Early Detection and Diagnosis*. <https://doi.org/10.1007/978-3-030-59208-0>
- Shaman, J., & Karspeck, A. (2012). Forecasting seasonal outbreaks of influenza. *Proceedings of the National Academy of Sciences of the United States of America*, 109(50), 20425–20430. <https://doi.org/10.1073/pnas.1208772109>
- Shashikumar, S. P., Josef, C., Sharma, A., & Nemati, S. (2019). DeepAISE - An end-to-end development and deployment of a recurrent neural survival model for early prediction of sepsis. *arXiv*.
- Sheehan, N. T., & Foss, N. J. (2007). Enhancing the prescriptiveness of the resource-based view through Porterian activity analysis. *Management Decision*.
- Shi, J., & Malik, J. (2000). Normalized cuts and image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(8), 888–905. <https://doi.org/10.1109/34.868688>



- Shinde, P. P., & Shah, S. (2018). A Review of Machine Learning and Deep Learning Applications. İçinde *Fourth International Conference on Computing Communication Control and Automation* (ss. 1–6).
- Shmueli, G., Bruce, P. C., Yahav, I., Patel, N. R., & Lichtendahl Jr, K. C. (2017). *Data Mining for Business Analytics: Concepts, Techniques, and Applications in R*.
- Shook, C. L. (2019). *Choosing Information Systems as a Major : Factors that Influence Selection A dissertation submitted in partial fulfillment of the requirements for the degree of Doctor of Education in Higher Education by Carole L . Shook University of Arkansas Bachelor of*. University of Arkansas.
- Shorr, A. F., Micek, S. T., Jackson, W. L., & Kollef, M. H. (2007). Economic implications of an evidence-based sepsis protocol: Can we improve outcomes and lower costs? *Critical Care Medicine*, 35(5), 1257–1262. <https://doi.org/10.1097/01.CCM.0000261886.65063.CC>
- Silahtaroglu, G. (2008). *Veri madenciliği*. İstanbul: Papatya Yayınları.
- Silahtaroglu, G. (2020). *Veri Madenciliği: Kavram ve Algoritmaları*. İstanbul: Papatya Yayınları.
- Silahtaroglu, G., Baykal, E., & Canbolat, Z. N. (2020). Weekly Emotional Changes Amidst Covid-19: Turkish Experience. *Journal of Economics Business and Finance Research*, 2(3), 280–304. <https://doi.org/10.38009/EKIMAD.825285>
- Silahtaroglu, G., & Canbolat, Z. N. (2018). Sosyal Medyanın Veri Sermayesi Olarak Kullanımı: Sağlık Sektörü Örneği. İçinde *Yönetim Bilişim Sistemlerinde Gündem* (ss. 87–98).
- Simon, H. A. (1947). A Comment on “The Science of Public Administration”. *Public Administration Review*, 7(3), 200. <https://doi.org/10.2307/972716>
- Singer, M., Deutschman, C., Jama, C. S., & 2016, U. (2016). The third international consensus definitions for sepsis and septic shock (Sepsis-3).
- Singh, M., Bhattacharjee, R., Sharma, N., & Verma, A. (2018). An improved xie-beni index for cluster validity measure. İçinde *2017 4th International Conference on Image Information Processing, ICIIP 2017* (C. 2018-Janua, ss. 95–99). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ICIIP.2017.8313691>
- Sitapati, A., Kim, H., Berkovich, B., Marmor, R., Singh, S., El-Kareh, R., ... Ohno-Machado, L. (2017). Integrated precision medicine: the role of electronic health records in

- delivering personalized treatment. *Wiley Interdisciplinary Reviews: Systems Biology and Medicine*, 9(3). <https://doi.org/10.1002/WSBM.1378>
- Sittig, D. F., Wright, A., Osheroff, J. A., Middleton, B., Teich, J. M., Ash, J. S., ... Bates, D. W. (2008). Grand challenges in clinical decision support. *Journal of Biomedical Informatics*, 41(2), 387–392. <https://doi.org/10.1016/j.jbi.2007.09.003>
- Slater, S. F., & Narver, J. C. (1995). Market Orientation and the Learning Organization. *Journal of Marketing*, 59(3), 63–74. <https://doi.org/10.1177/002224299505900306>
- Slotegraaf, R. J., Moorman, C., & Inman, J. J. (2003). The Role of Firm Resources in Returns to Market Deployment. *Journal of Marketing Research*, 40(3), 295–309. <https://doi.org/10.1509/jmkr.40.3.295.19235>
- Sohn, K. M., Lee, S. G., Kim, H. J., Cheon, S., Jeong, H., Lee, J., & Jo, E. K. (2020). COVID-19 patients upregulate toll-like receptor 4-mediated inflammatory signaling that mimics bacterial sepsis. *Journal of Korean medical science*, 35(38).
- Souza, N. M., Sebaldt, R. J., Mackay, J. A., Prorok, J. C., Weise-Kelly, L., Navarro, T., ... Haynes, R. B. (2011). Computerized clinical decision support systems for primary preventive care: A decision-maker-researcher partnership systematic review of effects on process of care and patient outcomes. *Implementation Science*, 6(1). <https://doi.org/10.1186/1748-5908-6-87>
- Sperry, L. (2003). *Becoming an Effective Health Care Manager: The Essential Skills of Leadership*. Health Professions Press.
- Spring, B. (2008). Health decision making: lynchpin of evidence-based practice. *Medical Decision Making*, 28(6), 866-874.
- Srivastava, M. K., & Gnyawali, D. R. (2011). When do relational resources matter? Leveraging portfolio technological resources for breakthrough innovation. *Academy of Management Journal*, 54(4), 797–810.
- Steininger, D. M., Mikalef, P., Pateli, A., & Ortiz-de-Guinea, A. (2022). Dynamic capabilities in information systems research: A critical review, synthesis of current knowledge, and recommendations for future research. *Journal of the Association for Information Systems*, 23(2), 447–490.
- Stoller, J. L., Halpin, L., Aplin, B., Weis, M. J., Georgescu, C., & Nazzal, M. M. (2015). Epidemiology of Severe Sepsis: 2008-2012. *Journal of the American College of Surgeons*, 221(4), S42. <https://doi.org/10.1016/j.jamcollsurg.2015.07.086>

- Subramani Mani, Asli Ozdas, Constantin Aliferis, H. A. V., & Qingxia Chen, Randy Carnevale, Yukun Chen, Joann Romano-Keeler, Hui Nian Weitkamp, J.-H. (2014). Medical decision support using machine learning for early detection of late-onset neonatal sepsis.
- Sultana, N., Chilamkurti, N., Peng, W., & Alhadad, R. (2018). Survey on SDN based network intrusion detection system using machine learning approaches. *Peer-to-Peer Networking and Applications 2018 12:2, 12(2)*, 493–501. <https://doi.org/10.1007/S12083-017-0630-0>
- Sun, J., Lang, J., Fujita, H., & Li, H. (2018). Imbalanced enterprise credit evaluation with DTE-SBD: Decision tree ensemble based on SMOTE and bagging with differentiated sampling rates. *Information Sciences*, 425, 76–91. <https://doi.org/10.1016/j.ins.2017.10.017>
- Sun, T. Q., & Medaglia, R. (2019a). Mapping the challenges of Artificial Intelligence in the public sector: Evidence from public healthcare. *Government Information Quarterly*, 36(2), 368–383.
- Sun, T. Q., & Medaglia, R. (2019b). Mapping the challenges of Artificial Intelligence in the public sector: Evidence from public healthcare. *Government Information Quarterly*, 36(2), 368–383. <https://doi.org/10.1016/j.giq.2018.09.008>
- Syafrudin, M., Alfian, G., Fitriyani, N. L., & Rhee, J. (2018). Performance Analysis of IoT-Based Sensor, Big Data Processing, and Machine Learning Model for Real-Time Monitoring System in Automotive Manufacturing. *Sensors 2018, Vol. 18, Page 2946*, 18(9), 2946. <https://doi.org/10.3390/S18092946>
- T.C. Sağlık Bakanlığı. (2016). Dijital hastane. 21.10.2021 Tarihinde <https://dijitalhastane.saglik.gov.tr/adresinden> erişildi
- Tai, K. S., Socher, R., & Manning, C. D. (2015). Improved semantic representations from tree-structured long short-Term memory networks. *Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing of the Asian Federation of Natural Language Processing, Proceedings of the Conference, 1*, 1556–1566. <https://doi.org/10.3115/v1/p15-1150>
- Taş, A., & Cevrioğlu, E. (2015). Stratejik Yönetimin Temel Sorularına Kurumsalçı Perspektiften Bakış: Kurumsal Temelli Görüşün Argümanları Stratejik Yönetim Disiplini İçin Ne Anlam İade Ediyor? *Yönetim ve Ekonomi Araştırmaları Dergisi* -, 3(13), 10–27.

- Taylor, R. A., Pare, J. R., Venkatesh, A. K., Mowafi, H., Melnick, E. R., Fleischman, W., & Hall, M. K. (2016). Prediction of In-hospital Mortality in Emergency Department Patients with Sepsis: A Local Big Data-Driven, Machine Learning Approach. *Academic Emergency Medicine*, 23(3), 269–278. <https://doi.org/10.1111/acem.12876>
- TechVidvan, "Real World Artificial Intelligence Applications in various sectors". (17.06.2021). 18.09.2021 Tarihinde <https://techvidvan.com/tutorials/artificial-intelligence-applications/adresinden-erişildi>
- Teece, D. J. (2007). Explicating dynamic capabilities: the nature and microfoundations of (sustainable) enterprise performance. *Strategic management journal*, 28(13), 1319-1350.
- Teece, D. J. (2018). Profiting from innovation in the digital economy: Enabling technologies, standards, and licensing models in the wireless world. *Research policy*, 47(8), 1367-1387.
- Teece, D. J., Pisano, G., & Shuen, A. (1997). Dynamic capabilities and strategic management. *Strategic management journal*, 18(7), 509–533.
- Thies, W., & Bleiler, L. (2012). 2012 Alzheimer's disease facts and figures. *Alzheimer's and Dementia* (C. 8). <https://doi.org/10.1016/j.jalz.2012.02.001>
- TM, C., Noels, E., Wakkee, M., Udrea, A., & Nijsten, T. (2019). Development of Smartphone Apps for Skin Cancer Risk Assessment: Progress and Promise. *JMIR Dermatol*, 2(1), e13376. <https://doi.org/10.2196/13376>
- Uddin, S., Khan, A., Hossain, E., & Moni, M. A. (2019). Comparing different supervised machine learning algorithms for disease prediction. *Medical Informatics and Decision Making*, 19(281). <https://doi.org/10.1186/s12911-019-1004-8>
- Uğuroğlu, Ö., Demir B., İ., & Ürek, D. (2019). *Sağlık Kurumlarında Stratejik Yönetim*.
- Unruh, G., & Kiron, D. (2017). 'Digital transformation on purpose'. Tarihinde <https://sloanreview.mit.edu/article/digital-transformation-on-purpose/adresinden-erişildi>
- Van Belle, J. P., Nash, J., & Eccles, M. (2010). *Discovering Information Systems: an exploratory approach*. University of Cape Town.
- Vargo, S. L., & Lusch, R. F. (2004). The four service marketing myths: remnants of a goods-based, manufacturing model. *Journal of service research*, 6(4), 324–335. <https://doi.org/10.1177/1094670503262946>
- Vazsonyi, A. (1963). Augmenting management ability by electronics. *IEEE Transactions on*

- Verma, H., & Kumar, S. (2019). An accurate missing data prediction method using LSTM based deep learning for health care. *ACM International Conference Proceeding Series*, 371–376. <https://doi.org/10.1145/3288599.3295580>
- Verma, T., & Srivatava, R. K. (2015). Artificial Neural Networks based heart disease predictive Approach. *International Journal of Application or Innovation in Engineering & Management*, 4(3), 29–32.
- Vidant Beaufort Hospital. (2017). The third-leading cause of death: sepsis - Washington Daily News | Washington Daily News. Tarihiinde 01 Ocak 2021, adresinden erişildi <https://www.thewashingtondailynews.com/2017/07/08/the-third-leading-cause-of-death-sepsis/>
- Vincent, C., Neale, G., & Woloshynowych, M. (2001). Adverse events in British hospitals: Preliminary retrospective record review. *British Medical Journal*, 322(7285), 517–519. <https://doi.org/10.1136/bmj.322.7285.517>
- Vincent, J.-L., & Moreno, R. (1996). The SOFA (Sepsis-related Organ Failure Assessment) score to describe organ dysfunction/failure. <https://doi.org/10.1007/BF01709751>
- Vincent, J. L., Martin, G. S., & Levy, M. M. (2016). qSOFA does not replace SIRS in the definition of sepsis. *Critical Care*, 20(1). <https://doi.org/10.1186/s13054-016-1389-z>
- Vincent, J., Mendonça, A. De, ... F. C.-C. care, & 1998, undefined. (y.y.). Use of the SOFA score to assess the incidence of organ dysfunction/failure in intensive care units: results of a multicenter, [https://journals.lww.com/ccmjournal/Fulltext/1998/11000/Use\\_of\\_the\\_SOFA\\_score\\_to\\_assess\\_the\\_incidence\\_of.16.aspx](https://journals.lww.com/ccmjournal/Fulltext/1998/11000/Use_of_the_SOFA_score_to_assess_the_incidence_of.16.aspx)
- Volvo Cars caps vehicle speed to prevent road deaths. (y.y.). Tarihiinde 12 Nisan 2022, adresinden erişildi <https://www.ft.com/content/3c2f66bc-3e61-11e9-9bee-efab61506f44>
- Vorhies, D. W., & Morgan, N. A. (2005). Benchmarking Marketing Capabilities for Sustainable Competitive Advantage. *Journal of Marketing*, 69(1), 80–94. <https://doi.org/10.1509/jmkg.69.1.80.55505>
- Wah, T. Y., & Sim, O. S. (2009). Development of a data warehouse for lymphoma cancer diagnosis and treatment decision support. *WSEAS Transactions on Information Science and Applications*, 6(3), 530–543.

- Walston, S. L. (2014). Chief Executive Officers' perceived value of coaching: individual and organisational influences. *An International Journal of Theory, Research and Practice*, 7(2), 115–131. <https://doi.org/10.1080/17521882.2014.924543>
- Wang, D., Khosla, A., Gargeya, R., Irshad, H., & Beck, A. H. (2017). Deep Learning for Identifying Metastatic Breast Cancer. *Radiology*, 284(2).
- Wang, S. L., Wu, F., & Wang, B. H. (2010). Prediction of severe sepsis using SVM model.
- Wang, W., & Zhang, Y. (2007). On fuzzy cluster validity indices. *Fuzzy Sets and Systems*, 158(19), 2095–2117. <https://doi.org/10.1016/j.fss.2007.03.004>
- Washburn, M., & Bromiley, P. (2012). (2012). Comparing aspiration models: The role of selective attention. *f Management Studies*, 49(5), 896–917.
- Wasserman, S., & Faust, K. (1994). *Social network analysis: Methods and applications*.
- Wassmer, U. (2010). Alliance portfolios: A review and research agenda., 36(1), 141–171.
- Wei-dong. (2004). The digital hospital in future: understanding and management of our future hospital. *Information of Equipment*.
- Weiss, C. H. (1979). The Many Meanings of Research Utilization. *Public Administration Review*, 39(5), 426. <https://doi.org/10.2307/3109916>
- Wernerfelt, B. (1984). A resource-based view of the firm. *Strategic Management Journal*, 5(2), 171–180. <https://doi.org/10.1002/smj.4250050207>
- What is sepsis? | Sepsis | CDC. (2021). 11 Ekim 2021 Tarihinde, <https://www.cdc.gov/sepsis/what-is-sepsis.html> adresinden erişildi
- Whittington, R. (1996). Strategy as practice. *Long range planning*, 29(5), 731–735.
- WHO. (2020a). Digital technology for COVID-19 response. 6.07.2020 Tarihinde <https://www.who.int/news/item/03-04-2020-digital-technology-for-covid-19-response> adresinden erişildi
- WHO. (2020b). Misinformation, WHO launches a chatbot on Facebook Messenger to combat COVID-19. 8.06.2020 Tarihinde <https://www.who.int/news-room/feature-stories/detail/who-launches-a-chatbot-powered-facebook-messenger-to-combat-covid-19-misinformation> adresinden erişildi
- Who we are | HIMSS. (y.y.). 14 Haziran 2020 Tarihinde, <https://www.himss.org/who-we-are> adresinden erişildi

- Wicks, P., Stamford, J., Grootenhuis, M. A., Haverman, L., & Ahmed, S. (2014). Innovations in e-health. *Quality of Life Research*, 23(1), 195–203. <https://doi.org/10.1007/S11136-013-0458-X/FIGURES/1>
- Wielemaker, M. W., Elfring, T., & Volberda, H. W. (2001). How Well-Established Firms Prepare for the New Economy. *International Studies of Management & Organization*, 31(1), 7–29. <https://doi.org/10.1080/00208825.2001.11656805>
- Wilden, R., Gudergan, S. P., Nielsen, B. B., Lings, I. (2013). Dynamic capabilities and performance: strategy, structure and environment. *Long range planning*, 46(1-2), 72–96.
- Williamson, O. E. (2009). *Markets and Hierarchies: Analysis and Antitrust Implications: A Study in the Economics of Internal Organization*.
- Winter, S. G. (2003). Understanding dynamic capabilities. *Strategic management journal*, 24(10), 991–995.
- Witten, Ian. H. (2016). *Data Mining: Practical Machine Learning Tools and Techniques*.
- Wong, M. L., Seng, K., & Wong, P. K. (2020). Cost-sensitive ensemble of stacked denoising autoencoders for class imbalance problems in business domain. *Expert Systems with Applications*, 141. <https://doi.org/10.1016/j.eswa.2019.112918>
- Wood, D., Stasko, T., Tarte, L., Jefferson, D., & Reddy, A. (2018). A Real-Time Service Management Decision Support System for Train Dispatching at New York City Transit. *Transportation Research Record*, 2672(8), 327–338. <https://doi.org/10.1177/0361198118792116>
- World Health Statistics. (2018). 20.11.2021 Tarihinde <https://apps.who.int/iris/bitstream/handle/10665/272596/9789241565585-eng.pdf> adresinden erişildi
- Wright, T. (2021). The 6 Best Business Strategies I've Ever Seen. 12 Nisan 2022 Tarihinde, <https://www.cascade.app/blog/the-5-best-business-strategies-ive-ever-seen> adresinden erişildi
- Xie, X. L., & Beni, G. (1991). A validity measure for fuzzy clustering. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 13(8), 841–847. <https://doi.org/10.1109/34.85677>
- Yong, Y., Chongxun, Z., & Pan, L. (2004). A novel fuzzy c-means clustering algorithm for image thresholding. *Measurement Science Review*, 4(1), 11–19. 17.04.2021 Tarihinde <https://core.ac.uk/download/pdf/20699412.pdf> adresinden erişildi

- Yu, C. P., Chen, H. G., Klein, G., & Jiang, R. (2015). The roots of executive information system development risks. *information and Software Technology*, (68), 34–44.
- Yu, K. H., Beam, A. L., & Kohane, I. S. (2018). Artificial intelligence in healthcare. *Nature Biomedical Engineering*, 2(10), 719–731. <https://doi.org/10.1038/s41551-018-0305-z>
- Yu, Y., Si, X., Hu, C., & Zhang, J. (2019). A review of recurrent neural networks: LSTM cells and network architectures. *Neural computation*, 31(7), 1235–1270. [https://doi.org/10.1162/neco\\_a\\_01199](https://doi.org/10.1162/neco_a_01199)
- Yuan, Q., Zhang, H., Deng, T., Tang, S., & Yuan, X. (2020). Role of artificial intelligence in kidney disease. *ncbi.nlm.nih.gov*, 17(7), 970.
- Zajac, E. J., & Shortell, S. M. (1989). Changing generic strategies: Likelihood, direction, and performance implications. *Strategic Management Journal*, 10(5), 413–430. <https://doi.org/10.1002/SMJ.4250100503>
- Zanaty, E. A. (2012). Determining the number of clusters for kernelized fuzzy C-means algorithms for automatic medical image segmentation. *Egyptian Informatics Journal*, 13(1), 39–58. <https://doi.org/10.1016/j.eij.2012.01.004>
- Zellner, M. (2014). The role of underlying mechanisms in achieving consistent hybrid combinations of competitive advantages.
- Zhang, M., Rajbhandari, S., Wang, W., & He, Y. (2018). Deepcpu: Serving rnn-based deep learning models 10x faster. *In 2018 {USENIX} Annual Technical Conference*, 951–965.
- Zhou, D. (2018). Universality of deep convolutional neural networks. *Applied and computational harmonic*. 19.11.2020 Tarihinde <https://www.sciencedirect.com/science/article/pii/S1063520318302045> adresinden erişildi
- Zhu, Y. (2018). A Data Driven Educational Decision Support System. *international journal of emerging technologies in learning*, 13(11). <https://doi.org/10.3991/ijet.v13i11.9582>
- Zott, C., & Amit, R. (2011). The business model: recent developments and future research. *Journal of Management*, 37(4), 1019-1042.
- Zwass, V. (2020). information system. 22.02.2022 tarihinde <https://www.britannica.com/topic/information-system> adresinden erişildi