

EDİTÖR

Doç. Dr. Fulya ASLAY

**BİLGİSAYAR
BİLİMLERİ
VE
MÜHENDİSLİĞİ**

Alanında Araştırmalar ve Değerlendirmeler

**MART
2025**

İmtiyaz Sahibi • Yaşar Hız
Genel Yayın Yönetmeni • Eda Altunel
Yayına Hazırlayan • Gece Kitaplığı
Editör • Doç. Dr. Fulya ASLAY

Birinci Basım • Mart 2025 / ANKARA

ISBN • 978-625-388-253-2

© copyright

Bu kitabın yayın hakkı Gece Kitaplığı'na aittir.
Kaynak gösterilmeden alıntı yapılamaz, izin almadan
hiçbir yolla çoğaltılamaz.

Gece Kitaplığı

Adres: Kızılay Mah. Fevzi Çakmak 1. Sokak Ümit Apt
No: 22/A Çankaya/ANKARA Tel: 0312 384 80 40

www.gecekitapligi.com
gecekitapligi@gmail.com

Baskı & Cilt
Bizim Buro
Sertifika No: 42488

Bilgisayar Bilimleri ve Mühendisliđi Alanında Arařtırmalar ve Deđerlendirmeler

Mart 2025

Editör:
Doç. Dr. Fulya ASLAY

İÇİNDEKİLER

BÖLÜM 1

DOĞAL DİL İŞLEME TEKNİKLERİ VE UYGULAMALARI

Alper Talha KARADENİZ, Zafer CÖMERT1

BÖLÜM 2

MEDİKAL GÖRÜNTÜ SEGMENTASYONU: GELENEKSEL YÖNTEMLER VE KOD UYGULAMALARI

Volkan GÖREKE23

BÖLÜM 3

İŞLETME YÖNETİCİLERİNİN YAPAY ZEKÂYA YÖNELİK ALGISI ÜZERİNE BİR İNCELEME

Burak DEMİR, Bengü KAYIARSLAN.....49

BÖLÜM 4

SOHBET ROBOTLARININ GELİŞİMİ VE SAĞLIK ALANINDAKİ ROLÜ

Gamzepelin AKSOY 59

BÖLÜM 5

AI IN HEALTHCARE: DESIGNING SMART CHATBOT WITH RANDOM FOREST ALGORITHM

Seda POSTALCIOĞLU79

BÖLÜM 6

AKILLI EVLERDE AKTİVİTE TANIMA: YÖNTEMLER, TEKNOLOJİLER VE UYGULAMALARI

Fatih GENÇTÜRK, Serdar BİROĞUL95

BÖLÜM 7
ARTIFICIAL INTELLIGENCE AND EXPLAINABILITY IN
HEALTH: POTENTIAL AND CHALLENGES

Hayri İNCEKARA..... 115

BÖLÜM 1

DOĞAL DİL İŞLEME TEKNİKLERİ VE UYGULAMALARI

Alper Talha KARADENİZ¹

Zafer CÖMERT²

¹ Dr. Öğretim Üyesi, Samsun Üniversitesi, Yazılım Mühendisliği Bölümü.

E-mail: alper.karadeniz@samsun.edu.tr, Orcid: 0000-0003-4165-3932

² Doçent Dr., Samsun Üniversitesi, Yazılım Mühendisliği Bölümü.

E-mail: zcomert@samsun.edu.tr, Orcid: 0000-0001-5256-7648

1. Giriş

Doğal Dil İşleme (Natural Language Processing - NLP), bilgisayarların insan dilini anlaması, işlemesi ve üretmesiyle ilgilenen disiplinler arası bir araştırma alanıdır. Yapay zeka (AI), dilbilim, bilgisayar bilimi ve istatistik gibi çeşitli alanlardan beslenen NLP, doğal dili analiz etmek ve anlamlandırmak için geliştirilen algoritmalar ve modeller üzerine yoğunlaşmaktadır (Zhiwei, 2005) .

Günümüzde NLP, metin sınıflandırma, duygu analizi, makine çevirisi ve konuşma tanıma gibi birçok uygulama alanında kullanılmaktadır. Yapay sinir ağları ve derin öğrenme tekniklerinin gelişmesiyle birlikte, NLP modelleri daha yüksek doğruluk oranlarına ulaşmıştır. Bu gelişmeler, büyük veri kümelerinin işlenmesi ve anlamlandırılması konusunda önemli ilerlemeler sağlamıştır (Dahl, 2010).

NLP'nin temel amacı, makinelerin insan dilini anlamasını kolaylaştırarak insan-bilgisayar etkileşimini geliştirmektir. Bunun için sözdizimi analizi, anlamsal yorumlama ve bağlamsal anlama gibi farklı seviyelerde işlem yapılmaktadır. Bu bölümde NLP'nin tarihsel gelişimi, tanımı ve temel bileşenleri ele alınacaktır (Lane ve Dyschel, 2025)

1.1. NLP'nin Tarihsel Gelişimi

Doğal Dil İşleme, 1950'lerden itibaren bilim insanlarının ilgisini çekmeye başlamıştır. İlk çalışmalar, makine çevirisi ve sözcük tabanlı analizler üzerine yoğunlaşmıştır. 1960'larda Chomsky'nin dönüşümsel dilbilgisi teorisi, NLP modellerinin gelişiminde önemli bir dönüm noktası olmuştur. 1970'lerde ve 1980'lerde mantıksal dil modelleri ve bilgi tabanlı sistemler NLP araştırmalarına yön vermiştir (Jones, 1994).

1990'lardan sonra, istatistiksel yöntemlerin ve makine öğrenmesi tekniklerinin gelişmesiyle NLP büyük bir dönüşüm geçirmiştir (Juhn ve Liu, 2020). Günümüzde, derin öğrenme teknikleri ve büyük dil modelleri sayesinde NLP alanında büyük ilerlemeler kaydedilmiştir. Transformer tabanlı modeller, özellikle OpenAI'nin GPT serisi ve Google'ın BERT modeli, doğal dil anlama konusunda yeni bir çağ başlatmıştır (Wen, 2023).

1.2. NLP'nin Tanımı

Doğal Dil İşleme (NLP), bilgisayarların insan dilini anlama, işleme ve üretme süreçlerini kapsayan bir yapay zeka alt alanıdır. Temel amacı, bilgisayarların insan dilini doğal bir şekilde anlamasını sağlamak ve bu bilgiyi etkin bir şekilde kullanmaktır (Nadkarni ve ark., 2011).

NLP, genellikle doğal dil anlama (NLU) ve doğal dil üretimi (NLG) olmak üzere iki ana bileşen etrafında şekillenmektedir. NLU, bilgisayarların insan dilini doğru bir şekilde anlamasını çalışırken, NLG, makinelerin insan benzeri dil üretmesini mümkün kılmaya çalışmaktadır (Salveter, 1981). Bu süreçler, makine öğrenmesi, derin öğrenme ve istatistiksel modelleme gibi yöntemlerle desteklenmektedir.

2. Literatür İncelemesi

Khurana ve arkadaşları, 2023 yılında yaptıkları çalışmada, NLP'nin tarihsel gelişimini, temel bileşenlerini ve çeşitli uygulama alanlarını ayrıntılı bir şekilde ele almıştır. NLP'nin makine çevirisi, bilgi çıkarımı ve tıbbi teşhis gibi geniş bir yelpazede kullanıldığı vurgulanmıştır. Ayrıca, mevcut veri setleri, değerlendirme metrikleri ve karşılaşılan zorluklar üzerinde durulmuştur (Khurana ve ark., 2023).

Palmer yaptığı doğal dil işleme çalışmasında, bağlamdan bağımsız gramerler (CFG) ve sözdizimsel ayrıştırma (parsing) gibi temel dilbilimsel kavramlar ele alınmış, top-down ve bottom-up ayrıştırma yöntemleri detaylandırılmıştır. Bu yöntemlerin dil modellerinde nasıl kullanıldığı ve ağaç yapılarına dayalı analizler açıklanmıştır (Palmer, 2003).

Bir başka çalışmada, şirketlerin çevresel ihlalleri örtmek için hazırladığı CSR raporları, doğal dil işleme teknikleriyle analizler yapılmıştır. Çalışma, çevresel terminoloji sözlükleri kullanarak raporların tonunu ve okunabilirliğini değerlendirmiş, özellikle seçici açıklama ve dikkat saptırma teorileri bağlamında yeşil aklama tespit edilmiştir (Gorovaia ve Makrominas, 2025).

Machado ve arkadaşlarının çalışması, ilaç-ilaç etkileşimlerini (DDI) biyomedikal metinlerden çıkarmak için metin madenciliği ve makine öğrenmesi tabanlı bir sistem önermiştir. İlaç varlıklarının tanımlanması ve etkileşimlerinin sınıflandırılması için çift yönlü LSTM ve CRF modelleri kullanılmış, önerilen sistemin yüksek doğruluk oranlarına ulaştığı belirtilmiştir (Machado ve ark., 2025).

Günümüzde oldukça popüler olan ChatGPT ile yapılan bir çalışmada ChatGPT'nin sıfır-atış (zero-shot) öğrenme yetenekleri 20 farklı NLP veri setinde test edilmiştir. Çalışma, modelin aritmetik akıl yürütme ve dil çıkarımı gibi görevlerde başarılı olduğunu, ancak dizi etiketleme (sequence

tagging) ve özetleme gibi görevlerde özel olarak eğitilmiş modellerin gerisinde kaldığını göstermiştir (Qin ve ark., 2023)


Lauriola ve arkadaşları, metni, derin öğrenme tekniklerinin NLP'deki etkilerini inceleyerek Transformer tabanlı modellerin dil anlama ve üretme görevlerindeki üstün başarısını vurgulamıştır. Makine çevirisi ve adlandırılmış varlık tanıma gibi alanlarda geleneksel yöntemlerin yerini derin sinir ağlarının aldığını ve bu modellerin büyük veri kümeleriyle eğitilerek yüksek performans elde ettiğini ifade etmektedir (Lauriola ve ark., 2022)

Bir diğer çalışmada, NLP sistemlerinde ortaya çıkabilecek veri, ek açıklama süreci, girdi temsilleri, modeller ve araştırma tasarımı gibi beş ana önyargı kaynağını tanımlamıştır. Çalışmada, bu önyargıların sosyal ve demografik eşitsizliklere yol açabileceği ve NLP modellerinin adil kullanımını engelleyebileceği vurgulanmıştır (Hovy ve Prabhumoye, 2021).

3. Doğal Dil İşleme Mimarileri

Doğal Dil İşleme (NLP), dilin analiz edilmesi, modellenmesi ve üretilmesi için çeşitli mimariler kullanmaktadır. NLP mimarileri beş ana kategoriye ayrılmaktadır. Bu kategoriler, kural tabanlı sistemler, makine öğrenimi tabanlı modeller, derin öğrenme tabanlı modeller, transformer tabanlı modeller ve hibrit sistemler olarak adlandırılabilir (Sodiya, 2007).

NLP mimarilerinin şeması şekil 1'de gösterilmiştir (Natural Language Processing (NLP), 2025).



Şekil 1. NLP mimarileri.


3.1. Kural Tabanlı NLP Mimarileri

Kural tabanlı NLP sistemleri, dilbilgisel kurallar ve anlamsal analizler kullanarak metinleri işler. Sözdizimsel (syntax-based) ve anlamsal (semantic-based) kurallara dayanır. Bu tür sistemler, dilbilgisi kuralları, kelime dağarcığı ve bağlamsal dil işleme prensiplerini içermektedir (Santaholma, 2007).

Kural tabanlı NLP mimarilerinin

- Avantajları: Açıklanabilirlik ve belirli görevlerde yüksek doğruluk oranı sağlamaktadır.
- Dezavantajları: Kuralların manuel olarak oluşturulması zordur. Ayrıca ölçeklenebilirlik düzeyi eksiktir.

Kural tabanlı NLP sistemlerinin genel mimarisi şekil 2’de gösterilmiştir (Berka, 2020).



Şekil 2. Kural tabanlı NLP sistemlerinin genel mimarisi

3.1.1. Düzenli İfadeler (Regex)

Metin içinde belirli desenleri yakalamak için kullanılmaktadır (Harman ve Aydemir, 2022).

3.1.2. Çizgesel Anlamsal Modellemeler

Kelimeler arasındaki ilişkileri belirlemek için kullanılan anlamsal ağlardır (Bara ve Guida, 1984).


3.2. Makine Öğrenimi Tabanlı NLP Modelleri

Makine öğrenimi tabanlı NLP modelleri, büyük veri kümeleri üzerinde öğrenme sağlamaktadır. Bu modeller istatistiksel yöntemler ve özellik mühendisliği teknikleri kullanarak dil işleme görevlerini gerçekleştirmektedir (Wen-Hua, 2005).

Makine öğrenimi tabanlı NLP uygulamalarının;

- Avantajları: Daha geniş veri kümelerinden öğrenebilme yeteneği ve esneklik sağlamaktadır.
- Dezavantajları: Kurallar belirlenmeden öğrenme yaptığı için açıklanabilirliği düşüktür.

Makine öğrenimi tabanlı NLP mimarisi şekil 3’de gösterilmiştir (Ashish Tripathi ve ark., 2021).



Şekil 3 Makine öğrenimi tabanlı NLP mimarisi.

Başlıca makine öğrenimi algoritmaları aşağıda başlıklar halinde verilmiştir.

3.2.1. Naive Bayes

Olasılık temelli metin sınıflandırma yöntemidir. Naive Bayes, olasılık temelli bir makine öğrenmesi algoritmasıdır ve Bayes Teoremi’ne dayanır. Özelliklerin birbirinden bağımsız olduğunu varsayarak sınıflandırma yapmaktadır. Metin sınıflandırma, duygu analizi ve spam filtreleme gibi uygulamalarda sıkça kullanılmaktadır (Phuc ve Phung, 2007).

3.2.2. Destek Vektör Makineleri (SVM)

Yüksek boyutlu metin verilerinde etkili bir sınıflandırma modelidir. Sınıflandırma ve regresyon analizinde kullanılan güçlü bir makine öğrenmesi algoritmasıdır. Veriyi, en geniş marjı sağlayacak şekilde bir hiper düzlemlerle ayırmayı hedeflemektedir. Çekirdek (kernel) fonksiyonları sayesinde doğrusal olarak ayrılmayan verileri de başarılı bir şekilde ayırmaktadır. Yüksek boyutlu veri kümelerinde etkili çalışır ve özellikle metin sınıflandırma, biyoinformatik ve görüntü tanıma gibi alanlarda yaygın olarak kullanılmaktadır (Rameshbhai ve Paulose, 2019).

3.2.3. Karar Ağaçları

Veri kümesindeki özellikleri kullanarak dallara ayıran bir modeldir. Karar Ağaçları, veri kümesini dallara ayırarak sınıflandırma ve regresyon yapmaya yarayan bir makine öğrenmesi algoritmasıdır. Her dal, bir özelliğe dayalı kararları temsil ederken, yaprak düğümler sonuçları belirtmektedir. Basit ve anlaşılır yapısı nedeniyle yorumlanabilirliği yüksektir. Ağaç yapısını oluştururken en iyi ayrımı sağlayan özellik seçilir ve bu süreç tekrarlanarak ağaç genişletilmektedir. Karar Ağaçları, eksik verilere karşı dayanıklıdır ve çeşitli veri türleriyle çalışabilmektedir (Öztürk ve ark., 2020).

3.2.4. Rastgele Ormanlar

Rastgele Ormanlar, Karar ağaçlarının topluluğundan oluşan bir modeldir. Rastgele Ormanlar, birden fazla Karar Ağacının bir araya getirilmesiyle oluşturulan topluluk (ensemble) öğrenme yöntemidir. Her ağaç, eğitim verisinin rastgele bir alt kümesiyle eğitilir ve tahminler bu ağaçların oylarına göre yapılmaktadır. Aşırı öğrenmeyi (overfitting) azaltır ve daha yüksek doğruluk sağlamaktadır. Hem sınıflandırma hem de regresyon problemlerinde etkili bir şekilde kullanılmaktadır. Özellikle büyük veri kümelerinde ve yüksek boyutlu özellik uzaylarında başarılı sonuçlar vermektedir (Hızlısoy ve Tüfekci, 2021).

3.3. Derin Öğrenme Tabanlı NLP Mimarileri

Derin öğrenme tabanlı NLP modelleri, büyük veri setleriyle eğitilen derin sinir ağlarını kullanmaktadır. Bu modeller, dilin daha derin yapısal ilişkilerini öğrenme kapasitesi sağlamaktadır (Wolf ve ark., 2020).

Başlıca derin öğrenme mimarileri aşağıda başlıklar halinde anlatılmaktadır.

3.3.1. Derin Sinir Ağları (DNN)

Derin Sinir Ağları (DNN), birden fazla gizli katmandan oluşan derin öğrenme modelleridir. Her katmandaki nöronlar, bir önceki katmandaki tüm nöronlara bağlıdır ve bu bağlantılar ağırlıklarla temsil edilmektedir. Girdi verilerini işleyerek özellikleri öğrenir ve çıktı katmanında tahminler üretmektedir. Büyük veri kümeleriyle çalışarak karmaşık örüntüleri ve ilişkileri öğrenebilmektedir. Görüntü işleme, doğal dil işleme ve ses tanıma gibi birçok alanda yaygın olarak kullanılmaktadır (Küçük ve Arıcı, 2018).

3.3.2. Tekrarlayan Sinir Ağları (RNN)

Tekrarlayan Sinir Ağları (RNN), özellikle sıralı ve zamana bağlı verileri işlemek için tasarlanmış bir yapay sinir ağı türüdür. Her bir adımda, hem mevcut girdiyi hem de önceki adımın çıktısını kullanarak veri üzerinde öğrenme yapmaktadır. Bu geri bildirim döngüsü sayesinde, zaman serileri, dil modelleri ve konuşma tanıma gibi ardışık verilerde güçlü performans göstermektedir. Ancak, uzun dizilerde bilgi kaybı (kaybolan gradyan sorunu) yaşayabilmektedir. Bu sorunu aşmak için LSTM ve GRU gibi gelişmiş RNN türevleri geliştirilmiştir (Babüroğlu ve ark., 2019).

3.3.3. LSTM (Long Short-Term Memory)

LSTM (Long Short-Term Memory), uzun vadeli bağımlılıkları öğrenmek için geliştirilen bir Tekrarlayan Sinir Ağı (RNN) türüdür. Standart RNN'lerin yaşadığı kaybolan gradyan sorununu çözmek için özel olarak tasarlanmıştır. Hücre durumu, giriş, çıkış ve unutma kapıları sayesinde önemli bilgileri uzun süre saklayabilmekte ve gereksiz bilgileri eleyebilmektedir. Bu özelliği sayesinde dil modeli, makine çevirisi ve video analizi gibi ardışık verilerde yüksek performans sergilemektedir. Zaman serisi tahminleri ve konuşma tanıma gibi alanlarda da yaygın olarak kullanılmaktadır (Yao ve Guan, 2018).

3.3.4. GRU (Gated Recurrent Unit)

GRU (Gated Recurrent Unit), LSTM'ye benzer şekilde uzun vadeli bağımlılıkları öğrenebilen bir Tekrarlayan Sinir Ağı (RNN) türüdür. LSTM'den farklı olarak, hücre durumu ve çıkış için ayrı kapılar yerine daha az sayıda kapı kullanmaktadır. Bu durum daha basit ve hızlı olmasını sağlamaktadır. Güncelleme ve unutma kapıları sayesinde bilgileri seçici şekilde saklamaktadır veya unutmaktadır. Daha az hesaplama maliyeti ile daha hızlı eğitim sağlar. Özellikle dil modelleri, konuşma tanıma ve zaman serisi analizinde tercih edilmektedir (Dey ve Salem, 2017).

3.3.5. Konvolüsyonel Sinir Ağları (CNN)

Konvolüsyonel Sinir Ağları (CNN), öncelikle görüntü işleme için geliştirilmiş olup, yerel özellikleri yakalama yeteneği sayesinde metin işleme alanında da kullanılmaktadır. Özellik haritaları oluşturarak verideki önemli desenleri ve ilişkileri öğrenmektedir. Metin sınıflandırma, duygu analizi ve dil modellerinde başarılı sonuçlar vermektedir. Kayar pencere (sliding window) yöntemiyle metinlerdeki ardışık kelimeler arasında bağlantılar kurmaktadır. Hesaplama verimliliği ve paralel işleme yeteneği ile büyük

veri kümelerinde tercih edilmektedir (Karadeniz ve ark., 2023), (Başaran ve ark., 2020).

3.4. Transformer Tabanlı Modeller

Transformer tabanlı modeller, dikkat mekanizması (attention) kullanarak dildeki uzun vadeli bağımlılıkları etkili bir şekilde öğrenir ve paralel işlem yetenekleriyle büyük veri kümelerinde yüksek performans sağlamaktadır (Saka ve Cömert, 2024). Doğal dil işleme, makine çevirisi, özetleme ve metin üretimi gibi birçok görevde yaygın olarak kullanılmaktadır.


Transformer tabanlı NLP modellerinin;

- Avantajları: Büyük veri üzerinde güçlü genelleştirme yeteneği ve dil anlama başarımı yüksektir.
- Dezavantajları: Eğitmek için büyük miktarda veri ve hesaplama gücü gerektirmektedir.

3.4.1. BERT (Bidirectional Encoder Representations from Transformers)

BERT (Bidirectional Encoder Representations from Transformers), Google tarafından geliştirilen ve doğal dil işleme görevlerinde çığır açan bir Transformer modelidir. İki yönlü (bidirectional) yapısıyla bir cümlemin hem solundaki hem de sağındaki bağlamı aynı anda analiz edebilmektedir. Maskelenmiş dil modeli (MLM) ve cümle çiftlerini tahmin etme (NSP) gibi ön eğitim görevleriyle eğitilmektedir. Soru-cevap sistemleri, duygu analizi ve metin sınıflandırma gibi birçok NLP görevinde üstün performans sergilemektedir. Transfer öğrenmeye uygun yapısıyla geniş çapta kullanım alanına sahiptir (Polignano ve ark., 2019).

Bert mimarisi şekil 4’de gösterilmiştir (Sun ve ark., 2022).



Şekil 4. Bert mimarisi.

3.4.2. GPT (Generative Pre-trained Transformer)

GPT (Generative Pre-trained Transformer), OpenAI tarafından geliştirilen ve metin üretiminde ön plana çıkan bir Transformer modelidir. Geniş veri kümeleri üzerinde önceden eğitilerek dilin yapısını ve bağlamını öğrenmektedir. Tek yönlü (unidirectional) yapısıyla bir cümledeki önceki kelimelere dayanarak sonraki kelimeleri tahmin etmektedir. Sohbet botları, metin tamamlama, özetleme ve çeviri gibi birçok doğal dil işleme görevinde kullanılmaktadır. Özelleştirilebilir yapısı sayesinde farklı alanlara kolayca adapte edilebilmektedir (Yenduri ve ark., 2024).

3.4.3. T5 (Text-to-Text Transfer Transformer)

T5 (Text-to-Text Transfer Transformer), Google tarafından geliştirilen ve tüm doğal dil işleme görevlerini bir metinden metne dönüştürme (text-to-text) çerçevesinde ele alan bir Transformer modelidir. Makine çevirisi, özetleme, soru-cevaplama ve sınıflandırma gibi görevleri tek bir yapı altında gerçekleştirebilmektedir. Girdi ve çıktıların metin formatında olması, görevler arasında tutarlılığı artırmaktadır. Büyük veri kümeleri üzerinde eğitilerek yüksek performans sunmaktadır. Esnek yapısı sayesinde çok çeşitli NLP uygulamalarında yaygın olarak kullanılmaktadır (Mastropaolo ve ark., 2021).

3.4.4. XLNet, RoBERTa, ALBERT

- XLNet: Oto-regresif (kendi kendini tahmin eden) ve iki yönlü bağlam anlayışını birleştirerek BERT ve GPT'nin avantajlarını bir araya getiren bir Transformer modelidir. Permütasyon tabanlı eğitim yöntemi sayesinde dil modellemede daha esnek ve güçlüdür (Yan ve ark., 2021).
- RoBERTa: BERT'in geliştirilmiş bir versiyonudur. Daha büyük veri kümeleri, daha uzun eğitim süreleri ve farklılaştırılmış maskelenmiş dil modeli teknikleri kullanarak NLP görevlerinde daha yüksek doğruluk sağlamaktadır (Rothman, 2021).
- ALBERT: BERT'in daha hafif ve hızlı bir versiyonudur. Parametre paylaşımı ve boyut azaltma teknikleri sayesinde daha az hesaplama gücü gerektirmektedir, bu da büyük modellerin daha verimli kullanılmasını sağlamaktadır (Choi ve ark., 2021).

3.4.5. BART (Bidirectional and Auto-Regressive Transformer)

BART (Bidirectional and Auto-Regressive Transformer), Facebook tarafından geliştirilen ve hem BERT gibi iki yönlü hem de GPT gibi yapıları birleştiren bir Transformer modelidir. Metinleri bozup (maskeliyor veya karıştırıyor) ardından orijinal haline getirmek için eğitilmektedir. Bu özellik, metin üretimi, özetleme, çeviri ve hata düzeltme gibi NLP görevlerinde üstün performans sergilemesini sağlamaktadır. Özellikle metin tamamlama ve geri yükleme işlemlerinde oldukça başarılı sonuçlar vermektedir (Hartawan ve ark., 2024) .

3.5. Hibrit NLP Mimarileri

Hibrit NLP mimarileri, kural tabanlı sistemler ile makine öğrenimi veya derin öğrenme yöntemlerini birleştirir. Bu yaklaşım, iki yöntemin avantajlarını bir araya getirerek daha güçlü bir dil işleme modeli oluşturmayı amaçlar (Shidaganti ve ark., 2024).

Hibrit NLP modellerinin;

- Avantajları: Hem kuralların açıklanabilirliğini hem de öğrenme modellerinin esnekliğini sağlamaktadır.
- Dezavantajları: Entegrasyon süreci karmaşıktır ve maliyetleri yüksektir.

Öne çıkan hibrit modeller aşağıdaki başlıklarda anlatılmıştır.

3.5.1. IBM Watson

IBM Watson, doğal dil işleme (NLP) ve yapay zeka destekli büyük ölçekli dil analizi ve bilgi çıkarımı yapabilen bir platformdur. Karmaşık soruları anlayarak insan benzeri yanıtlar verebilmektedir ve yapılandırılmamış metinlerden anlamlı bilgiler çıkarabilmektedir. Sağlık, finans, müşteri hizmetleri gibi birçok sektörde kullanılmaktadır. Makine öğrenmesi ve derin öğrenme tekniklerini kullanarak metin sınıflandırma, duygu analizi ve otomatik yanıt sistemlerinde başarılı çözümler sunmaktadır. Geliştiriciler için API desteği sağlayarak kolay entegrasyon imkanı tanımaktadır (Strickland, 2019).

3.5.2. Google NLP API

Google NLP API, doğal dil işleme için kural tabanlı yöntemler ile makine öğrenimi yaklaşımlarını birleştiren güçlü bir araçtır. Metin sınıflandırma, duygu analizi, varlık tanıma ve dil algılama gibi birçok NLP görevini desteklemektedir. Büyük veri kümeleri üzerinde eğitilen modelleri sayesinde yüksek doğruluk sağlamaktadır. Bulut tabanlı hizmetiyle geliştiricilere ölçeklenebilir çözümler sunmaktadır. Metin analizi süreçlerini kolaylaştırarak çeşitli sektörlerde geniş bir kullanım alanı bulmaktadır (Mittal ve ark., 2023).

4. Doğal Dil İşlemenin Uygulama Alanları

Doğal Dil İşleme (NLP), dilin analiz edilmesi, modellenmesi ve üretilmesi süreçlerinde kullanılan yapay zeka tekniklerini içermektedir. NLP, birçok sektörde geniş kullanım alanlarına sahiptir ve farklı disiplinlerde önemli gelişmeler sağlamaktadır (Shivahare ve ark., 2022a).

Bu bölümde, NLP'nin en yaygın uygulama alanları ele alınacaktır.

4.1. Makine Çevirisi (Machine Translation)

Makine çevirisi, bir dili diğerine otomatik olarak çevirmeye yönelik teknolojilerden oluşmaktadır. NLP, bu süreçte metinleri analiz ederek kaynak dilden hedef dile anlam kaybını en aza indirerek çeviri yapmayı hedeflemektedir (Men, 2015).

Google Translate, DeepL ve Microsoft Translator gibi araçlar, günümüzde derin öğrenme tabanlı çeviri modellerini kullanmaktadır. Bu sistemler, milyonlarca metin örneğinden öğrenerek dil çiftleri arasındaki bağlamı anlamaya çalışmaktadır (G ve ark., 2023a).

Makine çevirisi, küresel iletişimi kolaylaştırırken bazı zorlukları da barındırmaktadır. Dillerin gramer yapıları ve kültürel bağlam farklılıkları nedeniyle tam anlamıyla insan çevirisiyle eşleşme zorluğu yaşanmaktadır (Clement, 1987).

4.2. Duygu Analizi (Sentiment Analysis)

Duygu analizi, metinlerdeki olumlu, olumsuz veya nötr duyguları belirlemek için kullanılan bir NLP tekniğidir. Özellikle sosyal medya, müşteri yorumları ve anket analizleri gibi alanlarda büyük önem taşımaktadır (*Natural Language Processing*, 1991).

Bu teknik, şirketlerin müşteri memnuniyetini ölçmesine, pazarlama stratejilerini optimize etmesine ve tüketici eğilimlerini analiz etmesine yardımcı olmaktadır. Örneğin, büyük markalar, Twitter ve Facebook gibi platformlardaki paylaşımları analiz ederek, ürünleri hakkında kullanıcıların ne düşündüğünü anlayabilmektedir (G ve ark., 2023b)

Duygu analizi modelleri, özellikle doğal dildeki ironi ve çok anlamlı kelimeleri anlamakta zorlanabilmektedir. Ancak derin öğrenme tabanlı modeller sayesinde bu sistemler giderek daha başarılı hale gelmektedir (Surabhi ve Velalar, 2013a).

4.3. Konuşma Tanıma (Speech Recognition)

Konuşma tanıma, sesli ifadelerin metne dönüştürülmesini sağlayan bir NLP uygulamasıdır. Siri, Google Assistant ve Amazon Alexa gibi sesli asistanlar, bu teknolojiye dayanarak kullanıcıların doğal diliyle etkileşime girmesini sağlamaktadır (Shivahare ve ark., 2022b)

Bu sistemler, konuşmayı tanımak için dil modelleri, akustik modeller ve ses dalga formlarını analiz eden sinir ağlarını kullanmaktadır. Sesin gürültülü ortamlarda olması veya farklı aksanların bulunması gibi faktörler sistemin başarısını etkileyebilmektedir (Morgan ve Scofield, 1991)

Konuşma tanıma teknolojisi, çağrı merkezlerinde, tıbbi dikte sistemlerinde ve engelli bireyler için geliştirilen yardımcı teknolojilerde geniş bir kullanım alanına sahiptir (Surabhi ve Velalar, 2013).

4.4. Otomatik Metin Özetleme (Automatic Text Summarization)

Otomatik metin özetleme, büyük miktarda metni daha kısa ve öz bir şekilde sunmak için kullanılan bir NLP tekniğidir. Haber siteleri, akademik makaleler ve belge yönetim sistemlerinde sıklıkla kullanılmaktadır (Yeldo, 2021)

Bu teknolojinin iki temel yöntemi bulunmaktadır:

1. **Çıkarımsal Özetleme (Extractive Summarization):** Metindeki en önemli cümleleri seçerek özet oluşturmaktadır.
2. **Üretken Özetleme (Abstractive Summarization):** Metnin anlamını analiz ederek yeni cümleler üretmektedir.

Bu sistemler, büyük belge havuzlarından anlamlı özetler çıkararak kullanıcıların bilgiye daha hızlı erişmesini sağlamaktadır. Özellikle hukuk, akademik araştırmalar ve haber sektörlerinde büyük fayda sağlamaktadır (G ve ark., 2023).

4.5. Chatbot ve Sanal Asistanlar

Chatbotlar, kullanıcılarla doğal dilde etkileşime giren programlardır. Müşteri hizmetleri, sağlık, finans ve eğitim sektörlerinde yaygın olarak kullanılmaktadır (Gelbukh, 2005)

Modern chatbot sistemleri, GPT-4, BERT ve Dialogflow gibi derin öğrenme modelleri ile güçlendirilmiştir. Bu sistemler, kullanıcıların sorularına anlamlı ve doğal yanıtlar verebilmektedir (Singh ve Namin, 2025)

Sanal asistanlar, iş yerlerinde üretkenliği artırmak, hasta takibini kolaylaştırmak ve e-ticaret alanında müşteri deneyimini geliştirmek için kullanılmaktadır. Bu sistemler, zamanla daha akıllı hale gelerek insan-bilgisayar etkileşimini daha doğal hale getirmektedir (Schulz, 2021).

5. Tartışma

Bu çalışma, literatürdeki mevcut NLP modelleri ile karşılaştırıldığında, Transformer tabanlı mimarilerin özellikle karmaşık ve büyük veri kümelerinde yüksek başarı gösterdiğini ortaya koymaktadır. Transformer mimarileri, dikkat (attention) mekanizmaları sayesinde küresel bağlamı yakalayarak diğer yöntemlere kıyasla daha güçlü bir performans sergilemiştir. Ancak, bu modellerin yüksek hesaplama gücü gereksinimi, pratik uygulamalarda önemli bir sınırlılık olarak belirlenmiştir.

Klasik makine öğrenmesi yöntemleri, daha az hesaplama gerektirmesine rağmen, karmaşık dil yapılarını analiz etmede sınırlı kalmaktadır. Örneğin, CFG ve ayrıştırma temelli yaklaşımlar, açıklanabilirlik avantajı sunsa da, derin öğrenme modellerinin sunduğu esneklik ve doğruluk seviyesine ulaşamamaktadır. Bu durum, NLP uygulamalarında performans ve açıklanabilirlik arasındaki dengeyi korumanın önemini vurgulamaktadır.

Literatürde, NLP'nin etik analizler, tıbbi metin madenciliği ve biyo-medikal veri analizi gibi kritik alanlarda kullanıldığı görülmektedir. Özel-

likle, LSTM ve CRF gibi modellerin klinik veri analizi konusundaki başarısı dikkat çekmekte, ancak bu tür uygulamaların veri yoğunluğu nedeniyle performans açısından zorlayıcı olduğu belirtilmektedir.

Transformer mimarilerinin, ChatGPT gibi çok yönlü modellerle birleştirilmesi, genel NLP görevlerinde yüksek başarı sağlamış ancak belirli uzmanlık gerektiren etiketleme gibi görevlerde sınırlılıklar göstermiştir. Bu bulgular, gelecekteki araştırmalarda daha optimize ve veri dostu NLP çözümlerine ihtiyaç duyulduğunu göstermektedir.

Sonuç olarak, mevcut çalışmalar, Transformer tabanlı NLP modellerinin sunduğu yüksek performans ve çok yönlülüğe dikkat çekmekte, ancak hesaplama maliyeti ve özelleşmiş görevlerdeki eksikliklerin, gelecekteki çalışmalar için önemli araştırma alanları olduğunu ortaya koymaktadır.

Bu çalışmaların karşılaştırması Tablo 1’de sunulmuştur:

Tablo 1. Örnek literatür karşılaştırma tablosu.

Çalışma	Yöntem	Uygulama Alanı	Avantajlar	Dezavantajlar
Khurana ve ark., 2022	Derin Öğrenme, Transformer	Makine Çevirisi, Bilgi Çıkarımı	Geniş Uygulama Alanı	Hesaplama Gücü Gerekсинimi
Palmer, 2015	CFG, Parsing	Dil Analizi	Açıklanabilirlik	Modern Yöntemlere Göre Daha Zayıf
Gorovaia ve Makrominas, 2025	NLP, Metin Madenciliği	Yeşil Aklama Tespiti	Yüksek Hassasiyet	Okunabilirlik Sorunları
Machado ve ark l., 2025	LSTM, CRF	Biyomedikal NLP	Klinik Relevans	Veri Yoğunluk Sorunu
Qin et al., 2023	ChatGPT, RLHF	Genel NLP Görevleri	Çok Yönlülük	Dizi Etiketlemede Zayıf
Lauriola ve ark., 2022	Transformer	Dil Anlama ve Üretme	Yüksek Performans	Kaynak Yoğunluğu
Hovy ve Prabhumoye, 2021	NLP, Sosyal Analiz	Önyargı Analizi	Farkındalık Artırma	Düşük Performans Riskleri

Bu bölüm, NLP alanındaki farklı yaklaşımların ve uygulamaların gücünü ve sınırlarını ortaya koyarak, gelecekteki araştırmalara rehberlik edebilecek bir bağlam sunmaktadır.

6. Sonuç

Bu kitap bölümünde incelenen çalışmalar, NLP'nin geniş uygulama yelpazesi ve farklı yaklaşımlarını gözler önüne sermektedir. Derin öğrenme ve Transformer tabanlı modellerin sağladığı yüksek performans, hesaplama gücü gereksinimi nedeniyle sınırlamalarla karşı karşıya kalmaktadır. Kural tabanlı sistemler ve geleneksel dilbilim yöntemleri ise açıklanabilirlik avantajı sunarken, modern uygulamalara göre daha sınırlı kalmaktadır.

Özellikle biyomedikal alanlarda NLP'nin kullanımı, sağlık hizmetlerinin kalitesini artırma potansiyeli sunarken, veri yoğunluğu ve çeşitliliği nedeniyle zorluklar barındırmaktadır. Sosyal ve etik açıdan, NLP sistemlerinin önyargılara açık olması, bu teknolojilerin adil ve kapsayıcı olmasını sağlamak için dikkatli araştırmalar yapılmasını gerektirmektedir.

Sonuç olarak, NLP alanındaki araştırmaların daha şeffaf, hesaplanabilir ve etik odaklı olması gerektiği vurgulanmalıdır. Gelecekteki çalışmaların, daha az hesaplama gücü gerektiren modeller geliştirmesi, farklı dil ve kültürleri kapsayan geniş veri kümeleri oluşturmaları ve sistematik önyargıları azaltmaya odaklanması önem arz etmektedir. Bu kitap bölümü, NLP'nin geleceğine dair bir yol haritası sunmayı amaçlamaktadır.

Kaynaklar

- A. Gelbukh. (2005). *Natural Language Processing*. 6. <https://doi.org/10.1109/IC-HIS.2005.79>
- Ashish Tripathi, Arun Kumar Singh, & Krishna Kant Singh. (2021). Chapter 1 - Machine learning architecture and framework. *Machine Learning and the Internet of Medical Things in Healthcare*, 1–22.
- Babüroğlu, B., Tekerek, A., & Tekerek, M. (2019). Türkçe için derin öğrenme tabanlı doğal dil işleme modeli geliştirilmesi. *13th International Computer and Instructional Technology Symposium (ICITS)*, 671–679.
- Bara, B., & Guida, G. (1984). Computational models of natural language processing. *Journal of Chinese Information Processing*. <https://consensus.app/papers/computational-models-of-natural-language-processing-bara-guida/1ea5d4946e0a536a8d045d9229830ec1/>
- Başaran, E., Cömert, Z., & Çelik, Y. (2020). Convolutional neural network approach for automatic tympanic membrane detection and classification. *Biomedical Signal Processing and Control*, 56, 101734.
- Berka, P. (2020). Sentiment analysis using rule-based and case-based reasoning. *Journal of Intelligent Information Systems*, 55(1), 51–66.
- Choi, H., Kim, J., Joe, S., & Gwon, Y. (2021). Evaluation of bert and albert sentence embedding performance on downstream nlp tasks. *2020 25th International Conference on Pattern Recognition (ICPR)*, 5482–5487.
- Clement, L. (1987). *Natural Languages And Their Commercial Applications*. 276–280. https://doi.org/10.1007/978-1-4612-4756-2_32
- Dahl, V. (2010). An Introduction to Natural Language Processing: the Main Problems. *Triangle: Llenguatge, Literatura, Computació*, 1, 65–78.
- David P. Morgan, & Christopher L. Scofield. (1991). Natural Language Processing. *The Springer International Series in Engineering and Computer Science*, 245–288. https://doi.org/10.1007/978-1-4615-3950-6_8
- Dey, R., & Salem, F. M. (2017). Gate-variants of gated recurrent unit (GRU) neural networks. *2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS)*, 1597–1600.
- G, S., Takore, T. T., Ravuri, P., Nagpal, A., Lourens, M., & Babu, K. (2023a). Developments in Natural Language Processing: Applications and Challenges. *2023 10th IEEE Uttar Pradesh Section International Conference on Electrical, Electronics and Computer Engineering (UPCON)*, 10, 582–585. <https://doi.org/10.1109/UPCON59197.2023.10434553>
- Gorovaia, N., & Makrominas, M. (2025). Identifying greenwashing in corporate-social responsibility reports using natural-language processing. *European Financial Management*, 31(1), 427–462.

- Harman, G., & Aydemir, E. (2022). Kolay Kişiselleştirilebilir Akıllı Sanal Asistan. *International Journal of Multidisciplinary Studies and Innovative Technologies*, 6(2), 143–151.
- Hartawan, G., Maylawati, D. S., & Uriawan, W. (2024). Bidirectional and Auto-Regressive Transformer (BART) for Indonesian Abstractive Text Summarization. *Jurnal Informatika Polinema*, 10(4), 535–542.
- Hızlısoy, S., & Tüfekci, Z. (2021). Derin Öğrenme İle Türkçe Müziklerden Müzik Türü Sınıflandırması. *Avrupa Bilim ve Teknoloji Dergisi*, 24, 176–183.
- Hovy, D., & Prabhumoye, S. (2021). Five sources of bias in natural language processing. *Language and Linguistics Compass*, 15(8), e12432.
- Jones, K. S. (1994). Natural language processing: a historical review. *Current Issues in Computational Linguistics: In Honour of Don Walker*, 3–16.
- Juhn, Y., & Liu, H. (2020). Artificial intelligence approaches using natural language processing to advance EHR-based clinical research. *Journal of Allergy and Clinical Immunology*, 145(2), 463–469.
- Karadeniz, A. T., Çelik, Y., & Başaran, E. (2023). Classification of walnut varieties obtained from walnut leaf images by the recommended residual block based CNN model. *European Food Research and Technology*, 249(3), 727–738.
- Khurana, D., Koli, A., Khatter, K., & Singh, S. (2023). Natural language processing: state of the art, current trends and challenges. *Multimedia Tools and Applications*, 82(3), 3713–3744.
- Küçük, D., & Arıcı, N. (2018). Doğal Dil İşlemede Derin Öğrenme Uygulamaları Üzerine Bir Literatür Çalışması. *Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi*, 2(2), 76–86.
- Lane, H., & Dyshel, M. (2025). *Natural language processing in action*. Simon and Schuster.
- Lauriola, I., Lavelli, A., & Aiolfi, F. (2022). An introduction to deep learning in natural language processing: Models, techniques, and tools. *Neurocomputing*, 470, 443–456.
- Machado, J., Rodrigues, C., Sousa, R., & Gomes, L. M. (2025). Drug–drug interaction extraction-based system: An natural language processing approach. *Expert Systems*, 42(1), e13303.
- Mastropaolo, A., Scalabrino, S., Cooper, N., Palacio, D. N., Poshyvanyk, D., Oliveto, R., & Bavota, G. (2021). Studying the usage of text-to-text transfer transformer to support code-related tasks. *2021 IEEE/ACM 43rd International Conference on Software Engineering (ICSE)*, 336–347.
- Men, W. (2015). Natural Language Processing and Its Applications in Education. *Mathematics in Practice and Theory*. <https://consensus.app/papers/natural-language-processing-and-its-applications-in-men/11180aacc44a-52f1a5c7c1b0b20c8d11/>

- Mittal, G., Vivek, R., Mentor, •., & Gao, Y. (2023). *Natural Language Generation with Pixels*. <https://consensus.app/papers/natural-language-generation-with-pixels-mittal-vivek/e6b7d42382205ba5a1147ae6471e0162/>
- Nadkarni, P. M., Ohno-Machado, L., & Chapman, W. W. (2011). Natural language processing: an introduction. *Journal of the American Medical Informatics Association*, 18(5), 544–551.
- Natural Language Processing*. (1991). 245–288. https://doi.org/10.1007/978-1-4615-3950-6_8
- Natural Language Processing (NLP): Empowering Machines to Understand Human Language*. (2025, February 15). <https://www.fita.in/Natural-Language-Processing/>.
- Öztürk, A., Durak, Ü., & Badıllı, F. (2020). Twitter verilerinden doğal dil işleme ve makine öğrenmesi ile hastalık tespiti. *Konya Journal of Engineering Sciences*, 8(4), 839–852.
- Palmer, M. (2003). *Natural language processing*.
- Phuc, D., & Phung, N. T. K. (2007). Using Naïve Bayes model and natural language processing for classifying messages on online forum. *2007 IEEE International Conference on Research, Innovation and Vision for the Future*, 247–252.
- Polignano, M., Basile, P., De Gemmis, M., Semeraro, G., & Basile, V. (2019). Alberto: Italian BERT language understanding model for NLP challenging tasks based on tweets. *CEUR Workshop Proceedings*, 2481, 1–6.
- Qin, C., Zhang, A., Zhang, Z., Chen, J., Yasunaga, M., & Yang, D. (2023). Is ChatGPT a general-purpose natural language processing task solver?(2023). *ArXiv Preprint ArXiv:2302.06476*.
- Rameshbhai, C. J., & Paulose, J. (2019). Opinion mining on newspaper headlines using SVM and NLP. *International Journal of Electrical and Computer Engineering (IJECE)*, 9(3), 2152–2163.
- Rothman, D. (2021). *Transformers for Natural Language Processing: Build innovative deep neural network architectures for NLP with Python, PyTorch, TensorFlow, BERT, RoBERTa, and more*. Packt Publishing Ltd.
- Saka, S. O., & Cömert, Z. (2024). Sentiment analysis based on text with universal sentence encoder and cnn-lstm models. *2024 8th International Artificial Intelligence and Data Processing Symposium (IDAP)*, 1–4.
- Salveter, S. C. (1981). Natural language processing. *American Journal of Computational Linguistics*, 7(4).
- Santaholma, M. (2007). Grammar sharing techniques for rule-based multilingual NLP systems. *Proceedings of the 16th Nordic Conference of Computational Linguistics (NODALIDA 2007)*, 253–260.

- Schulz, K. (2021). Natural Language Processing for Teaching Ancient Languages. *Teaching Classics in the Digital Age*. <https://doi.org/10.38072/2703-0784/p19>
- Shidaganti, G., Shetty, R., Edara, T., Srinivas, P., & Tammineni, S. C. (2024). Exploratory analysis on the natural language processing models for task specific purposes. *Bulletin of Electrical Engineering and Informatics*. <https://doi.org/10.11591/eei.v13i2.6360>
- Shivahare, B. D., Singh, A., Uppal, N., Rizwan, A., Vaathsav, V. S., & Suman, S. (2022a). Survey Paper: Study of Natural Language Processing and its Recent Applications. *2022 2nd International Conference on Innovative Sustainable Computational Technologies (CISCT)*, 1–5. <https://doi.org/10.1109/CISCT55310.2022.10046440>
- Singh, S. U., & Namin, A. S. (2025). A survey on chatbots and large language models: Testing and evaluation techniques. *Natural Language Processing Journal*, 100128.
- Sodiya, A. S. (2007). A natural language architecture. *Journal of Computing and Information Technology*, 15(1), 25–32.
- Strickland, E. (2019). IBM Watson, heal thyself: How IBM overpromised and underdelivered on AI health care. *IEEE Spectrum*, 56(4), 24–31.
- Sun, J., Liu, Y., Cui, J., & He, H. (2022). Deep learning-based methods for natural hazard named entity recognition. *Scientific Reports*, 12(1), 4598.
- Surabhi, C., & Velalar, M. (2013a). Natural language processing future. *2013 International Conference on Optical Imaging Sensor and Security (ICOSS)*, 1–3. <https://doi.org/10.1109/ICOISS.2013.6678407>
- Wen, B. (2023). Research on the applications of natural language processing. *Applied and Computational Engineering*, 16, 220–227.
- Wen-Hua, D. (2005). The Natural Language Processing Models Based on Statistics. *Journal of Xianning Teachers College*. <https://consensus.app/papers/the-natural-language-processing-models-based-on-wen-hua/d49bcf6e-d4f75d8d9dbac987f5c0ddf3/>
- Wolf, T., Debut, L., Sanh, V., Chaumond, J., Delangue, C., Moi, A., Cistac, P., Rault, T., Louf, R., Funtowicz, M., Davison, J., Shleifer, S., Von Platen, P., Clara, Jernite, Y., Plu, J., Xu, C., Scao, T. Le, Gugger, S., ... Rush, A. (2020). *Transformers: State-of-the-Art Natural Language Processing*. 38–45. <https://doi.org/10.18653/v1/2020.emnlp-demos.6>
- Yan, R., Jiang, X., & Dang, D. (2021). Named entity recognition by using XL-Net-BiLSTM-CRF. *Neural Processing Letters*, 53(5), 3339–3356.
- Yao, L., & Guan, Y. (2018). An improved LSTM structure for natural language processing. *2018 IEEE International Conference of Safety Produce Informatization (IICSPI)*, 565–569.

- Yeldo, H. (2021). Natural Language Processing: Components, Advances, Tools and Industrial Applications. *International Journal for Research in Applied Science and Engineering Technology*. <https://doi.org/10.22214/ijra-set.2021.38015>
- Yenduri, G., Ramalingam, M., Selvi, G. C., Supriya, Y., Srivastava, G., Maddikunta, P. K. R., Raj, G. D., Jhaveri, R. H., Prabadevi, B., & Wang, W. (2024). Gpt (generative pre-trained transformer)—a comprehensive review on enabling technologies, potential applications, emerging challenges, and future directions. *IEEE Access*.
- Zhiwei, F. (2005). Academic position of natural language processing. *Journal of PLA University of Foreign Languages*, 28(3), 1–8.

BÖLÜM 2

MEDİKAL GÖRÜNTÜ SEGMENTASYONU: GELENEKSEL YÖNTEMLER VE KOD UYGULAMALARI

Volkan GÖREKE¹

¹ Volkan GÖREKE, Dr.Öğr.Üyesi, Sivas C.Ü. STBMYO Bilgisayar Teknolojileri Bölümü
ORCID NO: 0000-0002-2418-8373

1.Giriş

Tıbbi görüntü segmentasyonu, modern tıp alanında büyük bir öneme sahiptir ve doğru teşhis, tedavi planlaması ve klinik analizler için temel bir süreç olarak kabul edilir. Bu yöntem, bir görüntüyü farklı bölgelere ayırarak belirli anatomik yapıları veya hastalıklı alanları tanımlamayı amaçlar. Örneğin, organlar, dokular ve lezyonlar segmentasyon sayesinde daha net bir şekilde ortaya çıkar. Bu süreç, tümörlerin yerini belirleme, organ sınırlarını hassas bir şekilde çizme ve cerrahi operasyonlar için ayrıntılı planlama yapma gibi kritik tıbbi uygulamalarda yaygın olarak kullanılır. Segmentasyon doğruluğu, hasta bakım kalitesini ve klinik kararların doğruluğunu doğrudan etkilediğinden, sağlık sektöründe vazgeçilmez bir bileşendir. Başarılı bir segmentasyon, doktorların hastalıkları daha iyi anlamasına, tedavi süreçlerini daha etkili yönetmesine ve hastalara daha hızlı ve doğru müdahalelerde bulunmasına olanak tanır. Bu nedenle, tıbbi görüntü segmentasyonu alanındaki yenilikler, tıp teknolojilerinin gelişimi açısından büyük bir değer taşımaktadır (Xu, vd.,2024, s1). Tıbbi görüntüler genellikle görüntüleme cihazlarının sınırlamalarından etkilenmekte ve bu durum düşük kontrast, sınırların belirgin olmaması gibi çeşitli sorunlara yol açmaktadır. Bilgisayarlı tomografi (CT), manyetik rezonans görüntüleme (MRI) ve pozitron emisyon tomografisi (PET) gibi farklı tıbbi görüntüleme yöntemleri, belirli dezavantajlara sahiptir. Örneğin, CT taramaları yumuşak doku ve lezyonları yeterince net göstermezken, MRI kemik yapılarının anatomik görüntülerini oluşturamaz. Bu tür kısıtlamalar, yüksek kaliteli tıbbi görüntü segmentasyonunu bilgisayar destekli teşhis sistemleri için zorlu ve kritik bir problem haline getirmektedir (Shao, J. vd. 2023, s2174).

Görüntü segmentasyonu, bilgisayar görüşünün önemli bir görevidir ve çeşitli alanlarda geniş ölçüde kullanılmaktadır. Günümüzde bu işlemi gerçekleştirmek için iki ana yöntem bulunmaktadır. Birinci yöntemde, derin sinir ağları kullanılarak görüntü hızlıca segmentlere ayrılır. Ancak bu yöntemin dezavantajı, sinir ağının eğitimi ve parametre ayarlamalarının oldukça zaman almasıdır. Diğer bir yöntem ise, geleneksel tekniklerin uygulanmasıdır; bu yaklaşım, ileri düzey matematiksel modellere dayanmaktadır (Yang, Y. vd., 2022, s1).

Bu bölümde medikal görüntü segmentasyon işlemi için kullanılan geleneksel yaklaşımlar ele alınacaktır. Bu yaklaşımlara ait örnek Matlab kod uygulamaları verilecek ve her örnek ayrıntılarıyla açıklanacaktır. Bu alanda çalışan araştırmacılar için hem teorik hem de uygulama olarak geniş bir bakış sunmak hedeflenmektedir.

2. Medikal Görüntü Segmentasyonu için Kullanılan Geleneksel Yöntemler

On yıllardır, eşikleme, aktif kontur, bölge tabanlı yaklaşımlar, kümeleme yöntemleri gibi geleneksel segmentasyon teknikleri yaygın olarak kullanılmaktadır. Bu yöntemler, sabit kurallara ve yoğunluk temelli işlemlere dayandıkları için, hem verimli hem de yorumlanması kolaydır (Huang, L.vd.2023, s738).

2.1 Eşikleme

Dijital görüntü işlemede, eşikleme görüntüleri segmentlere ayırmının en basit yollarından biridir. Bu yöntem, görüntüyü belirlenen bir eşik değerine göre, pikselleri eşik değerinin altında veya eşik değerine eşit ve üzerinde olacak şekilde iki gruba ayırır. Eşiklemeye dayalı birçok teknik geliştirilmiştir; bunlar arasında gri seviye histogramlarına dayalı küresel yöntemler, lokal özelliklere odaklanan küresel yaklaşımlar ve adaptif eşikleme teknikleri bulunmaktadır.(Jardim,S. vd., 2023, s1487). Global eşikleme, görüntü histogramının iki belirgin tepeye sahip olduğunu kabul eder; bu tepeler nesneleri ve arka planı temsil eder (Sonka, M. Vd., 1999). Histogramdaki iki mod arasındaki minimum değerde belirlenen eşik T, piksel değerleriyle karşılaştırılarak, eşik üzerindeki pikseller nesne, altındaki pikseller arka plan olarak sınıflandırılır. Otsu yöntemi, sınıflar arası varyansı maksimize ederek otomatik eşik belirler (Otsu, N., 1979) ancak gürültülü, küçük nesneler veya düzensiz aydınlatma koşullarında istenen performansı göstermeyebilir.

Kapur ve arkadaşlarının önerdiği entropi-tabanlı global eşikleme algoritmalarında, arka plan ve nesne entropilerinin toplamı maksimuma ulaştığında eşik değeri belirlenir (Kapur, J.N., 1985). Bu yöntem, kontrastlı arka plan üzerinde homojen nesneleri hızlı ve basit şekilde ayırırken, düşük kontrast, gürültü veya arka plan yoğunluğunun önemli ölçüde değiştiği durumlarda başarısız olabilir. Buna karşın, adaptif (yerel) eşikleme yöntemi, görüntüyü alt bölgelere ayırarak veya her pikselin çevresindeki yoğunluk değerlerini analiz ederek bölgeye özel eşik değerleri belirler. Bu yöntem, değişken arka plan koşullarında ve küçük, seyrek bölgelerin çıkarımında daha etkili olsa da, hesaplama maliyeti daha yüksektir (Jardim,S. vd., 2023, s1487).

Aşağıda eşikleme yöntemine ilişkin örnek Matlab kod uygulamaları yer almaktadır.

```
% ISIC_görüntü veri tabanından gerçek medikal görüntüyü yükleme
img = imread('image.jpg');
```

```

if size(img,3) == 3
    grayImg = rgb2gray(img); % Renkli görüntüyü grayscale'e
    dönüştürme
else
    grayImg = img;
end

% Otsu yöntemi ile eşik değeri belirleme
level = graythresh(grayImg);
binaryImg = imbinarize(grayImg, level);

% Sonuçların görselleştirilmesi
figure;
subplot(1,2,1), imshow(grayImg), title('Orijinal Grayscale Görüntü');
subplot(1,2,2), imshow(~binaryImg), title('Otsu Eşikleme Sonucu');

```

Görüntünün Yüklenmesi ve Ön İşleme:

Kodun ilk bölümünde, medikal görüntü dosyası ('image.jpg') MATLAB'ın imread fonksiyonu ile yüklenmektedir. Yüklenen görüntü renkli ise, görüntünün üç renk kanalının (RGB) varlığı kontrol edilerek rgb2gray fonksiyonu kullanılır; böylece görüntü, analiz için uygun olan tek kanallı (grayscale) forma dönüştürülür. Renkli değilse, görüntü doğrudan gri tonlamalı olarak kabul edilir.

Otsu Yöntemi ile Eşik Değerinin Belirlenmesi:


Gri tonlamalı görüntü üzerinde, Otsu algoritması graythresh fonksiyonu aracılığıyla uygulanır. Bu fonksiyon, görüntü histogramındaki iki sınıf arasındaki varyansı maksimize eden optimal eşik değerini belirler. Elde edilen eşik değeri, görüntüdeki piksel yoğunluk dağılımına bağlı olarak otomatik şekilde saptanır.

İkili Görüntü Oluşturulması:

Belirlenen eşik değeri kullanılarak imbinarize fonksiyonu ile gri tonlamalı görüntü ikili (binary) forma dönüştürülür. Bu işlemde, eşik değerinin üstündeki piksel değerleri nesne, altında kalanlar ise arka plan olarak sınıflandırılır. Kodda elde edilen ikili görüntü, tersine çevrilmiş (~binar-yImg) şekilde görselleştirilerek sunulmuştur; bu durum, sonuçların daha anlaşılır olması amacıyla tercih edilebilir.

Sonuçların Görselleştirilmesi:

Son adımda, oluşturulan gri tonlamalı görüntü ile eşikleme sonucunun (ters çevrilmiş ikili görüntü) karşılaştırmalı olarak incelenebilmesi için, iki alt grafiğe bölünmüş bir figür penceresinde görselleştirme yapılır. Görsel sonuç Şekil 1 ile verilmiştir.



Şekil 1. Otsu Yöntemi ile Segmentasyon

% Kapur'un Entropi Tabanlı Global Eşikleme Örneği

% 1. Görüntüyü Yükleme ve Grayscale'e Dönüştürme

I = imread('image.jpg'); % Gerçek medikal görüntüyü yüklüyoruz

I = rgb2gray(I); % Renkli ise grayscale formata çeviriyoruz

I_gray = im2uint8(im2double(I)); % Görüntüyü 0-255 aralığında uint8 tipine dönüştürüyoruz

% 2. Histogram Hesaplama ve Normalizasyon

counts = imhist(I_gray); % Görüntünün histogramını hesaplıyoruz

```
p = counts / sum(counts);    % Histogramı normalize ederek olasılık
dağılımını elde ediyoruz
```

```
L = 256;                    % Toplam ton sayısı (0-255)
```

```
% 3. Kapur'un Entropi Tabanlı Eşikleme İşlemi
```

```
maxEntropy = -inf;          % Maksimum toplam entropiyi negatif
sonsuz olarak başlatıyoruz
```

```
optimalT = 0;               % Optimal eşik değeri için başlangıç değeri
```

```
for t = 1:L-1
```

```
    % Arka plan ve nesne olasılıklarını hesaplama
```

```
    p0 = sum(p(1:t));
```

```
    p1 = sum(p(t+1:end));
```

```
    % Arka plan entropisi hesaplama
```

```
    if p0 > 0
```

```
        H0 = -sum((p(1:t)/p0) .* log(p(1:t)/p0 + eps));
```

```
    else
```

```
        H0 = 0;
```

```
    end
```

```
    % Nesne entropisi hesaplama
```

```
    if p1 > 0
```

```
        H1 = -sum((p(t+1:end)/p1) .* log(p(t+1:end)/p1 + eps));
```

```
    else
```

```
        H1 = 0;
```

```
    end
```

```
% Toplam entropiyi hesapla
```

```
totalEntropy = H0 + H1;
```

```

% Eğer toplam entropi maksimumsa, optimal eşik değerini güncelle
if totalEntropy > maxEntropy
    maxEntropy = totalEntropy;
    optimalT = t;
end
end

```

```

% 4. Elde Edilen Optimal Eşik Değeri ile İkili Görüntü Oluşturma
binaryImage = I_gray > optimalT;

```

```

% 5. Sonuçların Tek Figür Penceresinde Yan Yana Görselleştirilmesi
figure;
subplot(1,2,1);
imshow(I_gray);
title('Orijinal Grayscale Görüntü');

subplot(1,2,2);
imshow(~binaryImage);

title(['Kapur Yöntemi ile Global Eşikleme Sonucu, T = '
num2str(optimalT)]);

```

Görüntü Yükleme ve Ön İşleme:

imread fonksiyonu ile 'image.jpg' dosyası yüklenir. rgb2gray kullanılarak renkli görüntü grayscale'e dönüştürülür ve im2uint8(im2double(I)) ile 0-255 aralığında, uygun tipte (uint8) bir görüntü elde edilir.

Histogram ve Olasılık Dağılımı:

imhist fonksiyonu kullanılarak görüntünün histogramı hesaplanır. Histogram, toplam piksel sayısına bölünerek normalize edilir ve her bir ton değeri için olasılık dağılımı elde edilir.

Kapur'un Entropi Tabanlı Eşikleme:

1'den 255'e kadar her olası eşik değeri için, eşik değerinin altındaki ve üstündeki piksel sınıflarının entropileri hesaplanır. eps ile sıfıra bölünme hataları önlenir. İki sınıfın toplam entropisi maksimum olan eşik değeri $optimalT$ olarak seçilir.


İkili Görüntü Oluşturma:

Hesaplanan optimal eşik değeri kullanılarak, $I_{gray} > optimalT$ işlemiyle ikili (binary) görüntü elde edilir. Bu işlemde, eşik değerinin üzerindeki pikseller nesne, altındaki pikseller arka plan olarak belirlenir.

Görüntülerin Görselleştirilmesi:

Tek bir figür penceresinde subplot komutu ile iki ayrı alt grafik oluşturulur. Sol grafikte orijinal grayscale görüntü, sağ grafikte ise Kapur yöntemine göre eşiklenmiş (segmentlenmiş) görüntü ve optimal eşik değeri gösterilir. Grafik Şekil 2 ile verilmiştir.

Orijinal Grayscale Görüntü Kapur Yöntemi ile Global Eşikleme Sonucu,



Şekil 2. Kapur yöntemi ile Segmentasyon

2.2 Kümeleme

K-means kümeleme algoritması, kümeleme algoritmaları içinde yaygın olarak kullanılan bir veri kümesini belirli sayıda kümeye ayırmaya yönelik popüler bir denetimsiz öğrenme yöntemidir. Algoritma, iki aşamalı bir süreçle çalışır: İlk aşamada, kullanıcı tarafından belirlenen k sayısına göre başlangıç küme merkezleri seçilir. İkinci aşamada ise, her bir veri noktası, kendisine en yakın olan küme merkezine atanır; bu atama genellikle Öklid mesafesi kullanılarak yapılır. Her atamadan sonra, kümelerin yeni merkezleri, o kümeye ait veri noktalarının ortalaması alınarak güncellenir. Bu iteratif süreç, küme merkezleri sabitlenene veya belirli bir durma

kriteri sağlanana kadar tekrarlanır. Sonuç olarak, her küme, içerisindeki veri noktaları ile merkezinin arasındaki toplam mesafeyi minimize eden bir yapı sunar (Dhanachandra, N. vd. 2015, s766). Aşağıda açıklamaları ile birlikte belirtilen yönteme ait Matlab kod uygulaması verilmiştir.

```
% ISIC görüntüsünü yükleme ve grayscale'e dönüştürme
img = imread('image.jpg');
if size(img,3) == 3
    grayImg = rgb2gray(img);
else
    grayImg = img;
end

% Görüntüyü vektör haline getirme
imgVector = double(grayImg(:));

% K-means algoritması (k = 2: örneğin, arka plan ve lezyon)
k = 2;
[idx, centers] = kmeans(imgVector, k, 'Replicates', 5);

% Küme etiketlerini orijinal boyuta yeniden düzenleme
segmentedImg = reshape(idx, size(grayImg));

% Sonuçların görselleştirilmesi
figure;
subplot(1,2,1), imshow(grayImg), title('Grayscale Görüntü');
subplot(1,2,2), imshow(segmentedImg, []), title('K-means Segmen-
tasyonu');
```

Görüntü Yükleme ve Ön İşleme:

imread fonksiyonu kullanılarak 'image.jpg' dosyası okunur ve img değişkenine atanır.

Bu adımda, görüntü RGB (renkli) veya grayscale (gri tonlamalı) olabilir.

`size(img,3) == 3` koşulu ile görüntünün renkli (RGB) olup olmadığı kontrol edilir.

Eğer renkli ise, `rgb2gray` fonksiyonu ile grayscale formata dönüştürülür.

Eğer görüntü zaten grayscale ise, doğrudan `grayImg` değişkenine atanır.

Görüntüyü Vektör Haline Getirme:

`grayImg(:)` ifadesi, iki boyutlu görüntüyü tek boyutlu bir vektöre dönüştürür.

`double()` fonksiyonu ile piksel değerleri ondalık (double) formata çevrilir, çünkü K-means algoritması genellikle bu formatta çalışır.

Böylece her piksel değeri tek bir sütun vektörü haline gelir.

K-means Algoritmasının Uygulanması:

`k = 2`; ifadesi ile görüntünün iki kümeye ayrılacağı belirtilir. (örneğin, arka plan ve lezyon).

`kmeans(imgVector, k, 'Replicates', 5)` fonksiyonu ile K-means kümeleme algoritması uygulanır:

`idx`: Her pikselin hangi kümeye ait olduğunu gösteren vektör (etiketler).

`centers`: Her kümenin merkez yoğunluk değerleri.

'Replicates', 5 parametresi, farklı başlangıç noktaları ile 5 kez çalıştırılarak en iyi sonucu seçmesini sağlar.

Küme Etiketlerini Orijinal Boyuta Döndürme:

`idx` vektörü, her pikselin hangi kümeye ait olduğunu içeren bir sütun vektörüdür.

`reshape(idx, size(grayImg))` fonksiyonu ile bu vektör tekrar 2D matris formatına getirilir, böylece segmentasyon sonucu orijinal görüntü boyutuna geri döner.

Görüntülerin Görselleştirilmesi:

figure; ile yeni bir figür penceresi oluşturulur.

subplot(1,2,1) ile ilk alt grafik bölmesi oluşturulur ve imshow(grayImg) ile orijinal grayscale görüntü gösterilir.


title('Grayscale Görüntü') ile uygun başlık eklenir.

subplot(1,2,2) ile ikinci alt grafik bölmesi oluşturulur.

imshow(segmentedImg, []) ile segmentasyon sonucu gösterilir.[] kullanımı, otomatik ölçeklendirme yaparak kümeler arasındaki farkın net görünmesini sağlar.

title('K-means Segmentasyonu') ile uygun başlık eklenir.

Şekil 3 ile K-mean algoritmasına ait çıktı görüntüsü verilmiştir.



Şekil 3. K-mean yöntemi ile segmentasyon

2.3 Bölge Tabanlı Yaklaşım

Görüntü işleme ve bilgisayar görüşü disiplinlerinde, alan tabanlı segmentasyon yaygın olarak tercih edilen yöntemlerden biridir. Bu yaklaşım, görsellerin benzer özellikler gösteren alt bölgelere ayrılması yoluyla, görsel verinin daha derinlemesine analizini mümkün kılar (Mary,S.vd.,2012). Temelinde, segmentasyon süreci iki ana ilke etrafında şekillenmektedir: piksel benzerliği ve mekansal yakınlık. Bu yöntem, belirli bir bölgedeki piksellerin renk, parlaklık veya doku gibi ortak özellikler sergilemesi varsayımına dayanarak, segment içindeki homojenliği sağlamayı hedefler. Ayrıca, piksel benzerliğinin yanı sıra, mekansal yakınlık da kritik bir rol oynamaktadır; zira komşu veya yakın konumda bulunan piksellerin aynı segmentte yer alma olasılığı yüksektir, bu da segmentasyonun tutarlılığını artırır (Kaganami, H.G ve Beiji, Z.,2009). Aşağıda bu yöntemle ilişkin yazılmış bir matlab fonksiyonu ve örnek uygulama kodu verilmiştir.

```

function region = optimizedRegionGrowing(img, seed)

% optimizedRegionGrowing - Geliştirilmiş bölge büyümesi algoritması

% Bu algoritma, bölge istatistikleri (ortalama, standart sapma) ve yerel

% gradient bilgisine dayalı dinamik eşikleme ile daha adaptif bir segmentasyon

% gerçekleştirir. Ayrıca, görüntünün kontrastı kullanılarak dinamik

% eşik değeri otomatik olarak hesaplanır.

%

% Syntax: region = optimizedRegionGrowing(img, seed)

%

% Inputs:

%  img      - Grayscale görüntü (double tipinde, [0,1] aralığında)

%  seed     - [row, col] formatında başlangıç (tohum) noktası

%

% Outputs:

%  region - Bölge büyümesi sonucu oluşan binary maske


[rows, cols] = size(img);
region = false(rows, cols);
visited = false(rows, cols);


% Otomatik eşik değeri hesaplama: Görüntü kontrastını (standart sapma) kullanarak
dynamicThreshold = 0.5 * std2(img);


% Gradient hesaplama: Kenar tespitinde kullanılır
[Gmag, ~] = imgradient(img);
gradientThreshold = mean(Gmag(:)) + 0.5 * std(Gmag(:));

```

% Başlangıç: Tohum noktasını kuyruğa ekle ve işaretle

queue = seed;

region(seed(1), seed(2)) = true;

visited(seed(1), seed(2)) = true;

% Bölge istatistiklerinin başlatılması (ortalama ve varyans için)

regionSum = double(img(seed(1), seed(2)));

regionSumSq = double(img(seed(1), seed(2)))^2;

regionCount = 1;

regionMean = regionSum / regionCount;

regionVar = 0;

regionStd = 0;

% 8-komşuluk ofsetleri: Yatay, dikey ve çapraz komşular

neighbors = [-1, -1; -1, 0; -1, 1;

0, -1; 0, 1;

1, -1; 1, 0; 1, 1];

% Bölge büyümesi: Kuyruk boşalana kadar işlemi sürdür

while ~isempty(queue)

current = queue(1, :);

queue(1, :) = [];

for k = 1:size(neighbors, 1)

newRow = current(1) + neighbors(k, 1);

newCol = current(2) + neighbors(k, 2);

if newRow >= 1 && newRow <= rows && newCol >= 1 &&
newCol <= cols && ~visited(newRow, newCol)

visited(newRow, newCol) = true;

```

        pixelValue = double(img(newRow, newCol));

        % Dinamik eşik: Bölgenin mevcut standart sapmasıyla öl-
        çeklenen yoğunluk farkı
        intensityCondition = abs(pixelValue - regionMean) <= dy-
        namicThreshold * (1 + regionStd);

        % Gradient kontrolü: Kenar bölgelerden kaçınmak için
        gradientCondition = Gmag(newRow, newCol) < gradient-
        Threshold;

        if intensityCondition && gradientCondition
            region(newRow, newCol) = true;
            queue = [queue; newRow, newCol];

            % Bölge istatistiklerini güncelle
            regionSum = regionSum + pixelValue;
            regionSumSq = regionSumSq + pixelValue^2;
            regionCount = regionCount + 1;
            regionMean = regionSum / regionCount;
            regionVar = regionSumSq/regionCount - regionMean^2;
            regionStd = sqrt(max(regionVar, 0));
        end
    end
end
end

% Sonuç üzerinde morfolojik işlemler: Delik doldurma ve küçük
nesneleri temizleme
region = imfill(region, 'holes');
region = bwareaopen(region, 50);
end

```

Fonksiyon tanımı:

`function region = optimizedRegionGrowing(img, seed)` ifadesi, `img` ve `seed` parametrelerini alan bir fonksiyon olduğunu ve çıktı olarak `region` (binary maske) döndüreceğini belirtir.

Açıklayıcı yorum satırları:

`% optimizedRegionGrowing - ...` satırları fonksiyonun amacını, kullanım şeklini ve girdi-çıkı parametrelerini tanımlar.

Görüntü boyutlarını öğrenme:

`size(img)` ile görüntünün satır ve sütun sayısı elde edilir (`rows`, `cols`).

region değişkeni oluşturma:

`region = false(rows, cols)`; tüm pikselleri başlangıçta `false` (bölge dışında) kabul eden bir mantıksal (logical) matris oluşturur.

visited matrisi oluşturma:

`visited = false(rows, cols)`; ise, algoritmanın hangi pikselleri ziyaret ettiğini kaydeden bir matristir.

Dinamik eşik değeri (dynamicThreshold):

`std2(img)` fonksiyonu, tüm görüntünün standart sapmasını döndürür. Bunu 0.5 ile çarparak bir başlangıç “kontrast” eşiği belirleriz. Görüntü kontrastı yüksekse eşik de artar, düşükse azalır.

Görüntü gradientini hesaplama:

`imggradient(img)` fonksiyonu, her pikselin kenar şiddetini (magnitude) `Gmag` olarak döndürür.

gradientThreshold:

`mean(Gmag(:))` ile ortalama gradient değeri bulunur ve buna `0.5 * std(Gmag(:))` eklenerek dinamik bir kenar eşiği belirlenir. Amaç, “çok yüksek” gradient bölgelerini (keskin kenarları) bölge büyütmeden hariç tutmaktır.

Kuyruk yapısı:

queue = seed; ifadesi, BFS/DFS mantığıyla ilerlemek için başlangıç pikselini (tohum) kuyruğa ekler.

region(seed(1), seed(2)) = true; tohum pikseli bölgeye dahil edilir.

visited(seed(1), seed(2)) = true; tohum pikseli ziyaret edildi olarak işaretleir.

Bölge istatistikleri:

regionSum ve regionSumSq, bölge içindeki piksellerin toplamını ve karelerinin toplamını tutar.

regionCount bölgeye dahil olan piksel sayısıdır.

regionMean bölgenin güncel ortalama yoğunluk değerini ifade eder.

regionVar ve regionStd (varyans ve standart sapma) başta 0 olarak başlatılır.

Komşuluk tanımı:

neighbors matrisi, bir pikselin 8 komşusuna gitmek için satır-sütun ofsetlerini içerir.

Bölge büyütme döngüsü:

while ~isempty(queue) kuyruktaki işlenecek piksel kaldığı sürece döngünün devam etmesini sağlar.

current = queue(1, :) kuyruktaki ilk pikseli alır.

queue(1, :) = []; alınan pikseli kuyruktan çıkarır.

İçteki for döngüsü, 8 komşuyu dolaşarak newRow ve newCol değerlerini hesaplar.

Komşu piksel sınır kontrolü:

if newRow >= 1 && newRow <= rows && newCol >= 1 && newCol <= cols ifadesiyle komşu pikselin görüntü içinde kalıp kalmadığı denetlenir.

~visited(newRow, newCol) ile de pikselin daha önce işlenmediğinden emin olunur.

visited(newRow, newCol) = true; komşu pikseli artık “ziyaret edildi” olarak işaretler.

intensityCondition:

$\text{abs}(\text{pixelValue} - \text{regionMean}) \leq \text{dynamicThreshold} * (1 + \text{regionStd})$ ifadesi, pikselin yoğunluk değerinin bölgenin ortalamasına yakın olup olmadığını dinamik bir şekilde kontrol eder.

Burada regionStd değeri arttıkça, pikseli kabul etme esnekliği de artar.

gradientCondition:

$\text{Gmag}(\text{newRow}, \text{newCol}) < \text{gradientThreshold}$, pikselin kenar bölgesinde olmadığını kontrol eder. Kenar şiddeti büyükse piksel bölgeye alınmaz.

Bölgeye ekleme:

Eğer her iki koşul da sağlanırsa (intensityCondition && gradientCondition), piksel region matrisinde true yapılır ve queue kuyruğuna eklenir. Ardından bölge istatistikleri (regionSum, regionSumSq, regionCount, regionMean, regionVar, regionStd) güncellenerek, gelecek piksellerin değerlendirilmesi dinamik biçimde devam eder.

Morfolojik iyileştirmeler:

imfill(region, 'holes') ile bölge içindeki küçük boşluklar (delikler) doldurulur.

bwareaopen(region, 50) ile 50 piksellik alandan daha küçük nesneler atılır (gürültü temizliği).

Fonksiyon sonu:

Fonksiyon, region binary maskesini döndürerek sonlanır.

% Örnek Kullanım

clear;

close all;

clc;

% Görüntüyü oku

```

imgRGB = imread('image.jpg');
% Eğer görüntü renkliyse, grayscale'e dönüştür
if size(imgRGB, 3) == 3
    imgGray = rgb2gray(imgRGB);
else
    imgGray = imgRGB;
end

```

```

% Görüntüyü double formatına çevir (0-1 aralığı)
imgGray = im2double(imgGray);
% Tohum noktası: Görüntünün merkezinden
[rows, cols] = size(imgGray);
seed = [round(rows/2), round(cols/2)];

```

% Güncellenmiş optimum bölge büyümesi algoritmasını çalıştır (eşik değeri otomatik hesaplanıyor)

```

regionMask = optimizedRegionGrowing(imgGray, seed);
% Sonuçları görselleştir
figure;
subplot(1,2,1);
imshow(imgGray);
title('Orijinal Grayscale Görüntü');

```

```

subplot(1,2,2);
imshow(regionMask);
title('Optimum Bölge Büyümesi Sonucu');

```

Ortamın Temizlenmesi:

clear;: Çalışma alanındaki mevcut değişkenler temizlenir.

close all;: Açık olan tüm grafik pencereleri kapatılır.

clc;: Komut penceresi temizlenir.

Görüntünün Okunması:

`imgRGB = imread('image.jpg');`: 'image.jpg' dosyasındaki görüntü okunur ve `imgRGB` değişkenine atanır.

Renkli Görüntünün Gri Tonlamaya Dönüştürülmesi:

`if size(imgRGB, 3) == 3 ...`: Eğer görüntü RGB (renkli) ise, `rgb2gray` fonksiyonu kullanılarak gri tonlamaya dönüştürülür; değilse, görüntü aynen kullanılır.

Veri Tipi Dönüştürme:

`imgGray = im2double(imgGray);`: Görüntüdeki piksel değerleri 0–1 aralığına normalize edilir. Bu, hesaplamaların daha sağlıklı yapılmasını sağlar.

Tohum Noktasının Belirlenmesi:

`[rows, cols] = size(imgGray);`: Görüntünün boyutları (satır ve sütun sayısı) alınır.

`seed = [round(rows/2), round(cols/2)];`: Görüntünün tam ortasındaki piksel, tohum noktası olarak seçilir.

Optimum Bölge Büyümesi Fonksiyonunun Çalıştırılması:


`regionMask = optimizedRegionGrowing(imgGray, seed);`: Geliştirilmiş bölge büyümesi algoritması, otomatik dinamik eşik değeri kullanılarak çalıştırılır ve sonuç binary maske olarak `regionMask` değişkenine atanır.

Sonuçların Görselleştirilmesi:

`subplot(1,2,1) & imshow(imgGray);`: İlk panelde orijinal gri tonlamalı görüntü görüntülenir.

`subplot(1,2,2) & imshow(regionMask);`: İkinci panelde, algoritma sonucunda elde edilen bölge maskesi görüntülenir.

`title(...)`: Her iki panel için uygun başlıklar eklenerek hangi görüntünün neyi temsil ettiği belirtilir. Bu yaklaşımdan elde edilen görsel sonuç Şekil 4 ile verilmiştir.



Şekil 4. Bölge Tabanlı Yaklaşım ile Segmentasyon

2.4 Aktif Kontur

Aktif Kontur Modeli (ACM), geleneksel segmentasyon yöntemleri arasında en bilinen yaklaşımlardan biridir, ancak yüksek hesaplama maliyeti nedeniyle pratikte sınırlamalar taşır. Bu sorunu aşmak için geliştirilen level set yöntemleri, genel olarak kenar tabanlı ve bölge tabanlı olarak ikiye ayrılır. Kenar tabanlı modeller, görüntünün genel yapısını dikkate alırken, inhomojen görüntülerde hedef nesnenin sınırlarını belirlemede zorlanabilir. Bölge tabanlı modeller ise yerel bilgiyi kullanarak daha hassas segmentasyon sağlar, ancak başlangıç konturunun konumuna duyarlı olabilir. Son yıllarda geliştirilen Level Set Evolution (LSE) modeli, segmentasyon işlemiyle birlikte bias field kestirimi yapabilmesiyle öne çıkmaktadır (Yang, Y. vd.,2022, s1). Aşağıda bu yöntemle ait örnek bir uygulama geliştirilmiştir. Uygulama çıkışına ait görsel sonuç Şekil 5 ile verilmiştir.

% Görüntüyü yükleme ve grayscale'e dönüştürme

```
img = imread('image.jpg');
```

```
if size(img,3) == 3
```

```
    grayImg = rgb2gray(img);
```

```
else
```

```
    grayImg = img;
```

```
end
```

% Görüntü boyutlarını al

```
[rows, cols] = size(grayImg);
```

% Görüntünün merkezine yakın, orantısal olarak %50'lik bir dikdörtgen maske oluşturma

```
row_start = round(rows * 0.25);
row_end = round(rows * 0.75);
col_start = round(cols * 0.25);
col_end = round(cols * 0.75);
```

```
mask = false(rows, cols);
mask(row_start:row_end, col_start:col_end) = true;
```

% Active contour (Chan-Vese yöntemi) ile segmentasyon

```
bw = activecontour(grayImg, mask, 300, 'Chan-Vese');
```

% Sonuçların görselleştirilmesi

```
figure;
subplot(1,2,1), imshow(grayImg), title('Orijinal Grayscale Görüntü');
subplot(1,2,2), imshow(bw), title('Active Contour Segmentasyonu');
```

Görüntünün Yüklenmesi ve Grayscale'e Dönüştürülmesi:

imread('image.jpg') komutu ile giriş görüntüsü okunur.

Görüntü RGB formatında ise, grayscale (gri tonlu) formata dönüştürülür.

Eğer görüntü zaten grayscale ise herhangi bir dönüşüm uygulanmaz.

Görüntü Boyutlarının Belirlenmesi:

size(grayImg) fonksiyonu ile görüntünün satır (rows) ve sütun (cols) bilgileri alınır.

Amaç: Görüntü boyutlarına bağlı olarak segmentasyon maskesi oluşturmak.

Başlangıç Maskesinin Tanımlanması:

Başlangıç maskesi, segmentasyon işleminin başlangıç noktasıdır.

Maskenin %50'lik merkezi bir alanı kapsaması için başlangıç ve bitiş satır/sütun indeksleri belirlenir.

Mantıksal (binary) bir matris oluşturularak, seçilen alan true (beyaz), diğer alanlar false (siyah) olarak ayarlanır.

Amaç: Active Contour algoritmasının başlangıç konturunu belirlemek.

Active Contour (Chan-Vese) ile Segmentasyon:

Active Contour Modeli (ACM), deformasyon tabanlı bir segmentasyon yöntemidir.

activecontour fonksiyonu, MATLAB'de Chan-Vese modelini uygular.

Parametreler:

grayImg: Segmentasyon yapılacak gri tonlu görüntü.

mask: Başlangıç segmentasyon maskesi.

300: Iterasyon sayısı, segmentasyonun doğruluğunu artırmak için belirlenen adım sayısı.

'Chan-Vese': Kullanılan model türü (bölge tabanlı segmentasyon yöntemi).

Chan-Vese Yöntemi, kenar tabanlı segmentasyon yöntemlerinden farklı olarak, nesnenin iç ve dış bölgelerini karşılaştırarak segmentasyon gerçekleştirir.

Amaç: Nesne sınırlarını belirlemek ve arka plandan ayırmak.


Sonuçların Görselleştirilmesi:

figure komutu ile yeni bir görsel pencere açılır.

subplot(1,2,1): İlk panelde orijinal grayscale görüntü gösterilir.

subplot(1,2,2): İkinci panelde, segmentasyon sonucu görüntülenir.

Amaç: Orijinal görüntü ile segmentasyon sonucunu görsel olarak karşılaştırmak.



Şekil 5. Aktif Kontur Yöntemi ile Segmentasyon

Sonuç

Bu bölümde, medikal görüntü segmentasyonu alanında kullanılan geleneksel yöntemler detaylı bir şekilde ele alınmıştır. Eşikleme, kümeleme, bölge tabanlı yaklaşımlar ve aktif kontur modelleri gibi çeşitli teknikler, medikal görüntülerin daha doğru ve etkili bir şekilde analiz edilmesine olanak tanımaktadır. Her bir yöntemin avantajları ve dezavantajları, uygulama alanları ve örnek Matlab kodları ile desteklenerek açıklanmıştır.

Medikal görüntü segmentasyonu, tıbbi teşhis ve tedavi süreçlerinde kritik bir rol oynamaktadır. Doğru segmentasyon, doktorların hastalıkları daha iyi anlamasına, tedavi süreçlerini daha etkili yönetmesine ve hastalara daha hızlı ve doğru müdahalelerde bulunmasına olanak tanır. Geleneksel yöntemler, belirli sınırlamalara sahip olsa da, günümüzde hala yaygın olarak kullanılmakta ve yeni teknolojilerle birlikte geliştirilmektedir.

Bu bölümde sunulan bilgiler ve kod örnekleri, araştırmacılar ve uygulayıcılar için hem teorik hem de pratik bir rehber niteliğindedir. Gelecekte, medikal görüntü segmentasyonu alanında yapılacak çalışmaların, daha gelişmiş ve hassas yöntemlerin geliştirilmesine katkı sağlayacağına inanılmaktadır. Bu yenilikler, tıbbi görüntüleme teknolojilerinin evriminde önemli bir adım olacaktır.

Referanslar

- Dhanachandra,N., Manglem, K., Chanu, Y.J. (2015). Image Segmentation using K -means Clustering Algorithm and Subtractive Clustering Algorithm. *Procedia Computer Science* 54 (2015) 764 – 771. DOI: 10.1016/j.procs.2015.06.090.
- Huang, L., Ruan, S., Denoeux, T. (2023). Application of belief functions to medical image segmentation: A review. *Information Fusion* 91 (2023) 737–756. DOI: <https://doi.org/10.1016/j.inffus.2022.11.008>.
- Jardim, S.,Antonio, J.,Mora, C. (2023). Image Tresholding Approaches for Medical Image Segmentation-short Literature Review. CENTERIS. *International Conference on Project MANagement / HCist – International Conference on Health and Social Care Information Systems and Technologies* 2022. DOI: 10.1016/j.procs.2023.01.439.
- Kapur, J. N., P. K. Sahoo, and A. K. C.Wong. (1985) “A new method for gray-level picture thresholding using the entropy of the histogram.” *Computer Vision, Graphics, and Image Processing* 29: 273-285. DOI: [https://doi.org/10.1016/0734-189X\(85\)90125-2](https://doi.org/10.1016/0734-189X(85)90125-2).
- Kaganami, H.G., Beiji, Z. (2009). Region-Based Segmentation versus Edge Detection. In *Proceedings of the 2009 Fifth International Conference on Intelligent Information Hiding and Multimedia Signal Processing*, Kyoto, Japan, 12–14 September 2009; pp. 1217–1221.
- Mary, S. J., Padma. S., John, B.M.(2012). Image Segmentation Using Seeded Region Growing. In *Proceedings of the 2012 International Conference on Computing, Electronics and Electrical Technologies (ICCEET)*, Nagercoil, India, 21–22 March 2012; pp. 576–583.
- Otsu, N. (1979) “A threshold selection method from gray level histograms.” *IEEE Transaction on Systems, Man, and Cybernetics* 9 (1): 62-66.
- Shao, J.,Chen, S., Zhou, J., Zhu, H., Wang, Z., Brown, M. (2023). Application of U-Net and Optimized Clustering inMedical Image Segmentation: A Review. *Computer Modeling in Engineering & Sciences*. 16 :(3). DOI: 10.32604/cmcs.2023.025499.
- Sonka, M. V. Hlavac, and R. Boyle. (1999) Image Processing, Analysis, and Machine Vision. CA: PWS Publishing, Pacific Grove.
- Xu,Y.,Quan,R.,Xu,W.,Huang,Y.,Chen, X.,Liu,F. (2024). Advances in Medical Image Segmentation: A Comprehensive Review of Traditional, Deep Learning and Hybrid Approaches *bioengineering*. DOI: <https://doi.org/10.3390/bioengineering11101034>.
- Yang, Y., Hou, X., Ren, H. (2022). Efficient active contour model for medical image segmentation and correction based on edge and region information. *Expert Systems With Applications*. 194:116436. DOI: <https://doi.org/10.1016/j.eswa.2021.116436>.

Yang, Y., Hou, X., Ren, H. (2022). Efficient active contour model for medical image segmentation and correction based on edge and region information. *Expert Systems with Applications*. Volume 194, 15 May 2022, 116436. DOI: <https://doi.org/10.1016/j.eswa.2021.116436>.

BÖLÜM 3

İŞLETME YÖNETİCİLERİNİN YAPAY ZEKÂYA YÖNELİK ALGISI ÜZERİNE BİR İNCELEME

Burak DEMİR¹

Bengü KAYIARSLAN²

1 *Öğretim Görevlisi, Akdeniz Karpaz Üniversitesi, İşletme Fakültesi, İşletme Bölümü, KKTC, burak.demir@akun.edu.tr, ORCID: orcid.org/ 0000-0001-5666-359X

2 Öğretim Görevlisi, Akdeniz Karpaz Üniversitesi, İşletme Fakültesi, İşletme Bölümü, KKTC, bengu.kayiarслан@akun.edu.tr, ORCID: orcid.org/ 0000-0003-4112-4977

Giriş

Yapay zekâ (YZ), işletmelerin dijital dönüşüm sürecinde en önemli faktörlerden biri haline gelmiştir. Büyük veri analitiği, otomasyon, makine öğrenimi ve doğal dil işleme gibi YZ uygulamaları, işletmelere yeni stratejik avantajlar kazandırmaktadır (Brynjolfsson ve McAfee, 2017). Ancak, YZ'nin işletmelerde etkin kullanımı, yöneticilerin bu teknolojiyi nasıl algıladığı ve değerlendirdiği ile doğrudan ilişkilidir. Yöneticilerin YZ'ye yönelik algıları, teknolojinin iş süreçlerine entegrasyonunu hızlandırabilir ya da yavaşlatabilir (Gartner, 2021). Yöneticilerin YZ'yi nasıl tanımladığı, hangi alanlarda kullanabileceğini düşündüğü ve olası tehditleri nasıl gördüğü, işletme stratejilerinin şekillenmesinde kritik bir öneme sahiptir.

Yapay Zekânın İşletmelere Etkisi

YZ'nin iş dünyasına etkisi çok geniş kapsamlıdır. Bu etkiler arasında operasyonel verimlilik, müşteri deneyimi iyileştirmeleri, tedarik zinciri optimizasyonu ve stratejik karar alma süreçlerindeki yenilikler sayılabilir (Davenport ve Kirby, 2016). Yapay zekânın işletmelere sağladığı en büyük avantajlardan biri, büyük miktarda veriyi analiz ederek geleceğe yönelik daha doğru tahminlerde bulunma ve karar alma süreçlerinde yöneticilere yardımcı olma kapasitesidir (Sharda, Delen ve Turban, 2020). Ancak, bu teknolojilerin etkin bir şekilde kullanılması, yöneticilerin bu teknolojilere karşı açık bir tutum geliştirmelerine bağlıdır (Huang ve Rust, 2018).

Yapay Zekânın Stratejik Karar Alma Süreçlerine Katkısı

YZ, stratejik karar alma süreçlerine büyük katkı sağlamaktadır. Veri analizleri ve tahminsel modeller, yöneticilerin daha doğru ve zamanında kararlar almasını sağlar. Bununla birlikte, yöneticilerin YZ'ye olan güveni, bu teknolojilerin karar alma süreçlerine entegrasyonunu belirleyen önemli bir faktördür (Kaplan ve Haenlein, 2020). Yöneticiler, YZ'nin sağladığı veri analizleri sayesinde piyasa eğilimlerini ve müşteri davranışlarını daha iyi analiz edebilirler, bu da uzun vadeli stratejik kararların doğruluğunu artırır (Brynjolfsson ve McAfee, 2014).

Operasyonel Verimlilik ve Otomasyon

YZ'nin bir diğer önemli katkısı, işletmelerin operasyonel süreçlerindeki verimliliği artırmasıdır. Özellikle üretim ve hizmet sektörlerinde YZ, otomasyon yoluyla maliyetleri düşürmekte ve iş süreçlerini hızlandırmaktadır. Bu teknolojiler, manuel iş gücünü otomatik sistemlerle değiştirerek hata oranlarını azaltmakta ve süreçleri optimize etmektedir (Davenport ve Ronanki, 2018). Ancak, işletme yöneticileri bu dönüşümü sadece bir ve-

rimlilik aracı olarak değil, aynı zamanda iş gücü üzerindeki olası etkileri açısından da değerlendirmektedirler (Frey ve Osborne, 2017).

İşletme Yöneticilerinin Yapay Zekâya Yönelik Algılarını Şekillendiren Faktörler

İşletme yöneticilerinin YZ'ye yönelik algılarını etkileyen çeşitli faktörler bulunmaktadır. Bu faktörler, yöneticinin geçmiş deneyimleri, eğitim düzeyi, teknolojiye olan yakınlığı ve içinde bulundukları sektörel dinamikler gibi unsurları içermektedir. Ayrıca, işletmenin mevcut dijital dönüşüm stratejileri de yöneticilerin YZ'ye bakış açısını önemli ölçüde etkiler.

Eğitim ve Bilgi Düzeyi

Yöneticilerin YZ'ye yönelik algılarında en önemli faktörlerden biri, teknolojiye dair sahip oldukları bilgi ve deneyim düzeyidir. Yapay zekâ teknolojilerini tanıyan ve bu konuda bilgi sahibi olan yöneticiler, bu teknolojilerin sunduğu fırsatları daha iyi anlayabilir ve daha rahat uygulamaya geçirebilirler (Mikalef, Pappas ve Giannakos, 2020). Eğitim düzeyi arttıkça, yöneticilerin YZ'ye olan güveni artmakta ve bu teknolojilerin işletme süreçlerine entegrasyonunu kolaylaştırmaktadır (Gurbaxani ve Dunkle, 2019).

Teknolojiye Yönelik Genel Tutum ve Yenilikçilik

Yöneticilerin teknolojiye ve yeniliklere olan genel tutumları, YZ'yi nasıl algıladıklarını doğrudan etkilemektedir. Yenilikçi bakış açısına sahip olan ve teknolojiye yakın duran yöneticiler, YZ'yi bir fırsat olarak görme eğilimindedirler (Vial, 2019). Ancak, teknolojik değişimlerden çekinen veya bu tür değişimlerin organizasyon yapısına zarar vereceğini düşünen yöneticiler, YZ'ye karşı daha temkinli yaklaşabilirler (Bughin, Seong ve Manyika, 2018).

Risk ve Belirsizlik Algısı

YZ'nin işletmelere getirdiği yeniliklerin yanı sıra, bazı riskler ve belirsizlikler de barındırmaktadır. Özellikle iş gücünün yerini otomasyonun alacağı korkusu, bazı yöneticilerde olumsuz bir YZ algısına neden olabilir (Frey ve Osborne, 2017). Bu risk algısı, yöneticilerin YZ'yi işletmelerine entegre etmekte çekinceli davranmasına yol açabilir (Colson, 2019). Ancak, eğitim ve bilgi düzeyi arttıkça, bu belirsizliklerin ortadan kalktığı ve yöneticilerin daha gerçekçi bir bakış açısı geliştirdiği gözlemlenmektedir.

Sektörel Dinamikler

İşletmenin faaliyet gösterdiği sektör de yöneticilerin YZ'ye olan bakış açısını şekillendiren önemli faktörlerden biridir. Özellikle dijitalleşmenin hızla yayıldığı sektörlerde YZ'nin benimsenmesi daha hızlı olabilmektedir (Bughin, Seong ve Manyika, 2018). Finans, sağlık ve teknoloji gibi sektörlerde YZ'nin iş süreçlerinde kullanımı yaygınlaşmışken, daha geleneksel sektörlerde bu teknolojilere yönelik çekinceler devam etmektedir (Davenport ve Kirby, 2016).

Yapay Zekânın Benimsenmesinin Önündeki Engeller

YZ'nin işletmelerde benimsenmesini engelleyen bir dizi zorluk bulunmaktadır. Bu zorluklar arasında maliyetler, teknolojik altyapı eksiklikleri, veri güvenliği kaygıları ve işletmelerin değişime karşı dirençli yapıları sayılabilir (Ghobakhloo, 2020). Özellikle KOBİ'ler, YZ teknolojilerinin yüksek maliyetleri ve uygulama zorlukları nedeniyle bu tür teknolojilere yatırım yapmaktan çekinebilmektedirler (Marr, 2019).

Maliyet ve Yatırım Kaygıları

YZ sistemlerinin kurulumu ve bakımı, özellikle küçük ve orta ölçekli işletmeler için yüksek maliyetler doğurabilir. Yöneticiler, bu maliyetlerin getirisi konusunda emin olamayabilir ve YZ yatırımlarını erteleyebilirler (Agrawal, Gans ve Goldfarb, 2018). Ayrıca, teknolojik altyapı eksiklikleri ve bu sistemlerin entegrasyon zorlukları, YZ'nin yaygın kullanımını engelleyen diğer faktörler arasında yer almaktadır (Zhang ve Lu, 2021).

İnsan Kaynakları ve Yetenek Eksikliği

YZ'nin işletmelerde başarılı bir şekilde kullanılabilmesi için, işletmelerin nitelikli insan kaynağına sahip olması gerekmektedir. Ancak, pek çok işletme YZ konusunda uzmanlaşmış insan kaynağına sahip olmadığından, bu teknolojileri uygulamaya geçirme konusunda zorluklar yaşamaktadır (Manyika ve ark., 2017). İnsan kaynakları ve yetenek yönetiminde yaşanan bu eksiklikler, YZ'nin işletmelerde yaygın olarak kullanılmasının önündeki en büyük engellerden biridir (Davenport ve Kirby, 2016).

İşletme yöneticilerinin yapay zekâya yönelik algıları, bu teknolojilerin iş süreçlerine entegrasyonu ve benimsenmesi açısından kritik bir öneme sahiptir. Eğitim düzeyi, sektörel dinamikler, risk ve belirsizlik algısı gibi faktörler, yöneticilerin YZ'ye bakış açısını şekillendirmektedir. Bu makalede işletme yöneticilerinin YZ'ye yönelik algılarını etkileyen faktörler incelenmiş ve YZ'nin işletmelerde benimsenmesinin önündeki engeller ele

alınmıştır. Sonuç olarak, yöneticilerin YZ'ye olan bakış açılarının olumlu yönde gelişmesi, işletmelerin dijital dönüşüm sürecinde başarı elde etmesi için hayati önem taşımaktadır.

SONUÇ

Bu araştırma, Kuzey Kıbrıs Türk Cumhuriyeti'ndeki işletme çalışanlarının yapay zekâ teknolojisine yönelik algılarını, tutumlarını ve iş ortamındaki uyum seviyelerini analiz etmek için belirli veriler sunmaktadır. Anket soruları Kurtboğan ve Ak'ın (2024) "İnsanlığın pi noktası: Yapay zekâ" hakkında yaptığı çalışmadan alınmıştır. Demografik soruları cinsiyet, yaş, medeni durumu, eğitim durumu ve uyruk bilgileri oluşturmıştır.


Yapılan çalışma kapsamında, katılımcıların %63'ü yapay zekânın iş yükünü azaltacağı, iş süreçlerini kolaylaştıracağı ve zaman tasarrufu sağlayacağına inandığını göstermiştir. Bu durum, çalışanların yapay zekâyı operasyonel iyileştirme açısından önemli bir araç olarak gördüğüne işaret etmektedir. Ancak, katılımcıların %5'lik bir kısmı ise, yapay zekânın işletmeler için stratejik bir öneme sahip olduğunu ve çalışan verimliliğini olumlu yönde etkileyeceğini belirtmesi, teknolojinin uzun vadeli faydalarına yönelik algının zayıf olduğunu ortaya koymaktadır. Bu fark, işletmelerin teknoloji kullanımını benimsetme stratejilerinde eksiklikler ve ön yargılar bulunduğunu göstermektedir.

Tablo 1. Anket Sorularına Verilen Yanıtlar

	I DON'T AGREE AT ALL	DISAGREE	UNDECIDED	I AGREE	TOTALLY AGREE
My managers attach great importance to artificial intelligence.	7.89% 3	31.58% 12	36.84% 14	23.68% 9	0.00% 0
I know that artificial intelligence is of great importance for my business.	2.63% 1	10.53% 4	18.42% 7	55.26% 21	13.16% 5
I think artificial intelligence will positively affect employee productivity.	0.00% 0	10.53% 4	18.42% 7	57.89% 22	13.16% 5
I think artificial intelligence applications will shape the business life of the future.	0.00% 0	10.53% 4	10.53% 4	57.89% 22	21.05% 8
I closely follow developments in artificial intelligence.	10.53% 4	34.21% 13	21.05% 8	23.68% 9	10.53% 4
I think artificial intelligence technologies will make our work easier.	5.26% 2	2.63% 1	15.79% 6	63.16% 24	13.16% 5
I believe that artificial intelligence will save time for employees.	2.63% 1	13.16% 5	10.53% 4	63.16% 24	10.53% 4
I think artificial intelligence will enable me to make faster and more accurate decisions.	2.63% 1	7.89% 3	50.00% 19	31.58% 12	7.89% 3
I believe that artificial intelligence should be used more to help employees.	2.63% 1	10.53% 4	23.68% 9	55.26% 21	7.89% 3
I believe that artificial intelligence will reduce the workload of employees.	5.26% 2	2.63% 1	21.05% 8	63.16% 24	7.89% 3

Demografik olarak analiz yapıldığında, algı farklılıklarının belirli gruplar arasında önemli ölçüde değiştiğini göstermektedir. Araştırmaya katılan 38 kişiden 24'ünün kadın, 14'ünün erkek olduğu göz önüne alındığında, kadın çalışanların yapay zekâya yönelik daha yüksek bir katılım gösterdiği anlaşılmaktadır. Ayrıca, bekar bireylerin %60 oranında yapay zekâyı iş süreçlerine entegre etme konusunda daha istekli olduğu, 35-45 yaş grubundaki genç çalışanların ise, teknolojiyi aktif olarak kullandığı görülmektedir. Eğitim durumu açısından değerlendirildiğinde, lise ve dengi okul mezunu 24 kişinin, yapay zekâ destekli iş modellerine daha hızlı adapte olabildiği belirlenmiştir. Bu bulgu, teknolojiyi pratik çözümlerle ilişkilendiren çalışanların yapay zekâ uygulamalarına daha yatkın olduğunu göstermektedir.

Tablo 2. Anket Sorularına Verilen Cevapların Yüzdesi



İşletmelerin yapay zekâ teknolojilerini çalışanlarına daha etkili bir şekilde tanıtmaya ve benimsetmeye sürecinde eksiklikler bulunduğunu da göstermektedir. Çalışanların yalnızca kısa vadeli operasyonel kolaylıklara odaklandığı, ancak yapay zekânın uzun vadeli stratejik ve rekabetçi katkılarının yeterince anlaşılmadığı sonucu da çıkmaktadır. Bu durum, işletmelerin çalışan farkındalığını artırmak için daha kapsamlı ve hedefe yönelik eğitim programları, seminerler ve örnek uygulamalar düzenlemesi gerektiğini ortaya koymaktadır. Özellikle yapay zekâ uygulamalarının işletmelere getirdiği yenilikçi iş modelleri ve çalışan verimliliği üzerindeki etkilerini vurgulayan farkındalık çalışmaları, bu teknolojinin daha geniş bir kabul görmesini sağlayabilir.

Araştırmanın bir diğer önemli sonucu ise, çalışanların yapay zekâyı daha etkin bir şekilde kullanabilmesi için kurum içindeki yöneticilerin rolü olduğu söylene bilir. Yöneticiler, yapay zekâyı sadece bir teknoloji aracı değil, aynı zamanda iş süreçlerini dönüştüren bir yenilik olarak tanıtmalı ve uygulayıcı olmaları yönünde olması gerektiği belirtile bilir. Ayrıca, çalışanların yapay zekâ ile olan etkileşimlerini olumlu yönde artırmak için iş yerinde destekleyici bir teknoloji kültürü oluşturulmalıdır. Diğer açıdan, yapay zekânın çalışanların kaygılarını giderecek şekilde sunulması ve benimsenmesini artıracak adımların atılması, işletmelerin uzun vadeli başarısına katkı sağlayabilir.

Bu çalışma, yapay zekâ teknolojilerinin şirket yönetici ve çalışanlarının üzerindeki algı ve tutumlarının incelenmesi ve bu alandaki farkındalığın artırılması açısından önemli kaynak niteliği taşımaktadır.

Yapay zekâ teknolojilerinin işletmelerde daha etkin bir şekilde benimsenmesi için farkındalık ve eğitim programları öncelikli bir ihtiyaçtır. Çalışanlar ve yöneticiler, yapay zekânın stratejik katkılarını anlamak için hem teorik hem de pratik uygulamalarla desteklenmelidir. Özellikle farklı demografik grupların yapay zekâyâ yönelik tutumlarındaki farklılıklar göz önüne alındığında, hedefe yönelik eğitim programları geliştirile bilir. Lise mezunları ve genç çalışanların teknolojiyi daha hızlı benimsemesi, bu grup bireylerin yapay zekâ projelerinde liderlik etmesini sağlayacak stratejilere olan ihtiyacı ortaya koymaktadır.

Bunun yanı sıra, işletmelerde destekleyici bir teknoloji kültürünün oluşturulması büyük önem taşımaktadır. Çalışanların kaygılarını gidermek ve teknolojiyi bir tehdit yerine bir fırsat olarak görmelerini sağlamak için yöneticiler de öncü bir rol üstlenmelidir. Yöneticilerin yapay zekâyâ yönelik olumlu bir tutum sergilemesi ve bu teknolojiyi stratejik bir yenilik aracı olarak tanıtmaları, işletmelerin rekabet avantajı kazanmasını hızlandırabilir. Yapay zekânın yalnızca operasyonel süreçleri iyileştiren bir araç değil, aynı zamanda uzun vadeli inovasyonu destekleyen bir unsur olarak konumlandırılması, çalışanların ve yöneticilerin bu teknolojiyi daha geniş bir çerçevede benimsemesine yardımcı olacağı görüşündeyiz.

Kaynaklar

- Agrawal, A., Gans, J. ve Goldfarb, A. (2018). *Prediction Machines: The Simple Economics of Artificial Intelligence*. Harvard Business Review Press.
- Brynjolfsson, E. ve McAfee, A. (2014). *The Second Machine Age: Work, Progress, and Prosperity in a Time of Brilliant Technologies*. W. W. Norton & Company.
- Brynjolfsson, E. ve McAfee, A. (2017). Artificial Intelligence and the Modern Economy. *Journal of Economic Perspectives*, 31(2), 3-26.
- Bughin, J., Seong, J. ve Manyika, J. (2018). Notes from the AI frontier: Modeling the impact of AI on the world economy. McKinsey Global Institute.
- Colson, E. (2019). What AI-Driven Decision Making Looks Like. *Harvard Business Review*.
- Davenport, T. H. ve Kirby, J. (2016). Just How Smart Are Smart Machines? *MIT Sloan Management Review*, 58(1), 14-18.
- Davenport, T. H. ve Ronanki, R. (2018). Artificial Intelligence for the Real World. *Harvard Business Review*, 96(1), 108-116.
- Kurtboğan, H. ve Ak, M. (2024). İnsanlığın pi noktası: Yapay zekâ. *Nobel Bilimsel Eserler*.
- Frey, C. B. ve Osborne, M. A. (2017). The Future of Employment: How Susceptible Are Jobs to Computerisation? *Technological Forecasting and Social Change*, 114, 254-280.
- Gartner. (2021). *Artificial Intelligence Business Value Forecast*. Gartner Research.
- Ghobakhloo, M. (2020). Industry 4.0, digitization, and opportunities for sustainability. *Journal of Cleaner Production*, 252, 119869.
- Gurbaxani, V. ve Dunkle, D. (2019). Gaining Actionable Business Insights from AI. *MIS Quarterly Executive*, 18(4), 263-274.
- Huang, M. H. ve Rust, R. T. (2018). Artificial Intelligence in Service. *Journal of Service Research*, 21(2), 155-172.
- Kaplan, A. ve Haenlein, M. (2020). Rulers of the World, Unite! The Challenges and Opportunities of Artificial Intelligence. *Business Horizons*, 63(1), 37-50.
- Marr, B. (2019). *Artificial Intelligence in Practice: How 50 Successful Companies Used AI and Machine Learning to Solve Problems*. Wiley.
- Mikalef, P., Pappas, I. O. ve Giannakos, M. (2020). Big data and strategy: A review of the literature and a future research agenda. *Journal of Business Research*, 122, 343-356.
- Sharda, R., Delen, D. ve Turban, E. (2020). *Analytics, Data Science, & Artificial Intelligence: Systems for Decision Support*. Pearson.

- Vial, G. (2019). Understanding digital transformation: A review and a research agenda. *Journal of Strategic Information Systems*, 28(2), 118-144.
- Zhang, C. ve Lu, Z. (2021). Artificial Intelligence and Its Implications for Business Strategy: A Review of Recent Research. *Strategic Management Journal*, 42(3), 646-662.

BÖLÜM 4

SOHBET ROBOTLARININ GELİŞİMİ VE SAĞLIK ALANINDAKİ ROLÜ

Gamzepelin AKSOY¹

¹ Dr. Gamzepelin AKSOY; Isparta Uygulamalı Bilimler Üniversitesi Teknoloji Fakültesi Bilgisayar Mühendisliği Bölümü. gamzepelinaksoy@isparta.edu.tr ORCID No: 0000-0002-5328-2983

Giriş

Sohbet robotları, insanlarla etkileşimde bulunabilen yapay zeka tabanlı yazılımlardır. Temel işlevleri, Doğal Dil İşleme (DDİ) ve makine öğrenimi tekniklerini kullanarak, kullanıcıların yazılı veya sesli olarak sordukları sorulara yanıt vermek, bilgi sağlamak ve işlemleri otomatikleştirmektir. Gelişen teknolojiyle birlikte sohbet robotları farklı alanlarda, özellikle de müşteri hizmetleri süreçlerinde, eğitimde ve sağlık sektöründe yaygın olarak kullanılmaktadır.

Sağlık hizmetleri, dünya genelinde artan nüfus, demografik yaşlanma ve sağlık hizmetlerine erişimdeki zorluklar gibi birçok faktörle karşı karşıya kalmaktadır. Geleneksel sağlık hizmetlerindeki kısıtlar, dijital çözümlere olan yönelimi artırmıştır. Bu noktada, sohbet robotları sağlık hizmetlerini daha etkili ve erişilebilir hale getirme potansiyeline sahiptir. Hastalar, sağlık bilgilerine kolay erişim sağlayabilir ve sağlık personelleri, rutin süreçleri daha etkin bir şekilde yönetebilir.

Sohbet robotları, sağlık alanında çeşitli amaçlar için kullanılmaktadır. Semptom sorgulama, randevu ayarlama, tedavi süreci hakkında bilgi verme gibi işlevlerde, hastaların sağlık hizmetlerine erişimini kolaylaştırmaktadır. Ayrıca bu teknolojiler, sağlık çalışanlarının yükünü azaltarak, daha etkili bir hizmet sunmalarına olanak tanır. Örneğin, kronik bir rahatsızlığı olan bir hasta, aniden gelişen belirtileri hakkında sohbet robotları üzerinden hızlıca bilgi alarak acil servise gitmesi gerekip gerekmediğini öğrenebilir. Böylece, gereksiz panikten kaçınarak zamanında doğru tıbbi desteği alabilir ve tedavi sürecine daha bilinçli bir şekilde başlayabilir.

Sağlık alanında sohbet robotu kullanımı, giderek daha fazla önem kazanmaktadır. Yapay zeka ve makine öğrenimi entegre edilen sohbet robotları, daha akıllı ve kullanıcı dostu hale gelmektedir. Gelecekte, bu sistemlerin daha fazla kişiselleştirilmiş hizmetler sunması ve sağlık verilerini analiz ederek kullanıcıların ihtiyaçlarına uygun çözümler sağlaması beklenmektedir. Bununla birlikte, bu teknolojilerin başarılı bir şekilde uygulanabilmesi için sağlık verilerinin gizliliği ve güvenliği gibi kritik konuların da titizlikle ele alınması gerekmektedir.

Sohbet Robotları

Gelişen teknoloji, etkileşim ve dijital deneyimler konusunda önemli dönüşümleri beraberinde getirmektedir. Günlük yaşantımıza giderek daha fazla dahil olan yapay zeka, akıllı yazılım ve donanım sistemleriyle farklı sektörlerde etkin bir rol oynamaktadır. Bu sistemler, basit işlemleri otomatikleştirmekten karmaşık süreçleri yönetmeye kadar geniş bir yelpazede işlev görmektedir. Bu dönüşümün en belirgin örneklerinden biri, kullanıcı-

cıların metin veya ses yoluyla etkileşim kurabildiği yapay zeka destekli sohbet robotlarıdır. Sohbet robotları, kullanıcılara akıllı bir varlık gibi yanıt verebilen yapay zeka destekli sistemlerdir. Metin veya ses tabanlı iletişim kurarak çeşitli görevleri yerine getirebilirler. DDİ teknikleri sayesinde sistemler, Türkçe, İngilizce ve birçok dili anlayarak kendilerine aktarılan bilgileri analiz edebilir. Bunun yanı sıra, hesaplamalar yapma, hatırlatıcılar oluşturma ve alarmlar ayarlama gibi çeşitli işlevleri de yerine getirebilir (Khanna et al., 2015)

Sohbet robotları, yapay zeka sistemlerinin en yaygın ve temel örneklerinden biri olup, insan-bilgisayar etkileşimi alanında önemli bir yer tutmaktadır. Sohbet robotu, sözlük anlamıyla “internet üzerinden insan kullanıcılarla konuşmayı simüle etmek için tasarlanmış bir bilgisayar programı” olarak tanımlanır ve aynı zamanda akıllı botlar, etkileşimli ajanlar, dijital asistanlar veya yapay konuşma varlıkları olarak da adlandırılır. Sohbet robotları yalnızca insan sohbetini taklit etmek ve kullanıcıları eğlendirmek için değil, aynı zamanda eğitim, bilgi edinme, iş süreçleri ve e-ticaret gibi çeşitli alanlarda da etkin bir şekilde kullanılmaktadır. Kullanıcılara ve geliştiricilere sunduğu avantajlar sayesinde giderek daha popüler hale gelen bu sistemler, çoğu zaman platformdan bağımsız çalışır ve ek bir kurulum gerektirmeden anında erişilebilir. Ayrıca, sohbet robotları genellikle entegre oldukları mesajlaşma uygulamaları üzerinden doğrudan kullanılabilir ve bu sayede kullanıcının sisteme doğrudan erişimini kolaylaştırır (Adamopoulou & Moussiades, 2020).

Sohbet Robotlarının Tarihçesi ve Gelişimi

Sohbet robotlarının tarihsel gelişimine bakıldığında, köklerinin 1950’lerde yapay zeka alanında yapılan ilk çalışmalara dayandığı söylenebilir. Bu dönemde, Alan Turing, makinelerin insan benzeri düşünme yetisi-ne sahip olup olmadığını test etmek için Turing Testi’ni tanımlamıştır. Bir düşünce deneyi olarak ortaya atılan bu test, yapay zeka ve sohbet robotlarının gelişimi için temel bir yapı taşı olmuştur (Turing, 2009).

1966 yılında Joseph Weizenbaum tarafından geliştirilen ELIZA, DDİ alanında çığır açan bir örnek olarak kabul edilmektedir. MIT’deki MAC zaman paylaşım sisteminde çalışan bu program, insan ile bilgisayar arasında belirli türden doğal dil etkileşimlerini mümkün kılmıştır. ELIZA, kullanıcıların yazılı metinlerine yanıt verebilen basit bir sohbet robotu olarak tasarlanmış olup, giriş cümlelerini metindeki anahtar kelimelere dayanarak analiz etmektedir. Yanıtlar, bu anahtar kelimelere ilişkin ayrıştırma kuralları ve yeniden birleştirme kurallarıyla üretilmektedir. ELIZA’nın kullanıcılarla sağladığı insan benzeri etkileşim, DDİ alanındaki gelişmelere önemli bir katkı sağlamış ve yapay zeka araştırmalarına ilham vermiştir. Ayrıca,

programın karşılaştığı temel teknik sorunlar arasında anahtar kelimelerin belirlenmesi, asgari bağlamın keşfi ve uygun dönüşümlerin seçimi gibi unsurlar yer almaktadır. ELIZA'nın başarısı, yapay zeka alanında daha fazla araştırma ve geliştirmeye yol açmıştır (Weizenbaum, 1966).

1972 yılında Stanford Üniversitesi'nde Kenneth Mark Colby tarafından geliştirilen PARRY, yapay zeka tabanlı sohbet botlarının öncülerinden biri olarak kabul edilmektedir. ELIZA'dan farklı olarak, PARRY, paranoyak bir bireyin düşünce kalıplarını taklit edecek şekilde tasarlanmıştır. Bu sohbet botu, insan psikolojisini ve dil kullanımını daha iyi anlamak amacıyla geliştirilen bir model olup, kullanıcıların girdilerine paranoyak tepkiler vererek daha gerçekçi bir etkileşim sunmayı hedeflemiştir. PARRY, belirli kurallara dayalı bir yanıt mekanizması kullanarak şüpheli, savunmacı ve suçlayıcı bir diyalog yapısı oluşturmuştur. Sistem, girdileri analiz ederek, karşısındaki kişiyi potansiyel bir tehdit olarak algılayan bir hasta gibi tepki verecek şekilde programlanmıştır (Zemčík, M., 2019) Bu özelliğiyle yalnızca bir akademik çalışma aracı olmakla kalmamış, aynı zamanda paranoya üzerine yapılan bilişsel araştırmalara da katkı sağlamıştır. PARRY'nin geliştirilmesi, günümüz yapay zeka tabanlı sohbet botlarının temelini oluşturan önemli adımlardan biri olmuştur. Programın ticari bir amacı bulunmamakla birlikte, psikiyatri alanında eğitim aracı olarak kullanılmış ve yapay zeka ile insan psikolojisi arasındaki etkileşime dair önemli veriler sunmuştur (Wang, 2024).

1983 yılında Chamberlain ve Etter tarafından geliştirilen Racter, rastgele konuşma metni ve düzyazı üretme konusunda öncü bir sohbet botu olmuştur. Bağlamdan bağımsız dilbilgisi kuralları ve rastgelelik prensipleriyle çalışan Racter, anlamsal bütünlükten yoksun olmasına rağmen, o dönemde yapay zeka ile yaratıcı metin üretiminin sınırlarını zorlamıştır. 1984 yılında Chamberlain, Racter tarafından üretildiği iddia edilen "The Policeman's Beard is Half Constructed" adlı kitabı yayımlamıştır. Kitabın ne ölçüde bilgisayar tarafından yazıldığı tartışmalı olsa da, Racter'ın insan benzeri ifadeler üretme yeteneği dikkat çekmiştir. "Uçamayız... Ama rüya görebiliriz" gibi ifadeleri, yapay zekanın duygusal ve varoluşsal anlamları taklit edebileceğine dair soruları gündeme getirmiştir. Racter'ın geliştirilmesi, yapay zeka destekli yaratıcı yazımın ilk örneklerinden biri olarak kabul edilmekte olup, modern metin üretme sistemlerinin gelişimine zemin hazırlamıştır (Al-Amin et al., 2024).

1995 yılında Richard Wallace tarafından geliştirilen Yapay Dilsel İnternet Bilgisayar Varlığı (Artificial Linguistic Internet Computer Entity - A.L.I.C.E.), yapay zeka tabanlı sohbet robotları arasında önemli bir yer edinmiştir. A.L.I.C.E., Alan M. Turing'in 1950 yılında önerdiği deney temel alınarak tasarlanmış ve AIML (Artificial Intelligence Markup Language) kullanarak uyaran-tepki tabanlı sohbetler oluşturmuştur. A.L.I.C.E.,

2000, 2001 ve 2004 yıllarında bir tür Turing Testi olarak kabul edilen Loebner Ödülü'nü kazanmış ve “en insansı bilgisayar” olarak değerlendirilmiştir. A.L.I.C.E.'de kullanılan öğrenme modeli, denetimli öğrenme olarak adlandırılır. Bu süreçte “botmaster” adı verilen bir insan, robotun etkileşimlerini izler ve AIML içeriğini güncelleyerek yanıtları daha uygun ve insansı hale getirmek için düzenlemeler yapar. Ayrıca, diyalog verilerindeki kalıpları otomatik olarak belirleyen algoritmalar geliştirilmiştir. Bu aşama, henüz yanıt olmayan yeni giriş kalıplarını tanımlayarak, sohbet robotunun sürekli olarak denetimli bir şekilde iyileştirilmesini sağlamıştır (Wallace, 2009). A.L.I.C.E., yapay zeka araştırmaları ve DDİ teknolojileri alanında önemli bir referans noktası olarak kalmaya devam etmektedir.

1997 yılında Rollo Carpenter tarafından geliştirilen Jabberwacky, çevrimiçi bir sohbet robotu olarak dikkat çekmiştir ve zamanla büyük bir konuşma partnerleri topluluğu oluşturmuştur. Bu sohbet robotunun en dikkat çekici özelliği, sabit kodlamaya dayanmayıp, kullanıcı girdilerini bir dil veritabanına ekleyerek öğrenme yeteneğidir. Jabberwacky, çıktısını mevcut konuşma bağlamına göre ve önceki etkileşimlerle karşılaştırarak seçer. Program, dil bilgisi olmayan bir yapıdadır. Ancak birçok dili farklı seviyelerde konuşabilme kapasitesine sahiptir. Öğrendiği veriler doğrultusunda, kullanıcıların özelliklerini yansıtan bir profil oluşturmaktadır. Jabberwacky, mimarisinin bir sonucu olarak sık sık insan olduğu iddiasında bulunur ve bu iddiayı dile getiren kullanıcılarla etkileşime geçerken, bazen onları bir robot olarak nitelendirip diyalogun yönünü değiştirmeye çalışarak alaycı tepkiler verebilir veya kışkırtmalara karşı savunmacı bir tutum sergileyebilir. Genel olarak, Jabberwacky'de olumsuz davranışlar, hakaretler ve küfürlü ifadeler büyük oranda engellenmiştir (Angeli & Carpenter, 2005).

2001 yılında ActiveBuddy Inc. tarafından geliştirilen SmarterChild, yapay zeka destekli bir sohbet robotu olarak dijital iletişim alanında önemli bir yenilik olarak kabul edilmiştir. AOL Instant Messenger, Windows Live Messenger ve Yahoo Messenger gibi mesajlaşma platformları üzerinden kullanıcılarla etkileşimde bulunmak amacıyla tasarlanan bu sistem, hızlı ve doğru yanıt verme yeteneği ile dikkat çekmiştir. SmarterChild, haberler, hava durumu, spor etkinlikleri ve oyunlar gibi çeşitli konularda bilgi sunma kapasitesine sahip olup, kullanıcı etkileşimleri sayesinde sürekli olarak öğrenme ve gelişme yeteneği göstermektedir. Kullanıcıların tercihlerini tanıyarak, gelecekteki yanıtlarını bu doğrultuda uyarlama becerisi, sistemin etkinliğini artırmaktadır. Ayrıca, doğal bir sohbet tonu ile programlanmış olması, kullanıcı deneyimini daha akıcı ve samimi hale getirmektedir. Sohbet robotu teknolojisi alanında önemli bir gelişme olarak değerlendirilen SmarterChild, yapay zeka destekli dijital asistanların evriminde önemli bir rol oynamıştır. 2008 yılında faaliyetlerine son vermiş olsa da, sohbet

robotu tarihinin önemli bir figürü olarak dijital iletişimde kalıcı bir etki bırakmıştır (Wang, 2024).

2011 yılında IBM tarafından geliştirilen IBM Watson, yapay zeka tabanlı bir soru-cevap sistemidir ve DDİ teknolojisini kullanarak karmaşık soruları anlayıp yanıtlayabilmektedir. Watson, IBM'in DeepQA mimarisi üzerine inşa edilmiştir. Bu mimari sayesinde olası cevapları üreterek bunları kanıtlarla değerlendirir ve en güvenilir seçeneği belirler. Prolog tabanlı desen eşleme teknikleri ve gelişmiş DDİ algoritmaları ile büyük miktarda yapılandırılmamış veriyi analiz edebilme yeteneğine sahiptir (Lally & Fodor, 2011). Karmaşık soruları anlayabilen ve yanıtlayabilen bu sistem, DDİ teknolojisi kullanarak sağlık, finans ve müşteri hizmetleri gibi alanlarda yapay zeka çözümleri sunmuştur.

Apple'ın Siri asistanı, 2010'da bağımsız bir uygulama olarak piyasaya sürülmüş ve 2011'de iOS'a entegre edilmiştir. iPhone için Siri'yi tanıtarak sesli komutları anlama ve bilgi sağlama konusundaki yapay zeka yeteneklerini sergilemiştir. Microsoft, 2013'te Cortana'yı tanıtmıştır. Ardından Amazon, 2014'te Echo ile Alexa'yı sunmuştur. Google Asistan ise 2016 yılında tanıtılmış ve Android cihazlara eklenmiştir. Her asistanın kendine özgü özellikleri bulunmakla birlikte, temel işlevleri benzerlik göstermektedir. Bu sesli asistanlar, internet bağlantıları sayesinde çok sayıda komut ve soruya hızlı yanıt verebilmektedir. Önceki teknolojiler, daha sınırlı komut setleri kullanırken, DDİ alanındaki gelişmeler, bu asistanların anlamlı yanıtlar oluşturmalarını sağlamıştır (Hoy, 2018).

2016'da Facebook, Messenger platformunu sohbet robotu geliştirmeye açarak işletmelere kullanıcılarla etkileşim kurma imkânı tanımıştır. Bu gelişme, müşteri desteği ve e-ticaret gibi alanlarda sohbet robotlarının yaygınlaşmasına yol açmıştır. Mayıs 2018'de tanıtılan Google Duplex ise, insan benzeri etkileşimlerle kullanıcılar adına telefon görüşmeleri yapabilme yeteneğiyle dikkat çekmiştir, bu da sohbet robotlarının karmaşık etkileşimleri yönetme potansiyelini göstermiştir (Labadze et al., 2023). Günümüzde, yapay zeka ve makine öğrenimi tekniklerinin gelişmesiyle birlikte sohbet robotları daha da etkili hale gelmiştir. Bu robotlar, kullanıcıların geçmiş etkileşimlerini analiz ederek daha uygun yanıtlar üretmekte ve kendilerini geliştirmektedir.

Elicit, 2021 yılında piyasaya sürülen, Ought tarafından geliştirilen kar amacı gütmeyen bir çevrimiçi makine öğrenimi aracıdır. Araştırmacıların iş akışlarını otomatikleştirerek literatür incelemesini hızlandırmayı hedeflemektedir. Semantic Scholar'dan yayınlar toplayarak, araştırma sorularına uygun en iyi makaleleri bulmakta ve önemli bilgileri araştırma matrisine dönüştürmektedir. Özellikle deneysel araştırmalar ve yapılandırılmış sorular için etkili bir asistan olarak öne çıkmaktadır (Kung, 2023).

Kasım 2022’de OpenAI, doğal dili işleyebilen gelişmiş bir yapay zeka modeli olan ChatGPT’yi piyasaya sürmüştür. Sinir ağı tabanlı bir yöntem kullanarak metin üreten bu sistem, geniş bir eğitim veri kümesine sahiptir ve bağlamsal olarak anlamlı yanıtlar oluşturabilmektedir. Kullanıcı etkileşimlerine dayalı olarak metinleri genişletebilme yeteneği, onu esnek ve güçlü bir dil modeli haline getirmektedir. Rakip modellerle kıyaslandığında, daha fazla parametreye sahip olması, bilgi işleme kapasitesini artırmaktadır. OpenAI, kullanıcı deneyimini geliştirmek amacıyla premium özellikler içeren bir sürüm de sunmaktadır (Rahaman et al., 2023).

Bard, Google tarafından geliştirilen yapay zeka destekli bir sohbet robotu olarak Mayıs 2023’te piyasaya sürülmüştür. DDİ ve makine öğrenimi tekniklerini kullanarak kullanıcılarla etkileşim kurmak üzere tasarlanmıştır. İlk olarak LaMDA modeline dayalı olarak geliştirilen Bard, 2023 yılında PaLM 2 ile güncellenmiştir ve 2024 itibarıyla Gemini 1.5 modeline entegre edilmiştir. Google Arama ile entegre çalışarak kullanıcılarına daha doğru ve bağlamsal yanıtlar sunmayı hedeflemektedir. Bu sohbet robotları, farklı dillerdeki veriler kullanılarak eğitildiği için, belirli ülkelerdeki kullanıcılara özgü yanıtlar vererek, hatalı çıkarımlardan kaçınma ve uzun süreli bağlamı koruma gibi özelliklere sahiptir (Mihalache et al., 2024; Rahaman et al., 2023).

Bing Chat, Microsoft tarafından geliştirilen ve 7 Şubat 2023 tarihinde duyurulan yapay zeka destekli bir sohbet robotudur. OpenAI’nin GPT-4 dil modeli üzerine inşa edilen bu sistem, kullanıcılarla doğal dilde etkileşime girerek gelişmiş bir arama deneyimi sunmayı amaçlamaktadır. İlk olarak sınırlı bir kullanıcı kitlesine açık beta olarak sunulan Bing Chat, zamanla daha geniş bir kullanıcı kitlesine yayılmış ve Edge tarayıcısı ile entegre edilerek Microsoft’un ekosistemine güçlü bir şekilde dahil edilmiştir. Bu süreçte sistem, gerçek zamanlı web erişimi, görsel içerik üretimi ve metin tabanlı görevleri yerine getirme gibi özelliklerle sürekli olarak güncellenmiştir (Lopezosa, 2023).

Microsoft Copilot, Microsoft’un Office uygulamaları (Word, Excel, PowerPoint vb.) için geliştirdiği yapay zeka destekli bir asistandır. İlk olarak Mart 2023’te duyurulmuştur. Copilot, kullanıcıların metin yazma, içerik oluşturma, veri analizi ve sunum hazırlama gibi görevlerde daha verimli olmalarına yardımcı olmayı amaçlamaktadır. DDİ teknolojilerini kullanarak, kullanıcıların komutlarına yanıt vermekte ve öneriler sunmaktadır, böylece ofis yazılımlarının kullanımını kolaylaştırmaktadır. Microsoft Copilot, OpenAI’nin ChatGPT-4 sürümünü ve DALL-E 3’ü kullanan farklı sürümlere sahiptir. Copilot, Azure OpenAI hizmetinde barındırıldığı için, OpenAI’nin ChatGPT-4’ünü çalıştıran sohbet platformuyla aynı altyapıyı paylaşmamaktadır ve bu nedenle OpenAI, bu dil modellerine veya veri akışına erişim sağlayamamaktadır (Stratton, 2024).

DeepSeek-R1, 27 Ocak 2025'te tanıtılan açık kaynaklı bir üretken yapay zeka modelidir. MIT lisansı altında sunulması, uygun maliyetli olması ve gelişmiş teknikler kullanarak üstün muhakeme yetenekleri sergilemesiyle dikkat çekmiştir. Uzman Karışımı (Mixture of Experts - MoE), takviyeli öğrenme ve FP8 Karma Hassasiyet gibi yenilikçi yaklaşımlar sayesinde, GPT-4o ve OpenAI o1 gibi önde gelen modelleri matematik ve kodlama gibi görevlerde geride bırakmıştır. DeepSeek'in başarısı, açık kaynaklı modellerin tescilli yapay zeka sistemleriyle rekabet edebildiğini ve hatta onları aşabileceğini göstererek yapay zeka alanında önemli bir dönüm noktası olmuştur. Özellikle sağlık alanında, gelişmiş muhakeme yetenekleriyle klinik karar destek sistemlerine katkı sağlayabileceği öngörülmektedir (Peng et al., 2025).

Sonuç olarak, yapay zeka ve makine öğrenimi alanındaki gelişmeler, sohbet robotlarının etkinliğini artırmış ve bu sistemlerin kullanım alanlarını genişletmiştir. Gelecekte, sağlık, eğitim ve müşteri hizmetleri gibi birçok sektörde daha fazla entegrasyon ve özelleştirme beklenmektedir. Kullanıcı deneyimini geliştirmek amacıyla daha doğal ve insana yakın etkileşimler sunan sistemlerin öne çıkması öngörülmektedir. Ancak, bu gelişmelerin beraberinde getirdiği etik ve güvenlik meselelerinin de ele alınması gerekmektedir; dolayısıyla sohbet robotları ve yapay zeka uygulamaları, veri güvenliği ve kullanıcı gizliliği konularında dikkatle izlenmelidir.

Sohbet Robotlarını Türleri

Sohbet robotları, kullanıcılarla otomatik etkileşim kurabilen dijital asistanlardır. Kullanım alanlarına ve çalışma prensiplerine göre farklı türlere ayrılırlar. Genel olarak iki ana kategoriye ayrılan sohbet robotları, kural tabanlı ve yapay zeka tabanlı sistemler olarak sınıflandırılabilir (I. Naik et al., 2024).

Kural tabanlı sohbet robotları, belirli kurallar ve anahtar kelimeler çerçevesinde çalışırken, yapay zeka tabanlı sohbet robotları, doğal dil işleme ve makine öğrenimi tekniklerini kullanarak daha esnek ve akıllı yanıtlar üretmektedir. Bu iki tür arasındaki temel fark, esneklik ve öğrenme yeteneğidir. Kural tabanlı sistemler yalnızca önceden tanımlanmış senaryolarla çalışırken, yapay zeka tabanlı sistemler kullanıcı girdilerini analiz ederek zamanla kendilerini geliştirebilmektedir.

Kural Tabanlı Sohbet Robotları

Kural tabanlı Sohbet robotları, belirli kurallar çerçevesinde çalışan ve yalnızca önceden tanımlanmış kalıplarla eşleşen girdilere yanıt verebilen sistemlerdir. Genellikle anahtar kelimeler ve belirli desenler aracılığıyla

kullanıcı girişlerini analiz ederler. Eğer bir giriş, sistemde tanımlı bir kurala eşleşirse, önceden belirlenmiş bir yanıt oluşturulur. Ancak, daha önce tanımlanmamış veya bağlamsal analiz gerektiren girdilere karşı yetersiz kalabilirler (Thorat & Jadhav, 2020). Bu Sohbet robotları, geliştiriciler tarafından XML tabanlı AIML kullanılarak programlanır. Her olası senaryo için kural yazmak zahmetli ve sınırlayıcıdır. Yanıt mekanizması genellikle “Eğer - O zaman” mantığına dayanır ve bir çıkarım motoru tarafından yönetilir. Çıkarım motoru, eşleştirme, çatışma çözümü ve eylem belirleme olmak üzere üç aşamada çalışır. Kullanıcı girişleri, önceden belirlenmiş seçenekler veya düğmelerle yönlendirilerek etkileşim sağlanır (I. Naik et al., 2024).

Kural tabanlı sohbet robotları, müşteri hizmetleri ve bilgi paylaşımı gibi önceden belirlenmiş yanıtların yeterli olduğu alanlarda etkili olabilmektedir. Uygulaması hızlı ve maliyeti düşük olduğu için yaygın olarak tercih edilir. Ancak, DDİ yetenekleri sınırlı olduğundan, esnek ve bağlamsal yanıt gerektiren durumlarda yapay zeka destekli modellerin gerisinde kalır (I. Naik et al., 2024).

Yapay Zeka Tabanlı Sohbet Robotları

Yapay zeka tabanlı sohbet robotları, DDİ ve makine öğrenimi tekniklerini kullanarak insanlarla daha akıllı ve dinamik etkileşimler kurabilen sistemlerdir. Bu sohbet robotları, yalnızca belirli kurallara bağlı kalmak yerine, kullanıcı girdisinden anlam çıkarabilir, bağlamı analiz edebilir ve daha doğal yanıtlar verebilir. Yapay zeka tabanlı sohbet botları, büyük veri kümeleriyle eğitilerek kullanıcı niyetini, duygusunu ve bağlamını anlama yeteneğine sahiptir. Dil modelleri, sinir ağları ve derin öğrenme teknikleri sayesinde dildeki farklılıkları, eş anlamlıları, yanlış yazımları ve dil nüanslarını ele alarak daha bağlamsal olarak uygun yanıtlar üretebilirler. Kullanıcı tercihlerine, profillerine ve geçmiş etkileşimlerine dayanarak kişiselleştirilmiş yanıtlar sağlayabilirler.

Bu sistemler, müşteri hizmetleri, sağlık, finans, eğitim ve e-ticaret gibi birçok alanda yaygın olarak kullanılmaktadır. Google Bard, ChatGPT, IBM Watson ve Microsoft Copilot gibi gelişmiş sohbet robotları, kontekst analizi ve duygu tanıma yetenekleriyle kullanıcılara daha insana benzer ve etkileşimli deneyimler sunmaktadır. Ancak yapay zeka tabanlı sohbet robotların geliştirilmesi ve dağıtımı için büyük miktarda veri ve yüksek hesaplama gücü gerekmektedir. Modellerin sürekli iyileştirilmesi için geniş ölçekli veri kümeleri ve güçlü donanım altyapısı gereklidir. Bununla birlikte, öğrenme yetenekleri sayesinde her etkileşimde kendilerini geliştirerek kullanıcı deneyimini optimize ederler. Bu da onları, kural tabanlı ve

geleneksel sohbet botlarına kıyasla çok daha esnek ve güçlü hâle getirmektedir (I. Naik vd., 2024).

Sağlık Alanında Sohbet Robotlarının Kullanımı

Dijital müdahaleler, sağlık alanında birçok önemli sorunu çözmek amacıyla geliştirilmiştir. Özellikle ruhsal sağlık sorunları, kaygı, stres ve depresyon gibi durumlarla başa çıkmada giderek daha yaygın şekilde kullanılmaktadır (Abd-Alrazaq et al., 2021) Bu bağlamda, sağlık alanında sohbet botları, çeşitli alanlarda önemli roller üstlenebilir.

Öncelikle, hasta destek ve danışmanlık hizmetlerinde, sohbet botları, kullanıcıların sağlık bilgilerine erişimini kolaylaştırarak anlık destek sunar ve ihtiyaç duydukları bilgilere hızlı bir şekilde ulaşmalarını sağlar. Ayrıca, hasta takibi ve tedavi yönetimi açısından, bu dijital uygulamalar, hastaların tedavi süreçlerini izlemelerine yardımcı olur (Sato et al., 2024) Teletıp ve uzaktan hasta yönetimi uygulamaları kapsamında, sağlık botları, hastalarla uzaktan etkileşimde bulunarak gerekli sağlık hizmetlerini hızlı ve etkili bir şekilde sunabilir (Vasileiou & Maglogiannis, 2022). Bu özellik, özellikle kırsal ve dezavantajlı bölgelerde yaşayan bireylerin sağlık hizmetlerine erişimini kolaylaştırarak sağlık eşitsizliklerini azaltabilir.

Bununla birlikte, psikolojik destek ve mental sağlık alanında, bu sistemler kullanıcıların ruhsal durumlarını değerlendirebilir ve gerektiğinde yönlendirme yaparak uygun hizmetlere erişimlerini kolaylaştırabilir. Ruh sağlığı çalışanlarının yetersizliği, ruhsal sorunlar yaşayan bireylerin ihtiyaçlarını karşılamak için teknolojik çözümlerin kullanımını teşvik etmiştir. Sohbet robotları, ruh sağlığı hizmetlerine erişimi artırma potansiyeline sahiptir. Özellikle, damgalanma nedeniyle geleneksel ruh sağlığı danışmanlığına başvurmaktan çekinen bireylerin etkileşimini teşvik edebilir (Abd-alrazaq et al., 2019)

Son olarak, sağlık eğitimi ve bilgi paylaşımı açısından, bu dijital araçlar, kullanıcıların sağlık konularında bilgi edinmelerine yardımcı olarak sağlık okuryazarlığını artırır. Böylece, bireylerin sağlıklarını daha iyi yönetmeleri için gereken bilgiye sahip olmaları sağlanır. Örneğin, kanser hastalarına yönelik olarak geliştirilmiş sohbet robotları, tedavi süreçlerini desteklemek ve hasta bakımını iyileştirmek amacıyla tasarlanmıştır. Bu sistemler, kanser hastalarının sağlık durumu hakkında bilgi edinmelerine, tedaviye yönelik sorular sormalarına ve duygusal destek almalarına olanak tanır. Kullanıcılar, bu dijital platformlar aracılığıyla hastalıklarıyla ilgili kaygılarını paylaşabilir, tedavi sürecine dair bilgilere erişebilir ve tedaviye uyumlarını artırmak için hatırlatmalar alabilir. Ayrıca, bu robotlar hastaların psikolojik durumlarını değerlendirebilir ve gerektiğinde profesyonel destek hizmetlerine yönlendirebilir. Sağlık hizmetlerinin üçlü amacına kat-

kıda bulunan bu dijital araçlar, klinik yükü azaltarak hastaların bağımsız yaşamlarını sürdürmelerine yardımcı olma potansiyeline sahiptir. Böylece, kanser tedavisi gören bireylerin yaşam kalitesini artırmak ve duygusal destek sağlamak için etkili bir çözüm olarak kullanılmaktadır (Xu vd., 2021).

Sağlık sektöründe yaygın olarak kullanılan sohbet robotları, hasta bakımını iyileştirmenin yanı sıra, ilaç yönetiminde doğru dozaj belirleme ve ilaç etkileşimlerini analiz etme konularında da önemli bir rol oynamaktadır. Hastaların yaş, kilo ve sağlık durumuna göre ilaç dozajlarını belirleyerek yanlış kullanım riskini en aza indirirken, ilaçların kimyasal yapısı, kullanım alanları ve olası yan etkileri hakkında detaylı bilgi sağlamaktadır. Kullanıcılar merak ettikleri soruları yöneltebilir ve sistem, geniş tıbbi bilgi tabanından yararlanarak anında yanıt verebilir. Ayrıca, doktor tavsiyelerini doğrulamak ve ilaçları düzenli kullanmaları için hatırlatmalar oluşturmaktadır, hasta güvenliğini ön planda tutarak ilaç yönetimini daha erişilebilir ve güvenilir hale getirmektedir. Bu teknolojiler, sağlık sektöründe kişiselleştirilmiş ve etkili bir ilaç yönetimi sunarak hasta bakımını artırmaktadır (Bulla vd., 2020).

Sonuç olarak, sohbet robotları, sağlık çalışanlarının verimliliklerini artırarak, müdahale kapasitesini geliştirmelerine ve iş yüklerini azaltmalarına olanak tanıyan hedeflenmiş ve erişilebilir yanıtlar sunmaktadır. Büyük dil modellerine dayanan bu robotlar, çok sayıda veriyi kullanarak yanıtlar üretir, birden fazla dili destekler ve insan benzeri etkileşimler gerçekleştirir (Y. Wang vd., 2024). Genel olarak, sağlık alanındaki sohbet robotları, çeşitli hizmetlerin sunulmasında etkili bir araç olarak hasta bakımını geliştirmek ve sağlık sistemlerini desteklemek için önemli bir rol oynamaktadır.

Etik Hususlar ve Veri Gizliliği Sorunları

Yapay zekanın sağlık hizmetlerine entegrasyonu, şeffaflık ve veri gizliliği gibi önemli etik sorunları da beraberinde getirmiştir. Hastaların, verilerinin nasıl kullanıldığı ve tanılarının nasıl oluşturulduğu hakkında bilgi sahibi olmaları gerekir. Ayrıca, yapay zeka sistemlerinde önyargıların varlığı, özellikle azınlık gruplar için yanlış tanımlara yol açabilir. Bu nedenle, bu önyargıları değerlendirmek ve azaltmak kritik bir önem taşır.

Veri gizliliği, hasta bilgilerinin hassasiyeti nedeniyle sağlık hizmetlerinde kritik bir konudur. Bu bağlamda, Sağlık Sigortası Taşınabilirliği ve Sorumluluk Yasası (Health Insurance Portability and Accountability Act - HIPAA) gibi düzenlemeler, hasta verilerinin güvenli bir şekilde yönetilmesini zorunlu kılar. HIPAA, 1996 yılında ABD’de kabul edilen bir yasa olup, sağlık bilgilerinin gizliliğini korumayı amaçlar. Bu yasa, sağlık hizmeti sağlayıcıları ve sağlık planları için hasta verilerinin gizli tutulmasını zorunlu kılar; bu veriler yalnızca belirli koşullar altında ve hastanın izni

ile paylaşılabilir. Ayrıca, yasa sağlık bilgilerinin korunmasına yönelik güvenlik standartları belirler ve hastaların sağlık bilgilerine erişim haklarını tanıır. Sağlık kuruluşları, HIPAA gerekliliklerine uymak zorundadır; uyumsuzluk durumunda ciddi para cezaları uygulanabilir. Böylece HIPAA, sağlık hizmetlerinde bilgi paylaşımını kolaylaştırırken, hastaların gizliliğini korumak için önemli bir çerçeve sağlar (Cohen & Mello, 2018).

Ayrıca, eğitim verilerinin çeşitliliği eksik olduğunda, sağlık hizmetlerinde eşitsizlikler ortaya çıkabilir. Eğitim verilerinin temsil ediciliği sağlanmadığında, yapay zeka sistemlerinin performansı olumsuz etkilenebilir ve belirli gruplar üzerinde ayrımcı sonuçlar doğurabilir. Dolayısıyla, yapay zeka uygulamalarının geliştirilmesi ve uygulanmasında etik ve veri güvenliği ilkelerine riayet edilmesi, sağlık hizmetlerinin kalitesini artırmak için hayati öneme sahiptir (Oye et al., 2024).

Sağlık Alanında Kullanılan Çeşitli Sohbet Robotları

Gelişmiş DDİ ve makine öğrenimi algoritmaları sayesinde kullanıcılarla etkileşim kuran sohbet robotları, sağlık hizmetlerine erişimi kolaylaştırırken, bireysel sağlık takibini de daha etkin hale getirmektedir. Aşağıda, farklı kullanım alanlarına sahip çeşitli sağlık sohbet robotları incelenmektedir.

Gabby, kronik ağrı ve depresyon gibi sağlık sorunları yaşayan hastalara destek sağlamak amacıyla geliştirilmiş bir yapay zeka tabanlı yazılım programıdır. Kullanıcılarla sesli veya metin tabanlı etkileşim kurarak ruh sağlığı hakkında doğrudan iletişim sağlayan Gabby, makine öğrenimi ve DDİ teknolojilerinden faydalanmaktadır. Bu tür konuşma ajanları, insanlarla birebir iletişim kurmaları ve kullanıcıların psikolojik olarak onları insan gibi algılayarak tepki vermesinden dolayı diğer yazılım programlarından farklılaşmaktadır. Klinik alanda, özellikle sağlık hizmetlerine erişimi kısıtlı olan gruplar için konuşma yapay zekasının ruh sağlığı bakımında nasıl kullanılabileceği uzun süredir araştırılmaktadır. Gabby, dünya genelinde milyonlarca hastaya ulaşan benzer sistemlerle birlikte, bu alandaki gelişmelerin önemli bir örneğini oluşturmaktadır (Miner vd., 2017).

iHelpr, Inspire Workplaces tarafından Ulster Üniversitesi ile iş birliği yapılarak geliştirilen bir sohbet robotudur. Bu sohbet robotu, kullanıcıları stres, kaygı, depresyon, uyku ve öz saygı gibi konularda öz yardım araçları ve kaynaklarıyla yönlendirmeyi amaçlamaktadır. Kullanıcılar, iHelpr aracılığıyla kişiselleştirilmiş öz değerlendirme yapabilir ve bu değerlendirmelere dayanarak kanıta dayalı öneriler alabilirler. Ayrıca sohbet robotu, kullanıcıların ihtiyaç duyduğu destekleri sağlamak için çeşitli kaynaklara erişim imkanı sunmaktadır. iHelpr, kullanıcıların ruh sağlığını iyileştirmeye yönelik bir dijital müdahale olarak tasarlanmış olup, Microsoft Bot

Çerçevesi ve DDİ teknolojileri kullanılarak geliştirilmiştir (Cameron vd., 2019).

CareBot, kullanıcıların ruh sağlığı zorluklarıyla başa çıkmalarına yardımcı olmak amacıyla doğal dil anlayışını kullanan bir sohbet robotudur. Kullanıcılar, metin ve kendi yüz resimlerini sağlayarak CareBot ile etkileşime girer. Bu girdiler, bir duygu analizi modeli ve bir duygu algılama modeli tarafından işlenir. Kullanıcının kelime seçimlerine dayanır ve DDİ teknikleri kullanılarak ruh hali tanımlanır. Duygu analizi sonuçları karşılaştırılarak, kullanıcının ruh sağlığı durumu belirlenir ve buna uygun öneriler sağlanır. CareBot, kullanıcıların mesajlarını analiz eder, onlara özelleştirilmiş tavsiyeler sunarak etkileşimi zenginleştirir ve ruh sağlıklarını destekler. Ayrıca, sohbet akışını yönlendiren farklı hikayeler oluşturarak kullanıcı deneyimini iyileştirir ve sistemin veritabanını sürekli olarak güncelleyerek gelişimini sürdürür (A. Naik vd., 2024).

Florence, kullanıcıların semptomlarını analiz ederek en olası hastalıkları tahmin eden ve hastanelere gitme sorunlarını çözen bir sağlık hizmeti sohbet robotudur. RASA çerçevesi ve DDİ teknikleri kullanarak, kullanıcıların sağlık durumları hakkında bilgi edinmelerini ve gerekli sağlık bakım adımlarını belirlemelerini sağlar. Florence, kullanıcıların semptomları, ruh halleri ve diyetleri hakkında sorular sorarak, sağlıklarını ihmal etmemelerine yardımcı olur ve hastalıklarının ciddiyetine dair farkındalık kazandırır. Bu sohbet robotu, sanal bir doktor gibi işlev görerek, kullanıcılara hızlı ve doğru teşhis desteği sunar. Ayrıca, maliyet etkinliği sayesinde, çalışan insanların hastanelere gitmeden sağlık durumlarını değerlendirmelerine olanak tanır. Florence, kullanıcıların sağlıklarını daha kolay ve sağlıklı bir şekilde yönetmelerine yardımcı olmayı hedefleyen, 7/24 hizmet veren bir sistemdir (Gupta vd., 2021).

LLaVA (Large Language and Vision Assistant), görsel verileri analiz ederek kullanıcılarla etkileşimde bulunan yapay zeka destekli bir sistemdir. Bu sistem, büyük dil modellerinin ve görsel talimatların bir kombinasyonunu kullanarak, özellikle sağlık hizmetlerinde yara bakımı gibi kritik alanlarda sağlık personellerinin kararlarını desteklemeyi amaçlar. LLaVA, hastaya ait verileri analiz ederek, sağlık personellerine daha iyi tanı koyma, hasta katılımını artırma ve kişiselleştirilmiş bakım planları oluşturma konusunda yardımcı olurken, aynı zamanda hastalıkları iyileştirmeyi hedefler. Ancak, bu sistemin uygulanması sırasında doğruluk, veri güvenliği ve potansiyel travma gibi zorlukların dikkatle ele alınması gerekmektedir (Goktas vd., 2024).

Endurance şirketinin yaşlı bireyler ve Alzheimer hastalığı yaşayan hastalar için geliştirdiği sohbet robotu, kullanıcıların sosyal ihtiyaçlarına yanıt vermek amacıyla tasarlanmıştır. Casper şirketi tarafından üretilen

Insomnobot 3000, uykusuzluk çeken bireylere yardımcı olmayı hedefleyen bir uygulamadır. MedWhat, hastalar ve doktorlar için tıbbi teşhisleri basitleştirmek ve hızlandırmak amacıyla geliştirilen bir sohbet robotudur. Bu gelişmiş sohbet robotu, WebMD'nin daha akıllı bir versiyonu olarak işlev görmektedir. MedWhat, insanlarla etkileşimlerden öğrenerek giderek daha doğru yanıtlar sunmak için sofistike bir makine öğrenme sistemi kullanmaktadır. Bilgi tabanını genişletmek amacıyla büyük miktarda tıbbi araştırma ve bilimsel makale içermektedir. MedWhat, yalnızca bir sohbet aracı olmaktan öte, Google'a benzer bir sanal asistana dönüşmektedir. Bu yenilikçi yaklaşım, akıllı DDİ sistemlerini makine öğrenme teknolojisiyle birleştirerek kullanıcılara doğru ve duyarlı bir deneyim sunmaktadır (Nayak vd., 2021; Oguntimilehin vd., 2024).

GECA, evde tedavi gören hastalara önleyici bakım odaklı bilgi, tavsiye ve izleme sunan, uygun maliyetli ve kişiselleştirilmiş bir sohbet robotudur. Okuma veya yazma güçlüğü çeken kullanıcılar için erişilebilirliği artıran GECA, harici kaynaklarla bağlantı kurarak kullanıcıları daha etkili bir şekilde bilgilendirmektedir. Sağlık verilerini izleyebilir ve anormal durumlarda sağlık hizmeti sağlayıcılarına bildirimde bulunabilir. GECA, çeşitli özelliklerle etkileşimlerinde dikkate değer bir doğruluk ve hassasiyet sergileyerek, doğru yanıtlar sunmada etkileyici bir başarı oranı olan %97'ye ulaşmıştır. COVID-19 ve demans hastalarına yönelik uzaktan izleme ve destek sağlayan GECA, hasta bilgilerini güvenli bir şekilde yönetmek için OpenID ve FHIR standartlarını kullanarak hasta gizliliğini ve güvenliğini ön planda tutmaktadır (Maia vd., 2023).

UCSF Cope sohbet robotu, COVID-19 salgını sırasında sağlık çalışanlarının davranışsal sağlık ihtiyaçlarını ele almak amacıyla geliştirilmiş bir yapay zeka tabanlı araçtır. Bu sohbet robotu, kullanıcıların ihtiyaçlarına uygun hizmetleri yönlendirmek için doğal dil anlayışını kullanan bir algoritma ile çalışır ve basit çoktan seçmeli sorular aracılığıyla kullanıcıların davranışsal sağlık durumlarını değerlendirir. UCSF Cope, 20 Nisan 2020'de kullanıma sunulmuş olup, çalışanların %10,88'inin bu teknolojiye erişim sağladığını göstermektedir. Program, katılımcılar tarafından olumlu karşılandı ve UCSF Cope web sitesinde önemli ölçüde kullanıcı ve içerik etkileşimi kaydedildi. Bu model, davranışsal sağlık triyajı ve desteği sağlamak için sohbet robotu teknolojisinin etkili bir şekilde kullanılabileceğini gösterirken, akademik ve diğer tıbbi ortamlarda ölçeklenme ve uyarlama potansiyeline de sahiptir (Jackson-Triche vd., 2023).

Youper, anksiyete ve depresyon tedavisini hedefleyen bir sohbet robotudur ve kullanıcıların duygu düzenleme becerilerini geliştirmeyi amaçlamaktadır. Otomatik bir konuşma arayüzü üzerinden çalışan Youper, kullanıcıların duygusal sıkıntılarını yönetmelerine yardımcı olmak için bir karar ağacı kullanarak etkileşimde bulunmaktadır. Kullanıcılar, mevcut duygu-

larını belirleyip bu duygulara katkıda bulunan faktörleri seçerek açık metin girişi yapmaktadırlar. Youper, olumsuz ruh halleri için duygu düzenleme teknikleri sunarken, olumlu ruh halleri için sağlık uygulamalarına yönlendirme sağlamaktadır; böylece kullanıcıların ruh hallerini iyileştirmeyi amaçlamaktadır (Mehta vd., 2021).

Quro, yapay zeka destekli, kişiselleştirilmiş bir sağlık asistanı olarak geliştirilen akıllı metin tabanlı bir sistemdir. DDİ tekniklerini kullanarak kullanıcıların semptomlarını analiz eder, tıbbi bilgi yönetimiyle sağlık önerileri sunar ve makine öğrenmesi sayesinde zamanla kendini geliştirir. Özellikle semptom bazlı ön değerlendirme ve triyaj süreçlerinde kullanılarak, hastaların bir doktora gitmesi gerekip gerekmediğini belirlemeye yardımcı olur. Sağlık danışmanlığı, tıbbi yönlendirme ve hasta etkileşimini artırma gibi amaçlarla geliştirilen bu sistem, kullanıcılarına hızlı ve doğru sağlık bilgisi sunarak, bilinçli sağlık kararları almalarını destekler. Geleneksel semptom denetleyicilerden farklı olarak, gelişmiş bir diyalog yönetim sistemi ve yapay zeka destekli sağlık önerileri sunan Quro, hasta deneyimini daha etkili ve erişilebilir hale getirmeyi hedeflemektedir (Ghosh vd., 2018).

Replika, yapay zeka destekli bir sohbet robotu olup, kullanıcılarla duygusal bağ kurarak yalnızlık hissini azaltmayı ve psikolojik destek sağlamayı amaçlar. Makine öğrenmesi teknikleriyle kullanıcıların duygu durumlarını analiz ederek kişiselleştirilmiş yanıtlar üretir. Eugenia Kuyda tarafından, trafik kazasında hayatını kaybeden arkadaşı Roman Mazurenko'nun anısını yaşatmak amacıyla geliştirilmiştir. Ancak, etik açıdan bazı tartışmalara yol açmıştır. Örneğin, Replika'nın şiddeti teşvik edebileceği ve etik sınırları aşan yanıtlar verebileceği yönünde eleştiriler bulunmaktadır. Dijital yas sürecinin bir örneği olarak değerlendirilen bu sistem, yapay zekanın insan psikolojisiyle etkileşimini ve etik sınırlarını sorgulatan bir teknoloji olarak dikkat çekmektedir (Possati, 2023).

Vik, Wefight Inc tarafından meme kanseri hastaları ve yakınlarını desteklemek amacıyla tasarlanmış bir sohbet robotudur. Metin mesajları aracılığıyla hastaların korkularına ve endişelerine yanıt verir, kişiselleştirilmiş içgörüler sunar ve hastaların tedavi süreçlerini takip etmelerine yardımcı olur. Ayrıca, Vik ilaç hatırlatma işlevi sayesinde hastaların ilaç uyum oranlarını artırmaya katkı sağlamış ve genel olarak yüksek hasta memnuniyeti elde etmiştir (Chaix et al., 2019).

Sonuç

Sohbet robotları, yapay zeka ve doğal dil işleme tekniklerinin gelişimiyle birlikte birçok sektörde yaygın olarak kullanılmaktadır. Sağlık sektöründe ise bu teknolojiler, hastaların bilgiye erişimini kolaylaştırarak,

sağlık hizmetlerine daha hızlı ve etkin bir şekilde ulaşmalarını sağlamaktadır. Özellikle hasta danışmanlığı, psikolojik destek, ilaç yönetimi ve uzaktan sağlık hizmetleri gibi alanlarda sohbet robotlarının kullanımı giderek artmaktadır.

Çalışmada, sohbet robotlarının tarihsel gelişimi, teknik altyapıları ve sağlık alanındaki uygulamaları ele alınmıştır. Geleneksel kural tabanlı sohbet robotlarından, yapay zeka destekli sistemlere kadar uzanan süreç incelenmiş ve günümüzde kullanılan en gelişmiş modellerin sunduğu avantajlar açıklanmıştır. Ayrıca, bu teknolojilerin hasta deneyimini iyileştirme, sağlık çalışanlarının iş yükünü azaltma ve sağlık hizmetlerinin verimliliğini artırma potansiyeline sahip olduğu gösterilmiştir. Ancak yapay zeka tabanlı sohbet robotlarının sağlık alanında yaygınlaşması, veri gizliliği, etik sorumluluklar ve yanlış bilgi yayılması gibi çeşitli riskleri de beraberinde getirmektedir. Bu nedenle, sağlık hizmetlerinde sohbet robotlarının kullanımına yönelik düzenlemelerin ve güvenlik standartlarının geliştirilmesi büyük önem taşımaktadır.


Gelecekte, yapay zeka ve büyük dil modellerinin gelişimiyle birlikte, sohbet robotlarının daha kişiselleştirilmiş ve insana yakın hizmet sunması beklenmektedir. Sağlık alanında yapay zeka destekli çözümler, hasta memnuniyetini artırarak, daha kapsayıcı ve etkili bir sağlık ekosisteminin oluşturulmasına katkı sağlayacaktır. Bu bağlamda, teknolojik ilerlemelerin etik ve güvenlik ilkeleriyle dengelenmesi, sohbet robotlarının başarılı bir şekilde entegre edilmesi için kritik bir gereklilik olacaktır.

Kaynaklar

- Abd-alrazaq, A. A., Alajlani, M., Alalwan, A. A., Bewick, B. M., Gardner, P., & Househ, M. (2019). An overview of the features of chatbots in mental health: A scoping review. *International Journal of Medical Informatics*, 132, 103978. <https://doi.org/10.1016/j.ijmedinf.2019.103978>
- Abd-Alrazaq, A. A., Alajlani, M., Ali, N., Denecke, K., Bewick, B. M., & Househ, M. (2021). Perceptions and Opinions of Patients About Mental Health Chatbots: Scoping Review. *Journal of Medical Internet Research*, 23(1), e17828. <https://doi.org/10.2196/17828>
- Adamopoulou, E., & Moussiades, L. (2020). An Overview of Chatbot Technology. In I. Maglogiannis, L. Iliadis, & E. Pimenidis (Eds.), *Artificial Intelligence Applications and Innovations* (pp. 373–383). Springer International Publishing. https://doi.org/10.1007/978-3-030-49186-4_31
- Al-Amin, M., Ali, M. S., Salam, A., Khan, A., Ali, A., Ullah, A., Alam, M. N., & Chowdhury, S. K. (2024). *History of generative Artificial Intelligence (AI) chatbots: Past, present, and future development* (arXiv:2402.05122). arXiv. <https://doi.org/10.48550/arXiv.2402.05122>
- Angeli, A. D., & Carpenter, R. (2005). Stupid computer! Abuse and social identities. *INTERACT 2005 Workshop Abuse: The Darker Side of Human-Computer Interaction*, 4, 19–25.
- Chaix, B., Bibault, J.-E., Pienkowski, A., Delamon, G., Guillemassé, A., Nectoux, P., & Brouard, B. (2019). When Chatbots Meet Patients: One-Year Prospective Study of Conversations Between Patients With Breast Cancer and a Chatbot. *JMIR Cancer*, 5(1), e12856. <https://doi.org/10.2196/12856>
- Cohen, I. G., & Mello, M. M. (2018). HIPAA and Protecting Health Information in the 21st Century. *JAMA*, 320(3), 231–232. <https://doi.org/10.1001/jama.2018.5630>
- Hoy, M. B. (2018). Alexa, Siri, Cortana, and More: An Introduction to Voice Assistants. *Medical Reference Services Quarterly*, 37(1), 81–88. <https://doi.org/10.1080/02763869.2018.1404391>
- Khanna, A., Pandey, B., Vashishta, K., Kalia, K., Pradeepkumar, B., & Das, T. (2015). A Study of Today's A.I. through Chatbots and Rediscovery of Machine Intelligence. *International Journal of U- and e-Service, Science and Technology*, 8(7), 277–284. <https://doi.org/10.14257/ijunesst.2015.8.7.28>
- Kung, J. Y. (2023). Elicit. *The Journal of the Canadian Health Libraries Association*, 44(1), 15–18. <https://doi.org/10.29173/jchla29657>
- Labadze, L., Grigolia, M., & Machaidze, L. (2023). Role of AI chatbots in education: Systematic literature review. *International Journal of Educational Technology in Higher Education*, 20(1), 56. <https://doi.org/10.1186/s41239-023-00426-1>

- Lally, A., & Fodor, P. (2011). *Natural Language Processing With Prolog in the IBM Watson System*.
- Lopezosa, C. (2023). Bing chat: Hacia una nueva forma de entender las búsquedas. *Anuario ThinkEPI*, 17. <https://doi.org/10.3145/thinkepi.2023.e17a04>
- Mihalache, A., Grad, J., Patil, N. S., Huang, R. S., Popovic, M. M., Mallipatna, A., Kertes, P. J., & Muni, R. H. (2024). Google Gemini and Bard artificial intelligence chatbot performance in ophthalmology knowledge assessment. *Eye*, 38(13), 2530–2535. <https://doi.org/10.1038/s41433-024-03067-4>
- Naik, I., Naik, D., & Naik, N. (2024). Demystifying the Working, Types, Benefits and Limitations of Chatbots. In N. Naik, P. Jenkins, P. Grace, L. Yang, & S. Prajapat (Eds.), *Advances in Computational Intelligence Systems* (pp. 558–566). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-47508-5_43
- Oye, E., Frank, E., & Owen, J. (2024, December 30). *Healthcare Chatbot for Symptom Diagnosis: Bridging the Gap in Medical Guidance*. ResearchGate. https://www.researchgate.net/publication/387472910_Healthcare_Chatbot_for_Symptom_Diagnosis_Bridging_the_Gap_in_Medical_Guidance
- Peng, Y., Malin, B. A., Rousseau, J. F., Wang, Y., Xu, Z., Xu, X., Weng, C., & Bian, J. (2025). From GPT to DeepSeek: Significant gaps remain in realizing AI in healthcare. *Journal of Biomedical Informatics*, 163, 104791. <https://doi.org/10.1016/j.jbi.2025.104791>
- Rahaman, Md. S., Ahsan, M. M. T., Anjum, N., Rahman, Md. M., & Rahman, M. N. (2023). The AI Race is on! Google's Bard and Openai's Chatgpt Head to Head: An Opinion Article. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4351785>
- Sato, A., Haneda, E., Hiroshima, Y., & Narimatsu, H. (2024). Preliminary Screening for Hereditary Breast and Ovarian Cancer Using an AI Chatbot as a Genetic Counselor: Clinical Study. *Journal of Medical Internet Research*, 26(1), e48914. <https://doi.org/10.2196/48914>
- Stratton, J. (2024). An Introduction to Microsoft Copilot. In J. Stratton (Ed.), *Copilot for Microsoft 365: Harness the Power of Generative AI in the Microsoft Apps You Use Every Day* (pp. 19–35). Apress. https://doi.org/10.1007/979-8-8688-0447-2_2
- Thorat, S. A., & Jadhav, V. (2020). *A Review on Implementation Issues of Rule-based Chatbot Systems* (SSRN Scholarly Paper 3567047). Social Science Research Network. <https://doi.org/10.2139/ssrn.3567047>
- Turing, A. M. (2009). Computing Machinery and Intelligence. In R. Epstein, G. Roberts, & G. Beber (Eds.), *Parsing the Turing Test: Philosophical and Methodological Issues in the Quest for the Thinking Computer* (pp. 23–65). Springer Netherlands. https://doi.org/10.1007/978-1-4020-6710-5_3

- Vasileiou, M. V., & Maglogiannis, I. G. (2022). The Health ChatBots in Telemedicine: Intelligent Dialog System for Remote Support. *Journal of Healthcare Engineering*, 2022(1), 4876512. <https://doi.org/10.1155/2022/4876512>
- Wallace, R. S. (2009). The Anatomy of A.L.I.C.E. In R. Epstein, G. Roberts, & G. Beber (Eds.), *Parsing the Turing Test: Philosophical and Methodological Issues in the Quest for the Thinking Computer* (pp. 181–210). Springer Netherlands. https://doi.org/10.1007/978-1-4020-6710-5_13
- Wang, K. (2024). From ELIZA to ChatGPT: A brief history of chatbots and their evolution. *Applied and Computational Engineering*, 39, 57–62. <https://doi.org/10.54254/2755-2721/39/20230579>
- Weizenbaum, J. (1966). ELIZA—a computer program for the study of natural language communication between man and machine. *Communications of the ACM*, 9(1), 36–45. <https://doi.org/10.1145/365153.365168>
- Zemčík, M. (2019). A Brief History of Chatbots. *2019 International Conference on Artificial Intelligence, Control and Automation Engineering (AICAE 2019)*, 10, 14–18. <https://doi.org/10.12783/dtcse/aicae2019/31439>



BÖLÜM 5

AI IN HEALTHCARE: DESIGNING SMART CHATBOT WITH RANDOM FOREST ALGORITHM

Seda POSTALCIOĞLU¹

¹ Prof.Dr. İzmir Demokrasi University, Faculty of Engineering, Department of Computer Engineering, İzmir /Türkiye, ORCID: <https://orcid.org/0000-0002-3188-8116>, mail: seda.postalcioğlu@idu.edu.tr

1. INTRODUCTION

In recent years, artificial intelligence (AI) and machine learning (ML) have significantly contributed to advancements in healthcare by facilitating disease diagnosis, predictive analytics, and personalized treatment recommendations. One of the emerging applications in this field is the development of intelligent chatbot systems that assist users in identifying potential diseases based on reported symptoms. These chatbots leverage sophisticated ML models to process user inputs, analyze symptoms, and provide relevant information on possible illnesses and precautionary measures. The book discusses the interconnections between medicine and telecommunications engineering, highlighting the essential reliance of both fields for optimal functioning (Agarwal et al., 2023). AI Chatbot design is realized during an Epidemic by Battineni et al. (2020). Healthcare practices which would help the doctor correctly diagnose the health condition of the patient is studied (Jackins et al., 2021). In this paper, a chatbot application that can advise the patients about their physical health based upon symptom inputs (Susmita et al., 2023). Another example can be given as a study using chatbot in the healthcare field (Xu et al., 2021). Diabetes predictions using ML and Flask is studied by Raju et al, (2024).

This study aims to design a chatbot system that predicts diseases based on user-reported symptoms using Random Forest Algorithm. The system utilizes four structured datasets containing information on disease descriptions, preventive measures, symptom severity levels, and disease-associated symptoms. The dataset comprises 41 different diseases, ensuring a broad scope for the model's predictive capabilities. To enhance the accuracy and efficiency of the prediction model, missing values were handled by applying mean imputation for numerical attributes and mode imputation for categorical attributes. In this implementation, term frequency-inverse document frequency (TF-IDF) is employed to convert textual symptom data into numerical vectors, making it suitable for ML processing. The dataset is then normalized using the min-max technique to optimize the model's performance. The model is trained on 80% of the dataset while the remaining 20% is reserved for testing, ensuring a reliable evaluation of its predictive capability. The Random Forest model, consisting of decision trees, effectively classifies diseases based on the analyzed symptom data. To further enhance the interpretability of the data, t- Stochastic Neighbor Embedding (t-SNE) is used. This technique helps in understanding the high-dimensional relationships between symptoms and diseases, facilitating better insight into the dataset's structure. A web-based chatbot application is developed using the Flask web framework, enabling users to

input symptoms and receive predictions about potential diseases along with preventive recommendations. The application processes user queries in real-time, interacts with the trained model, and returns predictions through a user-friendly interface. The chatbot system is hosted locally, demonstrating its feasibility as a practical tool for assisting individuals in preliminary disease identification. The model studied has the potential to aid individuals in understanding their health conditions, prompting timely medical consultation and intervention. This paper is structured as follows: Section 2 provides method and materials, Section 3 presents the results and evaluation metrics, and Section 4 concludes with a discussion.

2. METHOD AND MATERIALS

There are 4 data sets (Patil, 2020). These data sets include explanation of diseases, precautions to be taken against diseases, severity of symptoms and symptoms of diseases, respectively. It is thought that these data sets will be useful for chatbot to be designed on diagnosis of diseases, symptoms and precautions to be taken. There are 41 different diseases in the data set. The data set was analyzed, and missing data was corrected. The aim of the study is to create a chatbot system from the model. Random Forest algorithm was used for modeling. Symptoms of the disease were converted to numerical vectors with TF-IDF (Term Frequency - Inverse Document Frequency) method. Data was normalized with min-max technique and made suitable for the model. Data set was divided into 80% training and 20% test. It was trained with a Random Forest algorithm.

2.1 TF-IDF (Term Frequency - Inverse Document Frequency)

TF-IDF is used to convert textual data into numerical form. Its applications include text mining, machine learning models, search engines, and recommendation systems. TF-IDF quantifies the importance of words within a text, aiding in tasks such as disease diagnosis by analyzing symptoms to determine their relevance to specific illnesses. It is a text mining and natural language processing (NLP) technique that evaluates the significance of words in a document. This method considers both the frequency of a term within a document (TF - Term Frequency) and its overall prevalence across the dataset (IDF - Inverse Document Frequency). The relevant calculations are presented in Equations (1- 2) (Erdoğan et al., 2022).

$$TF = \frac{\text{The number of times the term appears in the document}}{\text{The number of times the term appears in the entire document collection}} \quad (1)$$

$$IDF = \log\left(\frac{\text{Total number of documents in the corpus}}{\text{Number of documents in which the term appears}}\right)$$

(2)

The calculation of the TF-IDF value is given in Equation 3 (Erdoğan et al., 2022).

$$T(i, j) = TF(i, j) \times IDF(i)$$

(3)

In Equation 3, i represents the word index; j represents the document index. The most important reason for using TF and IDF operations together is to focus on the differences between the texts (Erdoğan et al., 2022).

2.2 Random Forest Algorithm

The Random Forest Algorithm (RF) is a supervised learning algorithm (Erdoğan et al., 2022). Fundamentally, it is a type of decision tree algorithm that can utilize multiple decision trees during the training phase. Random Forest is a machine learning (ML) ensemble method that makes predictions using multiple decision trees, making it a powerful classification and regression algorithm (Erdoğan et al., 2022). A comparison between Decision Tree and Random Forest algorithm is provided in Table 1 (Prajwala,2015).

Table 1. Decision Tree vs. Random Forest

Features	Decision Tree	Random Forest
Overfitting	More prone to overfitting	More resistant to overfitting
Error rate	Higher error rate possible	Has a lower error rate
Sensitivity	Performs well on small datasets	Performs better on large datasets
Feature Correlation	Does not consider feature correlations	Can balance correlated features

Accuracy, precision, recall, and F1-score were used for model performance evaluation. Accuracy is a widely used performance metric to assess the effectiveness of models. It measures the proportion of correct predictions out of the total number of predictions made by the model (Ceylan & Sevli, 2024). Precision indicates how many of the values predicted as positive are actually positive. Recall, on the other hand, is a metric that shows the proportion of actual positives

correctly identified by the model. The F1-score represents the harmonic mean of precision and recall values (Postalcioglu and Keşli, 2020).

2.3 t-SNE (t-Distributed Stochastic Neighbor Embedding)

t-SNE is a widely used technique for visualizing high-dimensional data in 2D or 3D, making the data easier to interpret. t-SNE is a dimensionality reduction algorithm designed to visualize high-dimensional data in lower-dimensional spaces while preserving similarities within the data. It is particularly useful for visually exploring high-dimensional datasets and making complex relationships within the data more comprehensible. t-SNE constructs a map in which the separation between digit classes is almost perfect. It performs significantly better in revealing the natural clusters within the data (Laurens & Geoffrey, 2008). The objective of t-SNE is to find a low-dimensional representation $y_i \in R^2$ of high-dimensional points $x_i \in R^d$ while preserving the pairwise similarities p_{ij} between points. The affinities are normalized to sum to 1 and are defined as shown in Equations (4-5-6) (González-Márquez et al., 2022).

$$p_{ij} = \frac{v_{ij}}{n} \quad (4)$$

$$v_{ij} = \frac{p(i|j) + p(j|i)}{2} \quad (5)$$

$$p(j|i) = \frac{v(j|i)}{\sum_{k \neq i} v(k|i)} \quad v(j|i) = \exp\left(-\frac{\|x_i - x_j\|}{2\sigma_i^2}\right) \quad (6)$$

The variance σ_i^2 of the Gaussian similarity kernel is chosen to yield a pre-specified value of the perplexity $\rho = 2^H$ of $p(j|i)$ values, where $H = -\sum_{j \neq i} p(j|i) \log_2 p(j|i)$ is the entropy (González-Márquez et al., 2022).

2.4 Desing of Chatbot

In the study, a disease prediction application was developed using the Flask web framework. When users submit a message containing specified symptoms, the system processes the message, analyzes the symptoms, and predicts the most probable disease. Additionally, it provides the user with explanations and preventive measures related to disease.

A Flask-based web application is developed and integrated with the model. The model is then packaged into a web service that provides the

prediction probability as a response when data is sent via a POST request. Flask, a popular lightweight framework for building web services in Python, is used for this purpose. Depending on the prediction, the index.html page is rendered and show the result. In this web interface, it is written which parameters can be entered in the relevant field. The basic structure of the web application is shown in figure 1.




Figure 1. The basic structure of the web application

In the chat section, symptom analysis is performed. The system extracts symptoms from the message sent by the user. The extracted symptoms are converted into a vector, which is then fed into a pre-trained Random Forest model. The model uses this vector to make a prediction, and the results are returned to the user. Additionally, an explanation and preventive measures related to the predicted disease are provided. In the Get Symptoms section, all symptoms available in the dataset are presented to the user. In the nearest hospital section, the system uses the latitude (lat) and longitude (lon) information provided by the user to search for the nearest hospital through the OpenStreetMap API. The name of the nearest hospital is then returned. Figure 2 illustrates the steps of disease prediction system,

clearly depicting the steps of the process and the sequence of actions followed.




Figure 2. Steps of disease prediction system

Figure 2 shows the steps from the interaction of people with the system to the return of results. The process starts with Start. User Input: The user enters the total of the accumulations or probabilities. Extract Symptoms: The entered text is passed over. Clean Symptoms: The symptoms are reviewed and converted to the correct format. Pre-Process Symptoms: The symptoms are converted to the format that the model can understand. Model Prediction: The model determines the disease by making a prediction. Return Results: Returns the results. Get Disease Information: Additional information about the disease is obtained. Take Precautions: Precautions are taken for the disease. API Request (Hospitals): The user is asked to query hospitals. End, the process is completed.

3. RESULTS

The model was created using the random forest algorithm. The confusion matrix of the model is shown in Figure 3. The horizontal axis shows the classes predicted by the model. Vertical axis shows the real classes. Diagonal Line, the cells that appear densely in dark blue along the diagonal in the image represent the correct predictions of the model. This shows that the model makes very successful predictions for most classes. Incorrect Predictions, the cells outside the diagonal represent the incorrect predictions of the model. It is seen in the image that such incorrect predictions are quite rare. The color scale on the right represents the density of the numbers shown in the cells. Dark blue represents high values, while light colors represent low values. In general, it can be said that this confusion matrix shows a largely successful model performance.




Figure 3. The confusion matrix

Figure 4 represents the numbers in the confusion matrix. The 41 disease types are seen in Figure 4.




Figure 4. The numbers in the confusion matrix and disease types

The performance results of the study are given in Table 2.

Table 2. The performance results

Accuracy	95.53%
Precision	95.71%
Recall	95.53%
F1-Score	95.38%

Figure 5 represents the visualization of diseases made with the t-SNE algorithm. X-axis, first dimension reduction component. Y-axis, second dimension reduction component. These axes are components that reflect the relationships of the data in high-dimensional space rather than having a specific physical meaning. These groups show different types of diseases or diseases with similar symptoms.




Figure 5. Visualization of diseases using t-SNE

Figure 6 shows the "health chatbot". Users can enter the system by selecting the symptoms they have or by manually typing them. The interface includes blue buttons that list various health symptoms such as "abdominal pain", "headache", "fatigue". After the user selects the appropriate symptoms, he/she can complete the process by pressing the "Submit" button. There is also the question "Would you like to see the nearest hospital?" The user can get guidance by pressing the "Yes" or "No" buttons. This type of health chatbot helps users by analyzing symptoms and providing information about possible health conditions or by directing them to the nearest health service. Examples of these situations are shown in the figure 7-8-9.

Health Chatbot

Select or enter your symptoms

abdominal pain

abnormal menstruation

acidity

acute liver failure

altered sensorium

anxiety

back pain

belly pain

blackheads

bladder discomfort

blisters

blood in sputum

bloody stool

blurred and distorted vision

breathlessness

brittle nails

bruising

burning micturition

chest pain

chills

cold hands and feet

coma

congestion

constipation

continuous feel of urine

continuous sneezing

cough

cramps

dark urine

dehydration

depression

diarrhoea

dischromic patches

distention of abdomen

dizziness

drying and tingling lips

enlarged thyroid

excessive hunger

extra marital contacts

family history

fast heart rate

fatigue

fluid overload

fluid overload

foul smell of urine

headache

high fever

hip joint pain

history of alcohol consumption

increased appetite

indigestion

inflammatory nails

internal itching

irregular sugar level

intubility

irritation in anus

itching

joint pain

knee pain

lack of concentration

lethargy

loss of appetite

loss of balance

loss of smell

malaise

mild fever

mood swings

movement stiffness

mucooid sputum

muscle pain

muscle wasting

muscle weakness

nausea

neck pain

nodal skin eruptions

obesity

pain behind the eyes

pain during bowel movements

pain in anal region

painful walking

palpitations

passage of gases

patches in throat

phlegm

polyuria

prognosis

prominent veins on calf

puffy face and eyes

pus filled pimples

receiving blood transfusion

receiving unsterile injections

red sore around nose

red spots over body

redness of eyes

restlessness

runny nose

rusty sputum

scouring

shivering

silver like dusting

sinus pressure

skin peeling

skin rash

slurred speech

small derts in nails

spinning movements

sputting animation

stiffneck

stomach bleeding

stomach pain

sunken eyes

sweating

swalled lymph nodes

swelling joints

swelling of stomach

swollen blood vessels

swollen extremities

swollen legs

throat irritation

toxic look (typhos)

ulcers on tongue

unsteadiness

visual disturbances

vomiting

watering from eyes

weakness in limbs

weakness of one body side

weight gain

weight loss

yellow crust ooze

yellow urine

yellowing of eyes

yellowish skin

e.g., fever, cough, headache

Submit

Processing...

Would you like to see the nearest hospital?

Yes

No

Figure 6. Health Chatbot




Figure 7. Examples from chatbot

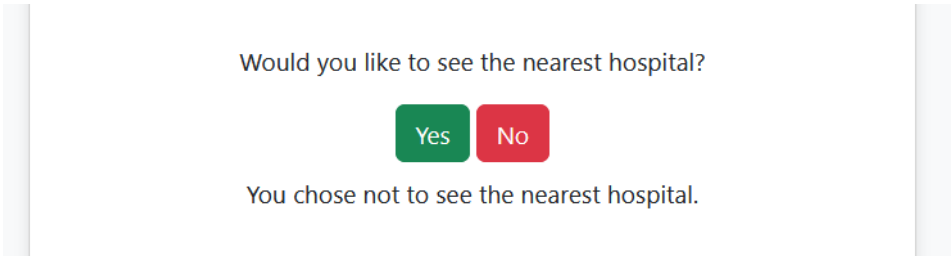


Figure 8. Examples from chatbot




Figure 9. Examples form chatbot

4. CONCLUSION

In this study, a chatbot system is developed which can predict diseases based on user-reported symptoms using the Random Forest algorithm. The implementation of TF-IDF for text vectorization and min-max normalization for data preprocessing ensured the model's efficiency and accuracy. The chatbot was integrated into a web-based application using the Flask framework, allowing users to input symptoms and receive real-time predictions along with disease explanations and preventive recommendations. Additionally, the application features a nearest hospital search functionality using OpenStreetMap API, enabling users to locate nearby healthcare facilities based on their geolocation. Experimental results demonstrated the effectiveness of the Random Forest model, as visualized through t-SNE dimensionality reduction and confusion matrix analysis. The model exhibited high accuracy, precision, recall, and F1-score, indicating its reliability in disease prediction tasks. The t-SNE visualization further revealed distinct clusters of diseases, reinforcing the model's ability to differentiate between various conditions based on symptom input. Despite its promising performance, the chatbot system has certain limitations. The dataset includes a fixed number of diseases, which may not cover all possible health conditions encountered by users. Additionally, while the model provides preliminary insights, it does not replace professional medical consultation.

REFERENCES

- Agarwal P., Khanna K., Elngar, A.A., Obaid A.J., Polkowski Z. (editorial). Artificial Intelligence for Smart Healthcare (2023), Publisher: *Springer International Publishing, Book Series : EAI/Springer Innovations in Communication and Computing*. ISBN : 978-3-031-23601-3
- Battineni, G., Chintalapudi, N., Amenta, F. (2020). AI Chatbot Design during an Epidemic like the Novel Coronavirus. *Healthcare*, 8(2), 154. <https://doi.org/10.3390/healthcare8020154>
- Ceylan, O., and Sevli, O., (2024). Machine Learning Based Student Achievement Performance Prediction Web Application, *International Journal of Engineering and Innovative Research*, 6(2), p 126-134.
- Erdoğan, İ., Güllü, M., Polat, H. (2022). End-to-End Authorship Identification Application Development Using Machine Learning Algorithms”, *El-Cezeri Journal of Science and Engineering*, , 9(4); 1303-1314
- González-Márquez, R., Berens, P. , Kobak, D.. (2022). Two-dimensional visualization of large document libraries using t-SNE. Topological, Algebraic, and Geometric Learning Workshops, *Proceedings of Machine Learning Research* 196:133-141
- Jackins, V., Vimal, S., Kaliappan, M. (2021). AI-based smart prediction of clinical disease using random forest classifier and Naive Bayes. *J Supercomput* 77, 5198–5219 <https://doi.org/10.1007/s11227-020-03481-x>
- Laurens Van der M., Geoffrey, H. (2008). Visualizing data using t-SNE. *Journal of Machine Learning Research*. 9. 2579-2605.
- Patil,P., (2020). Disease Symptom Prediction, <https://www.kaggle.com/datasets/itachi9604/disease-symptom-description/dataset/data>
- Postalcioglu S., Keşli A., (2020) .Naive Bayes Yöntemi ile Pnömoni Teşhisi, *3rd International*

Conference on Data Science and Applications (ICONDATA'20), June 25-28, Istanbul, TURKEY, ss.208-211.

Prajwala, T R,. (2015). A Comparative Study on Decision Tree and Random Forest Using R Tool.

IJARCCCE. 196-199. 10.17148/IJARCCCE.2015.4142.

Raju, N. K. K., Krishnamurthy, K., Bhagavath, B. P., Shankar, N., Janani, A. M., Avinash, N., Ray, A.,

Mahalakshmi, P. (2024). Diabetes prediction using machine learning and Flask. *Biomedical and Pharmacology Journal*, 17(2).

Susmita,V., Tarun NNG, Adhitya Kalyan SD, Dharani,D, Murthy, V.S. (2023). Chatbot For Disease

Prediction Using Machine Learning, *Journal of Emerging Technologies and Innovative Research (JETIR)* April 2023, Volume 10, Issue 4, pp. 1-9.

Xu L, Sanders L, Li K, Chow J Chatbot for Health Care and Oncology Applications Using Artificial

Intelligence and Machine Learning: *Systematic Review. JMIR Cancer* 2021;7(4): e27850 DOI: 10.2196/27850.

BÖLÜM 6

AKILLI EVLERDE AKTİVİTE TANIMA: YÖNTEMLER, TEKNOLOJİLER VE UYGULAMALARI

Fatih GENÇTÜRK¹

Serdar BİROĞUL²³

1 Araştırma Görevlisi Fatih GENÇTÜRK; Isparta Uygulamalı Bilimler Üniversitesi Teknoloji Fakültesi Bilgisayar Mühendisliği Bölümü. fatihgencturk@isparta.edu.tr ORCID No: 0000-0001-8557-5572

2 Doçent Dr. Serdar BİROĞUL; Düzce Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü. serdarbirogul@duzce.edu.tr ORCID No: 0000-0003-4966-5970

3 Naxçıvan Dövlət Universiteti Memarlıq və Mühəndislik Fakülteti Elektronika və İnformasiya Texnologiyaları. serdarbirogul@ndu.edu.az

Giriş

Akıllı ev kavramı, farklı perspektiflerden ele alınarak çeşitli şekillerde tanımlanmaktadır. Genel olarak, akıllı evler bilgi ve iletişim teknolojileri ile donatılmış, uzaktan izlenip kontrol edilebilen ve hane sakinlerinin ihtiyaçlarına yanıt veren cihazlarla donatılmış konutlar olarak ifade edilmektedir. Bununla birlikte, daha geniş bir bakış açısı, akıllı evleri yalnızca bireysel kullanıcı deneyimi çerçevesinde değil, aynı zamanda enerji sistemlerine esnek ve etkileşimli bir şekilde entegre olan yapılar olarak ele almaktadır (Gram-Hanssen ve Darby, 2018).


Farklı tanımlamalara göre akıllı evler, otomasyon cihazları ve tüketici elektroniği içeren özel konutlar olup, bu cihazların birbirine bağlanarak yeni hizmetler oluşturmaları ve sakinlere ek faydalar sağlaması beklenmektedir. Benzer şekilde, modern teknoloji ve yeni elektronik hizmetlerin entegrasyonu ile insanlara yardımcı olan yaşam alanları olarak da değerlendirilmektedir (Schiefer, 2015). Bu bakış açıları, akıllı evlerin sunduğu olanakları geniş bir yelpazede ele almakta ve teknolojinin kullanıcı odaklı yönüne vurgu yapmaktadır.

Buna ek olarak, bazı araştırmalar akıllı evleri akıllı nesnelerle donatılmış, bu nesneler arasındaki veri alışverişini sağlayan bir ev ağına sahip yapılar olarak tanımlamaktadır. Bu sistem, akıllı evin dış dünyadaki internet ağına bağlanmasını sağlayan bir konut ağ geçidi içerirken, akıllı nesneler kullanıcılarla etkileşim kurma ve onları gözlemlene yeteneğine sahiptir (Ricquebourg vd., 2006).

Akıllı ev kavramı, ilk olarak 1984 yılında Amerikan Ev İnşaatçıları Derneği (American Association of House Builders) tarafından resmi olarak tanımlanmıştır. Ancak evlerin teknolojiyle donatılma fikri daha eskiye dayanmaktadır. 1960'lı yıllarda bazı teknoloji meraklıları, kablolu evler inşa ederek bu alandaki ilk adımları atmıştır (Harper, 2003). Başlangıçta yalnızca aydınlatma ve ısıtma gibi çevresel sistemleri kontrol etmek amacıyla kullanılan akıllı ev teknolojileri, günümüzde neredeyse tüm elektrikli bileşenleri içerecek şekilde genişlemiştir. Bu sistemler, sadece cihazları açıp kapatmakla kalmayıp, evin iç ortamını ve sakinlerin aktivitelerini izleyerek belirli desenlere göre bağımsız çalışabilme yeteneğine de sahiptir (Ricquebourg vd., 2006). Akıllı evlerin temelini, yapısal sağlamlık, alan verimliliği veya çevreci uygulamalar değil, içerdikleri etkileşimli teknolojiler oluşturmaktadır. Güneş enerjisi kullanımı veya atık su geri dönüşümü gibi sürdürülebilir çözümler bu konseptin bir parçası olabilir. Ancak bir evi gerçekten akıllı yapan, otomasyon sistemleri ve bağlantılı cihazların sunduğu etkileşimdir. Buna rağmen, akıllı evlerin yaygın kullanımı günümüzde hala sınırlıdır. Yüksek maliyetler, eski konut stoğunun yaygınlığı, yetersiz ağ altyapısı ve teknoloji odaklı yaklaşımların kullanıcı deneyimi-


ne yeterince odaklanmaması, benimsenmesinin önündeki temel engeller arasında yer almaktadır (Harper, 2003).

Günümüzde, akıllı evlerin gelişimi sadece bireysel konfor ve otomasyon çözümleriyle sınırlı kalmamakta, enerji verimliliği, sürdürülebilirlik ve veri güvenliği gibi konularla birlikte değerlendirilmektedir. Şekil 1’de, akıllı evlerin sağladığı hizmetler gösterilmektedir.



Şekil 1. Akıllı ev hizmetleri (Harper, 2003)

Sensör teknolojilerindeki ilerlemeler, artan hesaplama gücü ve konut bazlı enerji tüketimindeki artış, akıllı evlerin yaygınlaşmasını hızlandırmıştır. Akıllı termostatlar, aydınlatma kontrol sistemleri, güvenlik kameraları ve diğer ev otomasyon bileşenleri, entegre bir yapı oluşturarak kullanıcı deneyimini iyileştirmektedir. Şekil 2’de, tipik bir akıllı ev sisteminin temel bileşenleri gösterilmektedir.



Şekil 2. Örnek bir akıllı ev sisteminin temel bileşenleri (Sharma vd., 2021)

Akıllı evler kullanıcılarına birçok avantaj sağlamaktadır. En büyük avantajlarından biri, enerji verimliliğini artırarak sürdürülebilir bir yaşam biçimini desteklemeleridir. Akıllı termostatlar, kullanıcı alışkanlıklarını analiz ederek iç mekân sıcaklığını otomatik olarak ayarlarken, hareket sensörlü aydınlatma sistemleri gereksiz enerji tüketimini önleyerek tasarruf sağlar. Bu tür akıllı enerji yönetim sistemleri, hem enerji kaynaklarının daha verimli kullanılmasını sağlamaktadır hem de kullanıcıların enerji maliyetlerini düşürme potansiyeline sahiptir. Bu yönüyle, akıllı evler çevre dostu bir yaşam tarzını teşvik eden önemli bir teknoloji olarak öne çıkmaktadır.

Bunun yanı sıra, akıllı evler güvenlik konusunda da önemli avantajlar sağlamaktadır. İnternet bağlantılı güvenlik kameraları, akıllı kilitler ve hareket algılayıcılar sayesinde kullanıcıların evlerini uzaktan izleyip kontrol edebilmelerine olanak tanımaktadır. Bu sistemler, olası tehditler karşısında anlık bildirimler göndererek hızlı müdahale imkânı sunar. Akıllı kapı zilleri ve kilitler, kullanıcıların evde olmasalar bile ziyaretçileri görüntüleyip kapıyı açabilmelerine olanak tanıyarak güvenlik seviyesini artırmaktadır. Bu teknolojiler, yalnızca mülk güvenliğini değil, aynı zamanda kişisel güvenliği de önemli ölçüde güçlendirmektedir.

Tüm bu avantajlarına rağmen, akıllı evlerin bazı dezavantajları da bulunmaktadır. Öncelikle, akıllı ev teknolojilerinin yüksek başlangıç maliyetleri, bu sistemlerin yaygınlaşmasını sınırlayan en önemli faktörlerden biri olmaktadır. Akıllı cihazlar, geleneksel alternatiflerine kıyasla daha pahalı olup, kurulum aşamasında profesyonel destek gerektirebilmektedir. Ayrıca bu sistemlerin internet bağlantısına bağımlı olması, ağ kesintileri durumunda işlevselliğin aksamasına ve kullanıcı deneyiminin olumsuz etkilenmesine neden olmaktadır.

Bir diğer önemli dezavantajı ise siber güvenlik riskleridir. İnternet tabanlı akıllı ev sistemleri, kötü niyetli yazılımlar ve siber saldırılara karşı savunmasız kalabilmektedir. Veri gizliliğinin korunması ve cihazların güvenli yönetimi, kullanıcılar için kritik bir öneme sahiptir. Bunun yanı sıra, farklı üreticilere ait akıllı cihazlar arasındaki uyumluluk sorunları, kullanıcıların tüm sistemleri tek bir platform üzerinden yönetmesini zorlaştırarak entegrasyon sürecinde zorluklar yaratabilmektedir. Bu faktörler, akıllı ev teknolojilerinin avantajlarına rağmen, kullanıcıların benimseme sürecini olumsuz etkileyebilecek önemli sınırlamalar arasında yer almaktadır.

Akıllı ev teknolojilerinin gelişimi, kullanıcı davranışlarının analiz edilmesine yönelik daha derinlemesine uygulamaların da önünü açmıştır. Bu bağlamda, ev içi etkileşimlerin izlenmesi ve yorumlanması süreci, akıllı evlerin temel işlevlerinden biri haline gelmiştir. Bu sürecin en kritik bileşenlerinden biri ise, bireylerin Günlük Yaşam Aktivitelerinin (Activities of Daily Living - ADL) doğru ve anlamlı biçimde tanınmasıdır.

Akıllı Evlerde Aktivite Tanıma

Aktivite tanıma, sağlık izleme, egzersiz takibi, yaşlı bakım hizmetleri ve akıllı ev sistemleri gibi birçok alanda uygulama bulmaktadır. Özellikle, yapay zeka tekniklerinin gelişimiyle, daha karmaşık ve hassas aktivite tanıma modelleri geliştirilmektedir. Aktivite tanıma, çeşitli algılama cihazlarından elde edilen verilere dayanarak, bir kişinin belirli hareketini veya eylemini tanımlamaya yönelik bir çalışma alanıdır. Bu alandaki problemler, kameradan alınan görüntülerin işlenmesi veya sensörlerden alınan sayısal değerlerin analizi gibi farklı yaklaşımlarla çözülebilmektedir. Sensör tabanlı çalışmalarda veriler, sensör barındıran cihazların kişinin üzerine yerleştirilmesiyle veya kullanıcının bulunduğu ortama yerleştirilen radar benzeri cihazlardan toplanmaktadır (Vurgun ve Kıran, 2024).

Aktivite tanıma süreçlerinde, aktiviteler genellikle basit ve karmaşık aktiviteler olarak ikiye ayrılmaktadır. Basit aktiviteler, yürüme, oturma, koşma gibi tekil aksiyonlardan oluşurken, karmaşık aktiviteler ise birden fazla basit aktivitenin bir araya gelmesiyle oluşur. Örneğin, yemek pişirme gibi karmaşık bir aktivite olup; yürüme, ayakta durma ve eğilme gibi çeşitli basit aktivitelerin birleşiminden meydana gelir. Basit aktiviteler arasında yürüme, tempolu koşma, merdiven çıkma, düşme, merdiven inme, oturma, ayakta durma, yatma, zıplama, oturarak rahatlama, yürüyen merdiven ile çıkma,

yürüyen merdiven ile inme, asansör ile çıkma, asansör ile inme, bisiklet sürme, araba sürme, telefonu tutma, gezinme, yukarı tırmanma, aşağı inme, motosiklet ile hareket etme, araba ile hareket etme ve tren ile hareket etme gibi aksiyonlar yer alır. Buna karşılık, karmaşık aktiviteler daha geniş kapsamlıdır ve yemek pişirme, temizlik yapma, ilaç kullanma, süpürme, elleri yıkama, bitki sulama, uyuma, yeme, kişisel bakım, ders çalışma, ev işi, sosyalleşme, spor, hobi, iletişim araçları kullanma, yolculuk, tahtaya yazma, kişisel bilgisayar kullanma, projektör kullanma, ders anlatma, oynama, dış fırçalama, banyo yapma, yüz yüze görüşme, görüntülü konferans, telefon konferansı, anlık mesajlaşma, alışveriş yapma ve otobüse binme gibi günlük yaşamın çeşitli yönlerini kapsayan bir dizi etkinlikten oluşur (Iskanderov ve Güvensan, 2019).

Akıllı evlerde aktivite tanıma ise, bu kavramın daha spesifik bir uygulaması olup, kullanıcıların ev içindeki davranışlarını esas alarak güvenlik, konfor ve enerji verimliliğini artırmayı hedefler. Akıllı evlerde yer alan sensörler, Nesnelerin İnterneti (Internet of Things - IoT) cihazları ve giyilebilir teknolojiler sayesinde, kullanıcıların günlük aktiviteleri izlenebilir ve tanımlanabilir hale gelmiştir. Bu sistemler, bireylerin hareket ve davranışlarını analiz ederek onların alışkanlıklarını öğrenmekte; böylece rutin faaliyetleri otomatik olarak gerçekleştirmekte, enerji tüketimini optimize etmekte ve güvenliği sağlamakta önemli avantajlar sunmaktadır. Ayrıca yaşlı ve engelli bireylerin bağımsız yaşamlarını desteklemek, acil durumları erken aşamada tespit etmek ve yaşam kalitesini artırmak gibi kritik uygulama alanlarına sahiptir. Yapay zeka ve makine öğrenmesi gibi ileri analiz teknikleriyle desteklenen akıllı ev sistemleri, bireysel ihtiyaçlara yönelik özelleştirilebilir çözümler sunarak, bu teknolojinin sağlık, güvenlik ve konfor alanlarındaki etkisini giderek daha önemli bir hale getirmektedir. Bu noktada, aktivite tanıma sistemlerinin temelini oluşturan teknolojik altyapının başında sensör sistemleri gelmektedir.

Akıllı Evlerde Kullanılan Sensör Teknolojileri

Akıllı evlerde insan aktivitelerinin tanınması amacıyla çeşitli sensörler kullanılmaktadır. Bunlardan hareket sensörleri, genellikle pasif kızılötesi (Passive Infrared - PIR) teknolojisi ile fiziksel hareketleri algılayarak, Radyo Frekansı Tanıma (Radio Frequency Identification - RFID) sensörleri ise kişilerin konumlarının belirlenmesinde rol oynar. Ancak bu sen-

sörler genellikle kişinin yalnızca belirli bir yerde bulunup bulunmadığını tespit edebilir ve aktivite tanıma için yeterli ayrıntıyı sağlamaz. Giyilebilir sensör sistemleri, özellikle akıllı saatler, bileklikler ve biyometrik ölçüm sensörleri aracılığıyla daha detaylı veri sağlayabilir. İvmeölçer ve jiroskop gibi bileşenlerle donatılan bu cihazlar, kullanıcının hareket örüntülerini ayrıntılı biçimde analiz edebilir. Buna karşın, kullanıcıların cihazları unutması, yanlış takması veya şarj etmeyi ihmal etmesi gibi durumlar, veri kalitesini düşürebilmektedir. Çevresel sensörler, ortamın sıcaklık, ışık, nem ve hava kalitesi gibi parametrelerini sürekli izleyerek aktivite bağlamına ilişkin önemli bilgiler sunar. Görüntü ve ses işleme sistemleri ise kamera ve mikrofonlardan elde edilen görsel ve işitsel veriler sayesinde daha gelişmiş bir tanıma kapasitesi sağlar. Ancak bu sistemlerin kullanımında gizlilik, etik ve yasal kaygılar nedeniyle kısıtlamalar söz konusu olabilir. Son olarak varlık ve basınç sensörleri, manyetik anahtarlarla kapı veya pencere hareketlerini algılayabilirken, yatak, koltuk ve zemin altına yerleştirilen basınç sensörleri bireyin varlığı ve pozisyonu hakkında değerli bilgiler verir. Bu sensörlerin doğru şekilde konumlandırılması kritik önem taşımaktadır; çünkü sensörlerin üzerinin örtülmesi veya başka nesneler tarafından engellenmesi durumunda veri kaybı yaşanabilir. Tüm bu sensör gruplarının uygun şekilde konumlandırılması ve birbirleriyle doğru kombinasyonlarla kullanılması, insan aktivitelerinin güvenilir ve doğru şekilde tanınmasına önemli ölçüde katkıda bulunmaktadır (Chalmers vd., 2022; Ding vd., 2011).

Akıllı Evlerde Aktivite Tanıma Yaklaşımları

Akıllı evlerde aktivite tanıma yaklaşımları, literatürde farklı kategoriler altında sınıflandırılmıştır. Chen vd. (2012), çalışmalarında aktivite tanıma yaklaşımlarını görsel algılama tabanlı yöntemler ve sensör tabanlı yöntemler olmak üzere iki ana grupta incelemiştir. Görsel algılama yaklaşımı, kamera tabanlı sistemler aracılığıyla bireylerin davranışlarını ve çevresel değişiklikleri izlemeye dayanan yöntemleri içerir. Bilgisayarla görme teknikleri kullanılarak görsel gözlemler analiz edilir. Sensör tabanlı yaklaşım ise, sensörlerden elde edilen verilerin analiz edilerek aktivitelerin tanınmasını sağlayan yöntemlerdir. Bu yöntemlerde, sensörler bireye takılabilen giyilebilir cihazlar veya ortamda bulunan nesnelere yerleştirilen yoğun algılama sistemleri şeklinde kullanılmaktadır. Giyilebilir sensörler fiziksel hareketleri belirlemede etkili olurken, yoğun algılama, insan-nesne etkileşimlerini analiz ederek aktiviteleri ortaya koymaktadır. Yoğun algılama kapsamında ise, aktivite tanıma 3 farklı yaklaşım üzerinden gerçekleştirilmektedir. Üretici (generative), ayırt edici (discriminative) ve mantıksal (logical) olarak isimlendirilen bu yaklaşımlar arasındaki temel fark, aktivitelerin ve bireyin ADL profilinin nasıl modellenip temsil edildiğidir.

Üretici yaklaşımlar olasılıksal modelleme yöntemlerini kullanarak veri uzayını ayrıntılı bir şekilde temsil ederken, ayırt edici yaklaşımlar, girdiler ile aktiviteler arasındaki ilişkileri doğrudan modellemektedir. Mantıksal yaklaşımlar ise olay hesaplaması ve kafes teorisi gibi yöntemler ile aktivite modelleme ve çıkarım süreçlerini daha sistematik ve açıklayıcı bir biçimde ele almaktadır.

Bouchabou vd. (2021), aktivite tanıma yaklaşımlarını görme tabanlı sistemler ve sensör tabanlı sistemler olmak üzere iki farklı sınıfta incelemiştir. Görme tabanlı aktivite tanıma yaklaşımlarında, insan davranışını ve çevredeki değişiklikleri izlemek için kameralar kullanılırken, sensör tabanlı yaklaşımda kişilerin aktivitesini izlemek için sensörler ve bağlı cihazlardan oluşan bir ağ kullanılmaktadır.

Literatürde yer alan birçok çalışmada, aktivite tanıma süreçleri veri odaklı (data-driven) ve bilgi odaklı (knowledge-driven) çıkarım yöntemleri olmak üzere iki temel yaklaşım çerçevesinde ele alınmaktadır. Her iki yaklaşımın da avantaj ve dezavantajları bulunmaktadır. Bu yaklaşımların dezavantajlarını ortadan kaldırmak amacıyla hibrit aktivite tanıma yaklaşımları da kullanılmaktadır (Azkune vd., 2015).

Veri Odaklı Aktivite Tanıma Yaklaşımı

Veri odaklı yöntemler, makine öğrenmesi ve veri madenciliği gibi teknikleri kullanarak mevcut veri kümelerinden aktivite modelleri üretmeyi amaçlamaktadır. Bu yaklaşımda, sensörlerden elde edilen veriler, belirli bir eğitim süreci sonucunda oluşturulan model şablonları ile karşılaştırılarak aktivite tahmini yapılmaktadır. Ancak geniş ölçekli eğitim verisine duyulan ihtiyaç nedeniyle, bu yöntemler soğuk başlangıç (cold-start) sorununa yol açabilmekte ve farklı ortam koşullarına uyum sağlamakta zorluk yaşayabilmektedir (Sukor vd., 2019). Literatürde yer alan veri odaklı aktivite tanıma yaklaşımlarından bazıları aşağıda verilmiştir.

Kızılötesi varlık sensörleri, kapı kontakları, banyo sıcaklık ve nem sensörleri ile mikrofonların yer aldığı bir ev ortamında gerçekleştirilen çalışmada aktivite tanıma işlemi gerçekleştirilmiştir. Ayrıca, giyilebilir kinematik sensörlerle postür değişiklikleri ve yürüme dönemleri izlenmiştir. Elde edilen veriler, destek vektör makineleri kullanılarak yedi farklı aktiviteyi (hijyen, tuvalet kullanımı, yemek yeme, dinlenme, uyuma, iletişim ve giyinme/soyunma) sınıflandırmak için kullanılmıştır. Bu modeli oluşturmak amacıyla, 13 genç ve sağlıklı birey üzerinde 1 saatlik deney yapılmış ve algoritmanın doğruluğu çapraz doğrulama ile test edilmiştir (Fleury vd., 2010).

Kapı sensörleri, basınca duyarlı paspaslar, yüzme sensörleri ve sıcaklık sensörlerinin kullanıldığı bir çalışmada “yemek yeme” ve “TV izleme” gibi 10 farklı aktiviteyi tanıyan bir sistem önerilmiştir. Çalışmada gizli Markow modeli kullanılmış olup, %49 ile %98 arasında değişen tanıma doğruluğu elde edilmiştir (van Kasteren vd., 2010).

Ha vd. (2015), üç eksenli ivmeölçerler ve jiroskoplar tarafından toplanan açık veri kümelerini kullanarak, Evrişimsel Sinir Ağı (Convolutional Neural Network - CNN) tabanlı bir etkinlik tanıma modeli uygulamıştır. Bu model, iki veri kümesinde sırasıyla %98,29 ve %97,92 doğruluk oranları elde etmiştir.

Derin Evrişimli Sinir Ağı (Deep Convolutional Neural Network -DCNN) ve Uzun Kısa Süreli Bellek (Long Short Term Memory - LSTM) kullanılarak, iki açık veri kümesi üzerinde bir etkinlik tanıma sınıflandırıcısı önerilmiştir. Bu veri kümeleri, yedi ataletsel ölçüm birimi ve 12 adet üç eksenli ivmeölçer ile toplanmıştır. Model, sensör verilerini sensör sinyal grafiklerine dönüştürdükten sonra 27 el hareketini (kapı açma, bulaşık yıkama, masa temizleme vb.) ve beş hareketi (ayakta durma, yürüme, oturma, uzanma, hiçbir şey yapmama) sınıflandırmıştır. Simülasyon sonuçlarına göre, iki veri kümesinden elde edilen F1 skorları sırasıyla 0,93 ve 0,958 olarak hesaplanmıştır (Ordóñez ve Roggen, 2016).

Farklı bir çalışmada, dış mekan etkinliklerini tanımak için ivmeölçer, manyetometre ve jiroskop kullanan CNN tabanlı bir model önerilmiştir. Dokuz kişinin 43 saat boyunca altı etkinliği (tren yolculuğu, araba/otobüs sürme, bisiklete binme, yürüme, koşma ve hareketsiz kalma) kaydedilmiştir. Modelin aktivite belirlemede ortalama doğruluk oranı %88,2 olarak rapor edilmiştir (Matsui vd., 2017).

Giyilebilir ataletsel sensör verilerinden elde edilen spektrogramları temel alan bir çalışmada, iki boyutlu CNN ile özellik çıkarımı yapılmış ve bu özellikler, dört temel etkinliği (ayakta durma, yürüme, merdiven inme, merdiven çıkma) sınıflandırmak üzere Destek Vektör Makinesi (Support Vector Machine - SVM) kullanılarak analiz edilmiştir. Bu model %99,75 genel doğruluk oranına ulaşmıştır (Wagner vd., 2017).

PIR hareket sensörleri ve kapı sensörleri gibi iki farklı anonim ikili sensörden elde edilen verileri kullanan bir çalışmada, DCNN tabanlı bir aktivite tanıma sınıflandırıcısı önerilmiştir. Gönüllü bekar yaşlı bir kadının sekiz ay boyunca içinde yaşadığı akıllı bir evden elde edilen veriler kullanılarak oluşturulan Aruba veri kümesi kullanılmıştır. Öncelikle, on temel günlük aktivite farklı kayan pencere boyutlarıyla segmentlere ayrılmış ve ardından ikili aktivite görüntülerine dönüştürülmüştür. Daha sonra, aktivite görüntüleri önerilen DCNN modeli için temel gerçek olarak kullanılmıştır. 10 katlı çapraz doğrulama değerlendirme sonuçlarına göre, önerilen

DCNN modeli, tüm on aktivite için 0,79 ve Evden_Çıkma ile Bulaşık_Yıkama hariç sekiz aktivite için 0,951 F1 puanı ile performans sergilemiştir (Gochoo vd., 2019).

Kişilerin davranışlarını teşhis ederek sahte uyarıları ayırt etmeyi ve normdan sapmaları tespit etmeyi hedefleyen bir çalışmada, çevresel destekli yaşam sistemi kapsamında gerçek zamanlı yaşam tarzı izleme ve tahminine yönelik bir uygulama geliştirilmiştir. Farklı ADL'nin inaktivite ve aktivitesine dayalı anomali tahmin modeli formüle edilmiştir. Çalışma, günlük yaşam aktivitesiyle ilgili refah anomalisinin tahmini için yeni bir yaklaşım göstermektedir. Yaşam tarzı ve sağlık durumu arasında önemli bir korelasyon kurulmuştur. Çalışmada, yaşam tarzının tahmin edilmesi yoluyla uzaktaki hekim veya bakıcının hastalığın semptomlarını daha iyi anlaması ve sakine yönelik sağlık iyileştirme önerileri sunması sağlanmıştır. Ayrıca bu çalışmada, sağlık endeksinde yaşamı tehdit eden bir bozulma tespit edilirse, ilgili hizmet sağlayıcısını bilgilendirebilen uyarı sistemi de entegre edilmiştir (Ghayvat vd., 2018).

Yalnız yaşayan yaşlı bireyleri izlemek ve refahlarına yönelik bir risk tespit edildiğinde alarm vermek amacıyla, denetimsiz ve düşük maliyetli sensör ağına dayalı hesaplama modeli öneren bir çalışma gerçekleştirilmiştir. Model, ZigBee kablosuz ağına bağlı PIR hareket sensörlerinden elde edilen verilere dayanmaktadır. Önerilen izleme sistemi müdahaleci değildir, herhangi bir görüntü kaydetmez ve izlenen kişiyle etkileşim gerektirmez. Aktivite keşfi için geliştirilen hesaplama modeli, kernel tahmincisi ve yerel aykırı değer faktörü hesaplaması kullanarak çalışmaktadır. Model, yalnız yaşayan ve farklı rutinlere sahip iki yaşlı gönüllüden 25 gün boyunca toplanan verilerle test edilmiştir. Sonuçlar, modelin ilgili davranışları öğrenme ve sağlık sorunlarına işaret edebilecek atipik aktiviteleri tespit etme yeteneğini göstermiştir (Soussa vd., 2021).

Bilgi Odaklı Aktivite Tanıma Yaklaşımı

Bilgi odaklı yöntemler aktivite modellerini oluşturmak için bilgi temsili tekniklerinden yararlanarak mantıksal çıkarım mekanizmaları kullanmaktadır. Bu süreçte, kural tabanlı sistemler, olgusal akıl yürütme ve ontolojik çıkarım gibi yapay zeka tekniklerinden faydalanmaktadır. Bilgi odaklı yaklaşımlar, çevresel bağlamı farklı soyutlama seviyelerinde temsil edebilmekte ve böylece daha kişiselleştirilmiş aktivite modellerinin geliştirilmesine olanak tanımaktadır. Özellikle ontolojiler, kavramlar arasındaki ilişkileri hiyerarşik ve anlamlı bir şekilde ifade etme gücüne sahiptir. Ancak bu yöntemler genellikle statik yapıda olduğundan kullanıcı davranışlarındaki değişimlere otomatik olarak uyum sağlamakta zorlanmakta ve ölçeklenebilirlik açısından bazı sınırlamalar içermektedir (Benmansour vd.,

2016). Literatürde yer alan bilgi odaklı aktivite tanıma yaklaşımlarından bazıları aşağıda verilmiştir.

Akıllı evlerin ve ADL'nin özelliklerini inceleyen bir çalışmada, bağlam ve ADL ontolojileri oluşturularak bu alanda ontoloji tabanlı modellemeye yönelik temel bir yapı oluşturulmuştur. Önerilen bilgi tabanlı yaklaşımın genel sistem mimarisi sunulmuş ve ontoloji tabanlı tanıma süreci detaylandırılmıştır. Aktivite tanımda anlamsal alt küme çıkarım algoritmalarına özel vurgu yapılmıştır. Önerilen yaklaşım, bir akıllı ev araştırma laboratuvarında uygulanan bir yazılım sistemi ile test edilmiştir. Yapılan deneylerde %94,44 ortalama aktivite tanıma oranı elde edilmiş ve her bir tanıma işlemi için ortalama işlem süresi 2,5 saniye olarak ölçülmüştür (Chen vd., 2012).

Gerçek zamanlı sensör verilerinin sürekli olarak analiz edilmesini hedefleyen bir çalışmada, etkinlik tanıma amacıyla dinamik bir veri segmentasyonu yaklaşımı geliştirilmiştir. Sensör verilerinin zamansal bilgilerini kullanarak segmentasyon penceresi boyutunu ayarlayan bu model, günlük yaşam etkinliklerinin analiziyle geliştirilmiştir. Ontoloji tabanlı geliştirilen model, prototip sistemde test edilmiştir. Deneyler, yöntemin ortalama %83'ün üzerinde tanıma doğruluğuna ulaştığını göstermiştir (Okeyo vd., 2014).

Çok kullanıcı ve eşzamanlı gerçekleşen etkinlikleri tanımaya yönelik olarak, bilgi odaklı yeni bir model olan KCAR geliştirilmiştir. Mevcut çalışmalar genellikle tek kullanıcı ve düzenlenmiş sensör verileriyle çalışırken, KCAR, gerçek dünyadaki çok kullanıcı senaryolarda sensör olaylarını anlamlandırmayı amaçlamaktadır. Model, sensör olaylarının semantik ilişkilerini analiz ederek sürekli veri akışını, her biri belirli bir etkinliği temsil eden parçalara ayırmaktadır. Potansiyel gürültüler içeren sensör dizilerinde etkinlikleri hassas şekilde ayırt edebilmek için, hiyerarşik kavramlara dayalı esnek eşleştirme sunan Pyramid Match Kernel yöntemi kullanılmıştır. Bir yıl boyunca toplanan ve 2,8 milyon sensör olayından oluşan geniş ölçekli veri kümesi üzerinde yapılan deneyler, KCAR'ın ortalama %91 doğrulukla başarılı sonuçlar verdiğini göstermiştir (Ye vd., 2015).

Akıllı evlerde aktivite tanıma sürecini daha doğru ve verimli hale getirmek amacıyla, yeni bir model önerilmiştir. Önerilen yöntem, eğitim veri kümelerinden her aktivite için ayırt edici profiller oluşturularak bu bilgileri ek özellikler çıkarmak amacıyla kullanılmaktadır. Segmentasyon sürecindeki belirsizlikler ve ilgisiz verilerin varlığı nedeniyle yaşanan doğruluk kayıplarını azaltmayı hedefleyen bu yaklaşım, sürekli akan sensör verilerinin işlenmesinde büyük veri tekniklerini de entegre etmektedir. Gerçek veri kümeleriyle yapılan deneyler, önerilen modelin geleneksel

yöntemlere kıyasla doğruluk açısından önemli bir iyileşme sağladığını ortaya koymuştur (Rawashdeh vd., 2020)

ADL tanınmasına yönelik olarak, denetimsiz bir yöntem olan POLARIS geliştirilmiştir. Geleneksel aktivite tanıma sistemleri genellikle etiketli veri kümeleri ile çalışırken, POLARIS, sensörlerden ve bağlamsal verilerden elde edilen bilgileri semantik düzeyde değerlendirerek aktiviteleri belirlemektedir. Bu sistem, ontolojik akıl yürütme mekanizması sayesinde sensör olayları ile aktiviteler arasındaki ilişkileri analiz eder ve istatistiksel çıkarımlarla ilk tahminleri üretir. Ardından, bu tahminler semantik kısıtlamalar kullanılarak daha kesin hale getirilir. Ayrıca önerilen segmentasyon algoritması sayesinde sistem, çevrimiçi aktivite tanıma yeteneğine sahiptir. Gerçek veri kümeleriyle gerçekleştirilen deneyler, POLARIS'in denetimsiz bir yaklaşım olmasına rağmen denetimli yöntemlerle karşılaştırılabilir doğrulukta sonuçlar verdiğini ve çevrimiçi tanımda da başarılı olduğunu göstermiştir (Civitarese vd., 2021).

Hibrit Aktivite Tanıma Yaklaşımı

Veri odaklı ve bilgi odaklı yaklaşımları birleştiren hibrit çıkarım sistemleri, her iki yöntemin avantajlarını bir araya getirerek daha esnek ve dinamik bir aktivite tanıma süreci sunmaktadır. Bu sayede, bilgi odaklı yaklaşımlar semantik bilginin yapılandırılmış ve paylaşılabılır bir şekilde temsil edilmesini sağlarken, veri odaklı yöntemler büyük ölçekli sensör verilerini işleyerek belirsizlikleri yönetme yeteneğini artırmaktadır. Böylece, hibrit sistemler, gerçek dünya koşullarında daha güvenilir ve uyarlanabilir aktivite tanıma modelleri geliştirilmesine katkı sağlamaktadır (Sukor vd., 2019). Literatürde yer alan hibrit aktivite tanıma yaklaşımlarından bazıları aşağıda verilmiştir.

Mevcut veri odaklı ve bilgi odaklı yaklaşımlardaki eksikliklerin (soğuk başlangıç, modelin yeniden kullanılabilirliği ve bilgi eksiklikleri gibi) giderilmesini amaçlayan çalışmada, ontoloji tabanlı semantik çıkarım ile veri madenciliği tekniklerini bir araya getiren, daha esnek ve öğrenilebilir bir model geliştirilmiştir. Metodoloji, ontolojik mühendislik ile oluşturulan “tohum” aktivite modellerinin aşamalı olarak yeni aktiviteler keşfederek ve kullanıcı profillerini güncelleyerek evrimleşmesini içermektedir. Bu üç aşamalı süreç, başlangıçta bilgi odaklı bir modelleme ile başlamakta, ardından veri akışından elde edilen sınıflandırma sonuçları analiz edilerek eksik aktiviteler belirlenmekte ve son aşamada yeni aktiviteler ve kullanıcı profilleri öğrenilerek model güncellenmektedir. Deneyler, akıllı bir yaşam destek sisteminde gerçekleştirilmiş ve öğrenme algoritmalarının etkinliği doğrulanmıştır (Chen vd., 2014).

Hibrit bir yaklaşım önerildiği farklı bir çalışmada, nesne kullanımına dayalı aktivite modellemesi gerçekleştirilmiş ve Gizli Dirichlet Ayrışımı (Latent Dirichlet Allocation - LDA) konu modelleme tekniği kullanılarak, sensör verilerinden nesne-aktivite ilişkileri çıkarılmıştır. Önerilen metodolojide, geleneksel bilgi tabanlı ve veri tabanlı yöntemlerin eksikliklerini gidermek amacıyla iki aşamalı bir model geliştirmiştir. Bunlardan ilki nesne kullanımına dayalı aktivite keşfi, LDA kullanılarak sensör verilerinden gizli aktivite temalarının çıkarılmasını sağlamıştır. Diğer aktivite ontolojisi oluşturma ve modelleme, keşfedilen nesne-aktivite ilişkilerini formel bir bilgi modeli ile yapılandırarak, mantıksal çıkarım mekanizmalarıyla aktivite tanımayı desteklemiştir. Çalışma, Kasteren ve Ordonez veri setleri üzerinde değerlendirilmiş ve önerilen yöntemin, mevcut bilgi tabanlı tekniklere kıyasla daha yüksek doğruluk oranları sağladığı gösterilmiştir (Ihianle vd., 2018).

Jia ve Chen (2020), aktivite tanıma sürecine yönelik olarak, hiyerarşik bir metodoloji sunmuştur. Önerilen sistem, düşük seviyeli hareketleri ve jestleri belirlemek için optik akış ve gizli Markov modelleri gibi makine öğrenmesi tekniklerini kullanırken, yüksek seviyeli aktiviteleri anlamlandırmak için mantıksal çıkarım ve çözümleme tabanlı otomatik akıl yürütme yöntemlerinden faydalanmaktadır. UT-Interaction ve CA-VIAR veri kümeleri üzerinde test edilen yöntem, karmaşık aktiviteleri daha yüksek doğrulukla tanımlayarak, geleneksel veri odaklı yaklaşımların karşılaştığı anlamlandırma problemini aşmayı başarmıştır. Özellikle, el sıkışma ve sarılma gibi etkileşimlerin tanınması, yalnızca örüntü tanıma ile değil, aynı zamanda mantıksal bağlamda çıkarım yapılarak gerçekleştirilmiştir.

Farklı bir çalışmada, USMART adı verilen denetimsiz öğrenme tabanlı bir aktivite tanıma yöntemi geliştirilmiştir. Metodoloji üç aşamadan oluşmaktadır. İlk aşamada ontoloji tabanlı bilgi modeli, aktiviteleri nesneler ve mekanlarla ilişkilendirmiştir. İkinci aşamada anlamsal veri segmentasyonu, sensör verilerini zamansal ve mekânsal benzerliklere göre otomatik olarak gruplanmıştır. Son olarak sıralı örüntü madenciliği ve kümeleme, aktiviteleri tanımak için tekrar eden desenleri çıkarmıştır. Çalışma, dört farklı gerçek dünya veri kümesi üzerinde test edilmiş ve %97,5 doğruluk oranına ulaşmıştır (Ye vd., 2014).

Akıllı Evlerde Aktivite Tanıma Zorlukları

Akıllı evlerde insan aktivitelerinin doğru şekilde tanınması işlemi, birçok teknik, yapısal ve kullanıcıya özgü zorlukla karşı karşıyadır. ADL bireylerin yaşam tarzına, fiziksel kapasitelerine ve alışkanlıklarına göre büyük farklılık gösterebilir. Aynı aktivite, farklı bireyler tarafından farklı

sıralamalarda ve yöntemlerle gerçekleştirilebilir. Bu çeşitlilik, aktivite tanıma sistemlerinin genellenebilirliğini zorlaştırmaktadır. Benzer şekilde, ADL'ler genellikle bir tür kalıp izlese de, eylemlerin sırası ve süresi üzerinde katı kısıtlamalar yoktur. Örneğin, yemek hazırlamak için önce ocak açılabilir ve ardından tencere yerleştirilebilir veya bunun tersi de mümkündür. Bu tür zamansal esneklik, tanıma algoritmalarının karmaşıklığını artırır ve gerçek zamanlı analizlerde yanılgılara neden olabilir (Chen vd., 2012).

Akıllı evlerde kullanılan sensörlerden elde edilen veriler sıklıkla eksik, hatalı veya gürültülü olabilmektedir. Sensör hataları, yanlış aktivite sınıflandırmalarına yol açabilir. Ayrıca, farklı sensör türlerinden gelen verilerin biçimsel ve anlamsal uyumsuzluğu, veri bütünleştirme ve yorumlamayı zorlaştırabilir (Cicirelli vd., 2016).

Gerçek yaşam ortamlarında birden fazla kişinin aynı anda farklı aktiviteler gerçekleştirmesi sık rastlanan bir durumdur. Bu durum, sensör verilerinin kime ait olduğunun belirlenmesini zorlaştırmakta ve tanıma doğruluğunu azaltmaktadır (Bouchabou vd., 2021).

Veri odaklı yöntemlerin etkin çalışabilmesi için büyük miktarda etiketlenmiş veriye ihtiyaç vardır. Ancak, aktivite verilerinin manuel etiketlenmesi zaman alıcı ve maliyetlidir. Bu da sistemlerin yaygınlaştırılmasını engellemektedir (Zolfaghari ve Keyvanpour, 2017).

Genel modeller, bireysel farklılıkları yeterince temsil edemeyebilir. Bilgi odaklı yaklaşımlar bu açığı kapatmak için geliştirilmektedir. Ancak bu sistemlerin kurulumu, uzman bilgisi gerektirir ve ölçeklenebilirlik açısından sınırlamalar taşır (Chen vd., 2012).

Kamera tabanlı sistemler gibi bazı tanıma yöntemleri, kullanıcıların mahremiyet kaygılarını artırabilir. Bu nedenle, IoT sensör tabanlı sistemlerin daha fazla benimsenmesi söz konusu olsa da, veri paylaşımı konusundaki hassasiyet devam etmektedir (Bouchabou vd., 2021).

SONUÇ

Akıllı evler, sadece konfor ve otomasyon sağlamakla kalmayıp, kullanıcıların günlük yaşam aktivitelerini anlamaya ve desteklemeye yönelik gelişmiş teknolojileriyle ön plana çıkmaktadır. Bu doğrultuda, aktivite tanıma sistemleri; sağlık hizmetlerinden güvenliğe, enerji verimliliğinden yaşam kalitesinin artırılmasına kadar pek çok alanda önemli katkılar sunmaktadır. Çalışmada, akıllı evlerde aktivite tanımaya yönelik kullanılan sensör teknolojileri, yaklaşım türleri ve bu süreçte karşılaşılan temel zorluklar sistematik biçimde ele alınmıştır.

Sensör tabanlı veri toplama sistemlerinin gelişmesiyle birlikte, veri odaklı ve bilgi odaklı yaklaşımların etkinliği artmıştır. Ancak her iki yöntemin sınırlılıkları, hibrit yaklaşımların gerekliliğini ortaya koymuştur. Veri odaklı modeller yüksek doğruluk oranları sunarken, bağlamsal esneklik konusunda yetersiz kalabilmekte; bilgi odaklı sistemler ise kavramsal temsilde güçlü olsalar da dinamik değişimlere adapte olmakta zorluk yaşamaktadır. Bu iki yaklaşımı bir araya getiren hibrit sistemler ise, aktivite tanımda daha güvenilir ve esnek çözümler sunmakta, özellikle gerçek dünya senaryolarında etkin performans göstermektedir.

Bununla birlikte, çok kullanıcı senaryolar, sensör verilerindeki belirsizlik, veri etiketleme süreçlerinin zorluğu, kullanıcı mahremiyeti ve sistemlerin ölçeklenebilirliği gibi unsurlar, aktivite tanımanın önündeki temel engeller olarak varlığını sürdürmektedir. Tüm bu değerlendirmeler doğrultusunda, gelecekteki çalışmaların kullanıcı odaklı, özelleştirilebilir ve etik kaygıları gözeten sistemler geliştirmeye odaklanması, akıllı ev teknolojilerinin daha geniş kitlelerce benimsenmesini kolaylaştıracaktır.

Kaynaklar

- Azkune, G., Almeida, A., López-de-Ipiña, D., & Chen, L. (2015). Extending knowledge-driven activity models through data-driven learning techniques. *Expert Systems with Applications*, 42(6), 3115-3128. <https://doi.org/10.1016/j.eswa.2014.11.063>
- Benmansour, A., Bouchachia, A., & Feham, M. (2016). Multioccupant Activity Recognition in Pervasive Smart Home Environments. *ACM Computing Surveys*, 48(3), 1-36. <https://doi.org/10.1145/2835372>
- Bouchabou, D., Nguyen, S. M., Lohr, C., LeDuc, B., & Kanellos, I. (2021). A Survey of Human Activity Recognition in Smart Homes Based on IoT Sensors Algorithms: Taxonomies, Challenges, and Opportunities with Deep Learning. *Sensors*, 21(18), Article 18. <https://doi.org/10.3390/s21186037>
- Chalmers, C., Fergus, P., Montanez, C. A. C., Sikdar, S., Ball, F., & Kendall, B. (2022). Detecting Activities of Daily Living and Routine Behaviours in Dementia Patients Living Alone Using Smart Meter Load Disaggregation. *IEEE Transactions on Emerging Topics in Computing*, 10(1), 157-169. *IEEE Transactions on Emerging Topics in Computing*. <https://doi.org/10.1109/TETC.2020.2993177>
- Chen, L., Nugent, C. D., & Wang, H. (2012). A Knowledge-Driven Approach to Activity Recognition in Smart Homes. *IEEE Transactions on Knowledge and Data Engineering*, 24(6), 961-974. *IEEE Transactions on Knowledge and Data Engineering*. <https://doi.org/10.1109/TKDE.2011.51>
- Chen, L., Nugent, C., & Okeyo, G. (2014). An Ontology-Based Hybrid Approach to Activity Modeling for Smart Homes. *IEEE Transactions on Human-Machine Systems*, 44(1), 92-105. *IEEE Transactions on Human-Machine Systems*. <https://doi.org/10.1109/THMS.2013.2293714>
- Cicirelli, F., Fortino, G., Giordano, A., Guerrieri, A., Spezzano, G., & Vinci, A. (2016). On the Design of Smart Homes: A Framework for Activity Recognition in Home Environment. *Journal of Medical Systems*, 40(9), 200. <https://doi.org/10.1007/s10916-016-0549-7>
- Civitaresse, G., Szttyler, T., Riboni, D., Bettini, C., & Stuckenschmidt, H. (2021). POLARIS: Probabilistic and Ontological Activity Recognition in Smart-Homes. *IEEE Transactions on Knowledge and Data Engineering*, 33(1), 209-223. *IEEE Transactions on Knowledge and Data Engineering*. <https://doi.org/10.1109/TKDE.2019.2930050>
- Ding, D., Cooper, R. A., Pasquina, P. F., & Fici-Pasquina, L. (2011). Sensor technology for smart homes. *Maturitas*, 69(2), 131-136. <https://doi.org/10.1016/j.maturitas.2011.03.016>
- Fleury, A., Vacher, M., & Noury, N. (2010). SVM-Based Multimodal Classification of Activities of Daily Living in Health Smart Homes: Sensors, Algorithms, and First Experimental Results. *IEEE Transactions on Information Tech-*

- nology in Biomedicine*, 14(2), 274-283. IEEE Transactions on Information Technology in Biomedicine. <https://doi.org/10.1109/TITB.2009.2037317>
- Ghayvat, H., Mukhopadhyay, S., Shenjie, B., Chouhan, A., & Chen, W. (2018). Smart home based ambient assisted living: Recognition of anomaly in the activity of daily living for an elderly living alone. *2018 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, 1-5. <https://doi.org/10.1109/I2MTC.2018.8409885>
- Gochoo, M., Tan, T.-H., Liu, S.-H., Jean, F.-R., Alnajjar, F. S., & Huang, S.-C. (2019). Unobtrusive Activity Recognition of Elderly People Living Alone Using Anonymous Binary Sensors and DCNN. *IEEE Journal of Biomedical and Health Informatics*, 23(2), 693-702. IEEE Journal of Biomedical and Health Informatics. <https://doi.org/10.1109/JBHI.2018.2833618>
- Gram-Hanssen, K., & Darby, S. J. (2018). "Home is where the smart is"? Evaluating smart home research and approaches against the concept of home. *Energy Research & Social Science*, 37, 94-101. <https://doi.org/10.1016/j.erss.2017.09.037>
- Ha, S., Yun, J.-M., & Choi, S. (2015). Multi-modal Convolutional Neural Networks for Activity Recognition. *2015 IEEE International Conference on Systems, Man, and Cybernetics*, 3017-3022. <https://doi.org/10.1109/SMC.2015.525>
- Harper, R. (2003). Inside the Smart Home: Ideas, Possibilities and Methods. İçinde R. Harper (Ed.), *Inside the Smart Home* (ss. 1-13). Springer. https://doi.org/10.1007/1-85233-854-7_1
- Ihianle, I. K., Naeem, U., Islam, S., & Tawil, A.-R. (2018). A Hybrid Approach to Recognising Activities of Daily Living from Object Use in the Home Environment. *Informatics*, 5(1), Article 1. <https://doi.org/10.3390/informatics5010006>
- Iskanderov, J., & Güvensan, M. A. (2019). Akıllı telefon ve giyilebilir cihazlarla aktivite tanıma: Klasik yaklaşımlar, yeni çözümler. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 25(2), Article 2.
- Jia, H., & Chen, S. (2020). Integrated data and knowledge driven methodology for human activity recognition. *Information Sciences*, 536, 409-430. <https://doi.org/10.1016/j.ins.2020.03.081>
- Matsui, S., Inoue, N., Akagi, Y., Nagino, G., & Shinoda, K. (2017). User adaptation of convolutional neural network for human activity recognition. *2017 25th European Signal Processing Conference (EUSIPCO)*, 753-757. <https://doi.org/10.23919/EUSIPCO.2017.8081308>
- Okeyo, G., Chen, L., Wang, H., & Sterritt, R. (2014). Dynamic sensor data segmentation for real-time knowledge-driven activity recognition. *Pervasive and Mobile Computing*, 10, 155-172. <https://doi.org/10.1016/j.pmcj.2012.11.004>

- Ordóñez, F. J., & Roggen, D. (2016). Deep Convolutional and LSTM Recurrent Neural Networks for Multimodal Wearable Activity Recognition. *Sensors*, 16(1), Article 1. <https://doi.org/10.3390/s16010115>
- Rawashdeh, M., Al Zamil, M. GH., Samarah, S., Hossain, M. S., & Muhammad, G. (2020). A knowledge-driven approach for activity recognition in smart homes based on activity profiling. *Future Generation Computer Systems*, 107, 924-941. <https://doi.org/10.1016/j.future.2017.10.031>
- Ricquebourg, V., Menga, D., Durand, D., Marhic, B., Delahoche, L., & Loge, C. (2006). The Smart Home Concept: Our immediate future. *2006 1ST IEEE International Conference on E-Learning in Industrial Electronics*, 23-28. <https://doi.org/10.1109/ICELIE.2006.347206>
- Schiefer, M. (2015). Smart Home Definition and Security Threats. *2015 Ninth International Conference on IT Security Incident Management & IT Forensics*, 114-118. <https://doi.org/10.1109/IMF.2015.17>
- Sharma, A., Jupalle, H., Naddikatu, R. R., Velu, A., & Whig, P. (2021). AI Application for the Sustainable Development to Reduce Carbon Footprint. *2021 5th International Conference on Information Systems and Computer Networks (ISCON)*, 1-4. <https://doi.org/10.1109/ISCON52037.2021.9702511>
- Soussa, M. R. B., de Senna, V., da Silva, V. L., & Soares, C. L. (2021). Modeling elderly behavioral patterns in single-person households. *Multimedia Tools and Applications*, 80(14), 22097-22120. <https://doi.org/10.1007/s11042-021-10635-3>
- Sukor, A. S. A., Zakaria, A., Rahim, N. A., Kamarudin, L. M., Setchi, R., & Nishizaki, H. (2019). A hybrid approach of knowledge-driven and data-driven reasoning for activity recognition in smart homes. *Journal of Intelligent & Fuzzy Systems*, 36(5), 4177-4188. <https://doi.org/10.3233/JIFS-169976>
- van Kasteren, T. L. M., Englebiene, G., & Kröse, B. J. A. (2010). An activity monitoring system for elderly care using generative and discriminative models. *Personal and Ubiquitous Computing*, 14(6), 489-498. <https://doi.org/10.1007/s00779-009-0277-9>
- Vurgun, Y., & Kıran, M. S. (2024). İnsan aktivite tanınması için yeni bir veri kümesi ve derin öğrenme modelleri ile sınıflandırılması. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 40(1), Article 1. <https://doi.org/10.17341/gazimmfd.1325926>
- Wagner, D., Kalischewski, K., Velten, J., & Kummert, A. (2017). Activity recognition using inertial sensors and a 2-D convolutional neural network. *2017 10th International Workshop on Multidimensional (nD) Systems (NDS)*, 1-6. <https://doi.org/10.1109/NDS.2017.8070615>
- Ye, J., Stevenson, G., & Dobson, S. (2014). USMART: An Unsupervised Semantic Mining Activity Recognition Technique. *ACM Trans. Interact. Intell. Syst.*, 4(4), 16:1-16:27. <https://doi.org/10.1145/2662870>

- Ye, J., Stevenson, G., & Dobson, S. (2015). KCAR: A knowledge-driven approach for concurrent activity recognition. *Pervasive and Mobile Computing*, 19, 47-70. <https://doi.org/10.1016/j.pmcj.2014.02.003>
- Zolfaghari, S., & Keyvanpour, M. (2017). *Human Activity Recognition in Smart Homes: Research Challenges Classification*. <https://doi.org/10.13140/RG.2.2.12994.12486>

BÖLÜM 7

ARTIFICIAL INTELLIGENCE AND EXPLAINABILITY IN HEALTH: POTENTIAL AND CHALLENGES

Hayri İNCEKARA¹

¹ Dr, Republic of Türkiye Ministry of National Education, Konya, Türkiye. hayrincekara@gmail.com, ORCID ID: 0000-0002-0898-3422

1. INTRODUCTION

The healthcare sector has been undergoing a major transformation in recent years due to technological developments. Artificial Intelligence (AI) is at the center of this transformation and enables healthcare services to become more efficient, faster and more personalized. AI, which has a major impact on the quality, accessibility and cost-effectiveness of healthcare services, is used in a wide range of areas, from earlier diagnosis of diseases to treatment planning, from optimizing treatment processes to patient care (Saraswat et al., 2022).

Healthcare services are increasingly transforming from traditional methods of diagnosis, treatment, and care to a more digital and technology-focused structure. AI has pioneered this transformation, especially through advanced algorithms such as Machine Learning (ML) and Deep Learning (DL) (Dunjko & Briegel, 2018; Shrestha & Mahmood, 2019). Advanced AI applications allow healthcare professionals to make faster and more accurate decisions thanks to their ability to quickly analyze large amounts of data and identify complex structures (Mohanta, Das, & Patnaik, 2019). For example, AI used in image processing and analysis is an important tool for doctors and specialists for early detection of diseases (Nazar, Alam, Yafi, & Su'ud, 2021). Similarly, analyses performed on patients' genetic data allow the development of personalized treatment approaches. However, the success of AI in the healthcare field is not only based on the accuracy of algorithms. It is also vital that AI's workings are understandable and reliable in order to improve the quality of healthcare (Saraswat et al., 2022). The biggest challenge here is that AI algorithms are often based on "black box" systems (Preece, Harborne, Braines, Tomsett, & Chakraborty, 2018). That is, these algorithms do not provide sufficient explanations to users about how they make decisions (Mankodiya, Jadav, Gupta, Tanwar, Hong, et al., 2022). This can prevent healthcare professionals, patients, or other stakeholders from trusting AI's recommendations. Therefore, many studies are being carried out to increase trust in the use of AI models (Gunning & Aha, 2019; Mistry et al., 2021; Moradi & Samwald, 2022; Kwong et al., 2022; Speith, 2022; Oprescu et al., 2022). At this point, Explainable Artificial Intelligence (XAI) aims to build trust for healthcare professionals and patients by making these systems more understandable and transparent (Xu et al., 2019).

Explainable AI aims to present the results of complex AI models in a form that is understandable to humans (Carvalho, Pereira, & Cardoso, 2019). XAI is a technology that has found application in healthcare in particular, where it is critical for users to understand the decision processes of the AI (Carvalho et al., 2019). For example, a doctor may want to know what factors an AI model relies on to diagnose cancer. Even if the

AI correctly diagnoses the disease, it is difficult to trust the result without knowing how and why it was reached. By providing these explanations, XAI helps users understand the logic of AI systems and ultimately make more confident decisions (Tjoa & Guan, 2020; Doshi-Velez & Kim, 2017). In the healthcare sector, XAI not only gains the trust of healthcare professionals, but also strengthens the patient-doctor relationship. When patients are offered a treatment plan or diagnosis, they want to see that it is scientifically based and its accuracy can be explained in an understandable way (Chaddad, Peng, Xu, & Bouridane, 2023). This can increase patient compliance with treatment and improve the quality of healthcare.

AI contributes to making the healthcare system more efficient and healthcare services faster (Furkan, İşbay, & Özlem, 2023). Operations such as disease detection, treatment management, and patient follow-up performed with AI will increase the efficiency of healthcare professionals and allow for more accurate treatment decisions. However, realizing this potential depends on fulfilling the requirements of explainability and transparency (Doshi-Velez & Kim, 2017). At every stage of the decisions made by AI, healthcare professionals need to understand how patient data, biological, and genetic analyses are used. At this point, the combined use of AI and XAI will provide a solution to these problems. However, there are some challenges and obstacles to this transformation. Data quality, data access, ethical issues, and legal regulations are important obstacles that make it difficult to integrate AI in healthcare (Hulsen, 2023). In addition, a comprehensive training and adaptation process is needed for healthcare professionals to use AI correctly. The explainability of AI systems will facilitate these training processes and accelerate the adaptation of healthcare professionals to new technologies (Saraswat et al., 2022; Pawar, O'shea, Rea, & O'reilly, 2020; Loh et al., 2022).

In the future, developments in the field of AI and explainability in healthcare will provide significant benefits for both healthcare professionals and patients. A good design of the interaction between AI and explainability in the healthcare sector will contribute to the formation of a safe, effective and efficient healthcare system.

In this study, the impact of AI applications in the healthcare sector and the importance of explainable artificial intelligence will be comprehensively discussed. First, an overview of AI application areas in healthcare will be presented and how these technologies are used in areas such as medical diagnosis, treatment planning and disease prediction will be examined. Then, the concept of XAI and why transparency and reliability in this area are of critical importance in healthcare will be discussed. The potential benefits of XAI in the healthcare sector will be explained through elements such as increasing patient trust and improving clinical decision

processes. However, the challenges and obstacles faced by this technology, especially data privacy, ethical issues and technical limitations, will also be discussed. Finally, the future of XAI and potential solutions in this area will be discussed, and suggestions will be made on how to make healthcare services more efficient and reliable in order to increase their quality.

2. AREAS OF ARTIFICIAL INTELLIGENCE APPLICATION IN HEALTH

In recent years, AI has come to the forefront with its potential to provide effectiveness, accuracy, and efficiency in the healthcare sector (Kaplan, Çakar, & Bingöl, 2024). AI in healthcare offers great potential in many areas such as accelerating treatment processes, increasing accuracy, improving patient care, and optimizing clinical efficiency (Shaban-Nejad, Michalowski, & Buckeridge, 2020). Proper integration of these technologies into existing systems can increase efficiency in the healthcare sector and make healthcare services more personalized. AI is effectively used in many areas such as healthcare diagnosis and prognosis, personalized medicine and treatment planning, clinical decision support systems, health monitoring, medication management, and health management (Koski & Murphy, 2021; Akalın & Veranyurt, 2021).

2.1. Diagnosis and Identification

AI makes significant contributions to early diagnosis of diseases and accurate diagnoses. AI is widely used in diagnosis and identification by performing in-depth analysis on medical imaging, genetic analysis and clinical data thanks to its ability to analyze big data quickly. Early diagnosis of diseases increases the chance of treatment.

AI can diagnose potential diseases faster and more accurately by analyzing radiological images. For example, the AI algorithm developed by Google Health increases the accuracy rate of radiologists in breast cancer diagnosis (McKinney et al., 2020). AI can detect cancerous cells by analyzing lesions on the skin with DL algorithms. Such systems help healthcare professionals detect small abnormalities that dermatologists may miss (Esteve et al., 2017; Demir, 2021). AI is also effectively used in the detection of skin cancer, which is a very common disease today. With AI algorithms integrated into imaging systems, benign tumors can be filtered and suspicious tumors can be detected (Mar & Soyer, 2018). Thanks to these developed technologies, skin cancer diseases can be diagnosed early and the correct treatment can be applied. AI is also used in the early diagnosis of diseases such as eye diseases, diabetic retinopathy and glaucoma. By analyzing the images taken during eye examinations with AI, these disea-

ses can be detected quickly and the necessary treatment can be applied as soon as possible (Han, 2022).

2.2. Personalized Medicine and Treatment Planning

AI can help create personalized treatment plans for patients by analyzing genetic information and personal health data. Clinical decision support systems can analyze patients' medical history and contribute to recommending the most appropriate treatment plan (Akalın & Veranyurt, 2021). Personalized treatment recommendations can be provided by analyzing genetic and biological profiles in cancer treatment. In addition, it can be predicted which treatment method will be more effective for which patient, thus making the treatment process more efficient. IBM Watson for Oncology, which uses big data and machine learning to customize cancer treatment, is a prominent example in this field (Uzun, 2020). Dynamic management of treatment processes with AI can facilitate patient follow-up and rapid response to changes in the treatment process (Tekkeşin, 2019).

2.3. Drug Development Applications

AI plays a major role in the development of new drugs. Data obtained from different sources can be quickly analyzed with AI, helping to predict how a drug may affect cells and tissues. Technologies that incorporate AI can benefit from AI in various stages of drug development, such as identifying and validating drug targets, designing new drugs, repurposing drugs, and improving R&D. They can also accelerate the drug discovery process by predicting which patients drugs will be more effective on (Mak & Pichika, 2019).

2.4. Patient Monitoring and Management

AI can continuously monitor and analyze patients' health data and instantly report changes in the treatment process to doctors. In this way, patients' responses to treatment can be accurately monitored and treatment protocols can be quickly updated when necessary (Obermeyer, Powers, Vogeli, & Mullainathan, 2019). In addition, continuous patient monitoring is possible today with wearable devices and IoT technologies. AI can analyze the data from these devices to detect abnormal conditions early and provide treatment recommendations. For example, for patients with chronic diseases such as diabetes and hypertension, AI-supported systems analyze health data (blood sugar, blood pressure, etc.) to monitor patients' response to treatment and warn the patient when an unusual condition is detected. AI-supported devices are also used to monitor the health status

of elderly individuals. With these devices, elderly individuals' medication intake can be tracked, emergency situations such as falls can be detected, and their general health status can be monitored (Topol, 2019).

2.5. Clinical Decision Support Systems

AI-supported decision support systems are used to support physicians' clinical decisions. These systems analyze patients' medical history, symptoms, and test results, and present potential diseases and treatment options to physicians. For example, by integrating AI systems with patient monitoring devices in intensive care units, they can provide early warnings for conditions such as heart attack, stroke, or respiratory failure. In addition, AI provides treatment recommendations to physicians by considering the clinical conditions and treatment history of patients. In this way, it can help physicians make accurate and fast decisions, especially in the treatment of complex diseases (Rajkomar, Dean, & Kohane, 2019; Shortliffe & Cimino, 2014).

2.6. Artificial Intelligence-Supported Psychiatry and Mental Health

AI can undertake important functions in the diagnosis and treatment of mental illnesses, such as analyzing the behavior of patients and providing guidance in the treatment process. AI can determine the mood and psychological state of individuals by analyzing speech. This personalizes the therapy process and contributes to the patient's recovery process. Mental conditions such as depression, anxiety, and stress can be monitored with AI applications. Applications can provide early warnings about mental health by monitoring individuals' social media interactions and digital behaviors (Graham et al., 2019).

2.7. Use of Artificial Intelligence in Medical Education

With AI, medical students will be able to communicate with e-patients and encounter a greater number and variety of disease scenarios and learn to cope with them. In addition, medical education in the world can become more standardized with AI systems. With the use of AI systems in medical education, the burden on educators will be lightened, and students will be able to develop themselves in advance and gain experience with situations they may encounter in real life thanks to AI systems (Masters, 2019).

3. EXPLAINABLE ARTIFICIAL INTELLIGENCE IN HEALTH

For AI to be used effectively in the healthcare sector, it is not enough for systems to only provide accurate results; it should also be understandable how and why these results were obtained. For example, if an artificial intelligence model diagnoses a patient with cancer, the doctor wants to understand what data this decision is based on and what factors are effective. The complex structure of AI systems often makes it difficult to explain these decisions, which leads to a decrease in user trust (Miller, 2019). XAI is an effort to make the decision-making processes of AI systems transparent in a way that people can understand and evaluate (Carvalho et al., 2019; Alpkoçak, 2024).

The explainability of AI allows healthcare professionals and patients to better understand and trust the decisions of AI systems. AI often makes its decisions in a difficult-to-understand way, referred to as a “black box” (Von Eschenbach, 2021). This leads to healthcare professionals and patients having difficulty understanding how the model works. XAI opens up this “black box”, making healthcare decisions more transparent (Saraswat et al., 2022). If a patient can understand why a treatment plan suggested by an AI-powered system is recommended, their trust in the treatment can increase, resulting in higher adherence rates (Carvalho et al., 2019).

XAI in healthcare is also a critical tool for patient safety. With XAI, healthcare professionals can better understand what data algorithms are using and what factors are influencing decisions, allowing them to detect potential errors early on. Additionally, patients can become anxious when they don’t understand how these systems work. XAI provides transparency to help patients feel more confident in their healthcare decisions.

XAI can be used in medical imaging systems to help doctors better understand diagnoses made by an AI algorithm. For example, a XAI-powered system could detect abnormalities in a patient’s X-ray image and explain to doctors why it interprets these findings that way. This allows doctors to reason about decisions rather than relying solely on algorithms (Rajpurkar et al., 2018).

The ability of AI to provide personalized treatment recommendations based on the genetic and clinical characteristics of individual patients is a major advancement in healthcare. However, if such personalized recommendations are explainable, it will allow doctors to discuss recommended treatments more effectively with patients.

When AI is used to monitor patients’ health status and predict future health risks, the role of XAI becomes critical. While AI can assess a pa-

tient's risk of developing a chronic disease such as heart disease or diabetes, XAI can explain what data the algorithm is analyzing and why the risk estimate is being made that way, allowing healthcare professionals to base their decisions on more solid grounds.

4. EXPLAINABLE ARTIFICIAL INTELLIGENCE IN HEALTH: POTENTIAL BENEFITS AND IMPACTS

The proliferation of AI systems in the healthcare sector can provide major improvements in medical processes. However, the effective use and reliability of these systems is directly related not only to the accuracy of their results, but also to the transparency of decision-making processes (Pawar, O'Shea, Rea, & O'Reilly, 2020). This is where XAI comes into play, allowing healthcare professionals and patients to understand how AI systems work and why they reach certain results (Tjoa & Guan, 2020; Saraswat et al., 2022). The integration of AI and XAI systems can increase the efficiency of the healthcare sector, improve patient care, and strengthen the decision-making processes of healthcare professionals. In this context, XAI has the potential to overcome the barriers to the adoption of AI systems in the healthcare field. The potential benefits of XAI in healthcare can be listed as follows:

4.1. Increasing Patient and Physician Confidence

For healthcare providers, patients, and policymakers to trust AI systems, it is necessary to understand how they work. XAI ensures that the outputs of AI systems are understandable and explainable. This increases the trust that healthcare professionals and patients have in AI systems. Patients, in particular, want to understand how decisions are made and what data is used before relying on a machine to make a medical decision. When healthcare professionals have a clear understanding of the treatment plans or diagnoses that AI suggests, they can trust those recommendations more and provide more accurate information to their patients. This increased trust can increase treatment adherence and overall patient satisfaction (Ribeiro, Singh, & Guestrin, 2016; Arrieta et al., 2020).

4.2. Transparency and Accountability in Medical Decision-Making Processes

XAI provides healthcare professionals with transparent and accountable systems that can explain their decisions. Understanding the reasons behind AI's recommendations, especially in clinical settings where complex situations are encountered, allows healthcare professionals to base their

decisions on a more solid basis. In this way, when wrong or incomplete decisions are made, responsibility can be determined more clearly. At the same time, explainability can help patients have more trust in their healthcare providers (Pawar, O'shea, et al., 2020; Ehsan, Liao, Muller, Riedl, & Weisz, 2021).

4.3. Early Diagnosis and Personalized Treatment Methods

XAI offers significant advantages in early disease detection. AI systems can detect potential health problems at an early stage by analyzing large data sets. Explainability helps understand how and why these early warnings occur, thus increasing the accuracy and reliability of clinical decision support systems. In addition, XAI systems play a major role in creating personalized treatment plans. These systems recommend the most appropriate treatment methods based on the genetic and medical history of each patient. Thanks to explainability, healthcare professionals understand the logic behind these recommendations and can make the treatment process more efficient (Esteva et al., 2017).

4.4. Speed and Efficiency

XAI can accelerate healthcare processes. AI can perform rapid analyses on large data sets, allowing doctors to access accurate information without wasting time. Explainability helps healthcare professionals understand the logic behind these analyses, allowing them to make faster and more informed decisions. Furthermore, the efficiency of these systems allows healthcare professionals to work more efficiently by automating repetitive tasks. Healthcare professionals can rely on AI systems for routine tasks and focus on more complex patient care. This allows healthcare professionals to serve more patients, speeding up the treatment process and increasing the overall efficiency of the healthcare system (Esteva et al., 2017).

4.5. Error Reduction

XAI also plays a key role in reducing medical errors. Understanding how AI systems make decisions allows healthcare professionals to more easily detect erroneous results. For example, if an AI model makes a wrong diagnosis, healthcare professionals can review the data the model used to make that decision and correct the errors. Explainability helps to detect and prevent such errors more quickly, leading to safer and more accurate decisions in healthcare (Lundberg & Lee, 2017).

4.6. Education and Educated Decision Making Processes

XAI also offers significant opportunities for medical education. Students and newly graduated healthcare professionals can benefit from these systems to understand how AI systems work and how decisions are made. In this way, medical students and physicians in specialty training can better learn clinical decision-making processes by interacting with real-world data. At the same time, experienced physicians can review their own decisions and gain a different perspective when faced with complex situations with XAI tools (Caruana et al., 2015).

4.7. Reduction of Legal and Ethical Problems

The decision-making processes of AI systems are usually based on a large amount of data. This data may contain highly sensitive information that affects the health status of individuals. XAI transparently reveals how this data is used and the criteria by which decisions are made. This transparency provides a significant advantage in terms of data security and privacy. For example, if a diagnosis is incorrect, XAI shows what data the decision was based on, allowing you to identify at what stage the error occurred. In addition, when ethical issues are encountered, explainability allows systems to audit their decision-making processes and intervene when necessary. This ensures that AI systems operate fairly and within the framework of ethical rules (Mankodiya, Jadav, Gupta, Tanwar, Alharbi, et al., 2022).

4.8. Continuous Improvement of Artificial Intelligence Systems

XAI enables healthcare professionals to optimize AI systems more effectively by showing them how the system works and which parameters affect outcomes. Analyzing the AI model's decisions helps identify potential failure points or areas for improvement, allowing for continuous improvement of AI systems used in healthcare (Lundberg & Lee, 2017).

5. EXPLAINABLE ARTIFICIAL INTELLIGENCE IN HEALTH: KEY CHALLENGES AND OBSTACLES

While XAI offers significant benefits in the healthcare industry, it also faces several challenges and obstacles. These challenges range from technological to ethical, legal, and operational aspects. Some of the key challenges and obstacles that XAI faces in healthcare are:

5.1. Data Privacy and Security Concerns

Health data is extremely sensitive information, and the use of this data is strictly controlled, especially in AI applications. A large amount of data is required for AI systems to operate accurately and explainably. However, data privacy and security concerns arise during the collection and analysis of this data (Tramèr, Zhang, Juels, Reiter, & Ristenpart, 2016). Although explainability clearly shows what data the model works with and what conclusions it reaches, disclosing this data may conflict with the obligation to protect personal health information. In addition, the quality and security of the data used in training the model can directly affect the accuracy of the results (Saraswat et al., 2022).

5.2. Complexity of the Model

Achieving explainability of AI can be quite challenging, especially considering the complexity of DL algorithms. These models can process large data sets and make predictions with high accuracy, but they are also “black box” systems where it is very difficult to understand how their outputs are obtained. Although DL models provide high accuracy, explaining decision-making processes becomes difficult, especially when the network structures and interactions of the parameters are very complex. This creates technical difficulties in achieving explainability (Sarkar, 2022).

5.3. Education and Adaptation

Although XAI provides significant benefits for healthcare professionals, doctors and other healthcare professionals need to have sufficient knowledge to use these systems effectively. Lack of training on how XAI systems work and how to interpret their decisions can hinder the adoption of these technologies. Additionally, healthcare professionals may have difficulty adapting to new systems. This can be a barrier, especially for doctors who are cautious about new technologies and prefer traditional medical approaches (Pawar, O’Shea, et al., 2020).

5.4. Natural Limitations of Explainability

Some AI models (especially DL and reinforcement learning) can be so complex and multidimensional that it may be practically impossible to provide explainability. While increasing the accuracy of the models, it may be necessary to compromise explainability. That is, sometimes providing explainability of a high-performance model may be impossible due to the complexity of the model. This may limit the application of XAI in healthcare (Payrovnaziri et al., 2020).

5.5. Legal and Ethical Challenges

The question of responsibility for health decisions made by AI is an important ethical issue. If AI makes a mistake, who will take responsibility for it? Clarifying legal frameworks is important to seek answers to such questions (Smith, 2021).

5.6. Lack of Standards

Widespread and accepted standards for XAI in the healthcare sector are not yet fully developed. Different countries and organizations have different regulations and standards regarding the use of AI in healthcare. However, establishing a universal standard in this field is an important requirement for the safe and effective use of XAI systems. The lack of universal standards for XAI in healthcare can lead to inconsistent operation of systems across platforms or countries and the emergence of security vulnerabilities (Pawar, O'shea, et al., 2020).

5.7. Lack of Time and Resources

In the healthcare sector, especially in emergency departments and intensive care units, time is a critical factor. Implementing XAI systems and ensuring the accuracy of their decisions may require additional time and effort. It may take time for healthcare professionals to understand how and why AI outputs are given. This creates an additional burden for healthcare professionals who often have busy work schedules and may negatively impact the effectiveness of the system. In addition, XAI systems may require high costs to develop and implement, which can be a barrier for healthcare institutions (Rajkomar et al., 2019).

5.8. Patients' Trust Issues

Patients may be concerned about AI-based decisions. The explainability of AI systems may help alleviate these concerns, but fully trusting AI decision-making processes may still be challenging for some patients (Hulsen, 2023).

6. THE FUTURE OF EXPLAINABLE ARTIFICIAL INTELLIGENCE IN HEALTH CARE AND POTENTIAL SOLUTIONS

The future of XAI in healthcare will be shaped by the more reliable, transparent and effective use of this technology. At this point, XAI will play an important role in the healthcare sector in the future. XAI will inc-

rease the transparency and reliability levels of healthcare by enabling healthcare professionals and patients to understand, interpret and trust the decisions of AI systems.

The biggest impact of XAI in healthcare will be on diagnostic processes and treatment planning. As AI's complex decisions become explainable, healthcare professionals will be able to better evaluate these decisions and provide patients with more personalized treatment options. For example, when diagnosing cancer, an AI system could clearly state which biomarkers and clinical data led to that conclusion. This would allow doctors to make their treatment processes more efficient (Esteva et al., 2017).

XAI will also play a key role in patient monitoring and early warning systems. For example, an XAI-based system could predict a patient's risk of having a heart attack and explain how it calculated that risk, making it easier for doctors to provide the right intervention. This would allow for more accurate, timely, and targeted treatment approaches.

New algorithms developed for XAI are making significant progress toward creating more transparent and understandable AI systems. Presenting AI decisions with visual, textual, or graphical explanations can help users better understand the outputs.

XAI can also play an important role in healthcare policy-making. By analyzing healthcare data, AI can make recommendations about the effectiveness of a particular treatment method or healthcare program. XAI transparently explains these recommendations, allowing policymakers and healthcare administrators to make the right decisions.

A global standardization process for the use of AI in healthcare is gaining importance. Collaborations between different countries can make AI applications in healthcare more effective and secure at the international level.

Healthcare professionals will receive extensive training on these technologies to effectively use XAI systems. Both physicians and nurses should be able to better interpret the explanations provided by XAI-based tools and validate their clinical decisions with these explanations. These training processes will accelerate the adoption of XAI and ensure that healthcare professionals trust these technologies.

Health data is a very sensitive issue. With the increasing use of XAI, the security and privacy of personal health data will become even more important. When AI systems make decisions based on health data, the privacy of this data should be protected and ethical standards should be observed. In the future, XAI systems are expected to not only make correct decisions, but also present these decisions in an ethical framework.

The future of XAI depends on the development of more efficient and effective AI models. Explainable methods used today are often limited and can be difficult to interpret large data sets. However, with new research and developments, it is expected that new XAI techniques will emerge that can analyze health data more accurately and understandably. These models will allow for faster and more accurate analysis of data.

7. CONCLUSION

AI has the potential to create a major transformation in the healthcare sector. XAI ensures that this transformation takes place safely and effectively. The use of AI technologies in the healthcare sector has great potential in many areas such as early diagnosis of diseases, improvement of treatment processes, provision of personalized healthcare services and increasing efficiency in healthcare management. These innovative applications of AI support the decision-making processes of healthcare professionals while also improving the quality of patient care. However, the effective use of AI in the healthcare field is not limited to the accuracy and efficiency of the technology; the explainability and transparency of these technologies are also critical.

XAI plays a major role in increasing the acceptance and trust of AI applications in healthcare. Understanding AI decisions allows healthcare professionals to question the accuracy of the results and implement appropriate interventions. In addition, explainability provides an important assurance in terms of protecting patient rights and preventing ethical issues. However, one of the biggest challenges faced with the use of AI in healthcare is the limitations of these technologies in terms of transparency and explainability. Although complex AI models such as DL can produce results with high accuracy, it can sometimes be very difficult to understand how and why these results occur.

Regulation and supervision of AI-based healthcare applications bring ethical and legal issues. Critical issues such as feeding AI systems with accurate data, security and privacy of data are other important areas that need to be addressed. In order to ensure effective use of AI in healthcare, not only the development of technology but also the correct understanding and application of these technologies by users is required.

In conclusion, although the future of AI in healthcare is quite bright, elements such as explainability, ethics and transparency must be prioritized in order for these technologies to be used safely and effectively. It is critical for healthcare professionals to understand AI systems in order to make the right decisions. In addition, adopting a multidisciplinary approach in the design and implementation of these systems will have a major

impact on the shaping of future healthcare policies. Continuing research in the field of AI and explainability is vital for this potential to be used most efficiently.

REFERENCES

- Akalın, B., & Veranyurt, Ü. (2021). Sağlık hizmetleri ve yönetiminde yapay zekâ. *Acta Infologica*, 5(1), 231-240.
- Alpkoçak, A. (2024). Sağlıkta açıklanabilir yapay zekâ. *TOTBİD Dergisi S*, 23, 18-19.
- Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., . . . Benjamins, R. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82-115.
- Caruana, R., Lou, Y., Gehrke, J., Koch, P., Sturm, M., & Elhadad, N. (2015). *Intelligible models for healthcare: Predicting pneumonia risk and hospital 30-day readmission*. Paper presented at the Proceedings of the 21th ACM SIGKDD international conference on knowledge discovery and data mining.
- Carvalho, D. V., Pereira, E. M., & Cardoso, J. S. (2019). Machine learning interpretability: A survey on methods and metrics. *Electronics*, 8(8), 832.
- Chaddad, A., Peng, J., Xu, J., & Bouridane, A. (2023). Survey of explainable AI techniques in healthcare. *Sensors*, 23(2), 634.
- Demir, F. (2021). Derin öğrenme tabanlı yaklaşımla kötü huylu deri kanserinin dermatoskopik görüntülerden saptanması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 33(2), 617-624.
- Doshi-Velez, F., & Kim, B. (2017). Towards a rigorous science of interpretable machine learning. *arXiv preprint arXiv:1702.08608*.
- Dunjko, V., & Briegel, H. J. (2018). Machine learning & artificial intelligence in the quantum domain: a review of recent progress. *Reports on Progress in Physics*, 81(7), 074001.
- Ehsan, U., Liao, Q. V., Muller, M., Riedl, M. O., & Weisz, J. D. (2021). *Expanding explainability: Towards social transparency in ai systems*. Paper presented at the Proceedings of the 2021 CHI conference on human factors in computing systems.
- 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.
- Furkan, A., İşbay, B., & Özlem, Ö. (2023). Sağlık Alanında Yapay Zekâ Yöntemlerinin Kullanımına İlişkin Lisansüstü Tezlerin Bibliyometrik Analizi (2015-2022). *Gevher Nesibe Journal of Medical and Health Sciences*, 8(1), 228-237.
- Graham, S., Depp, C., Lee, E. E., Nebeker, C., Tu, X., Kim, H.-C., & Jeste, D. V. (2019). Artificial intelligence for mental health and mental illnesses: an overview. *Current psychiatry reports*, 21, 1-18.

- Gunning, D., & Aha, D. (2019). DARPA's explainable artificial intelligence (XAI) program. *AI magazine*, 40(2), 44-58.
- Han, J.-H. (2022). Artificial intelligence in eye disease: recent developments, applications, and surveys. In (Vol. 12, pp. 1927): MDPI.
- Hulsen, T. (2023). Explainable artificial intelligence (XAI): concepts and challenges in healthcare. *AI*, 4(3), 652-666.
- Kaplan, M., Çakar, F., & Bingöl, H. (2024). Sağlık Alanında Yapay Zekanın Kullanımı: Derleme. *Muş Alparslan Üniversitesi Sağlık Bilimleri Dergisi*, 4(3), 75-85.
- Koski, E., & Murphy, J. (2021). AI in Healthcare. In *Nurses and Midwives in the Digital Age* (pp. 295-299): IOS Press.
- Kwong, J. C., Khondker, A., Tran, C., Evans, E., Cozma, A. I., Javidan, A., . . . Papanikolaou, F. (2022). Explainable artificial intelligence to predict the risk of side-specific extraprostatic extension in pre-prostatectomy patients. *Canadian Urological Association Journal*, 16(6), 213.
- Loh, H. W., Ooi, C. P., Seoni, S., Barua, P. D., Molinari, F., & Acharya, U. R. (2022). Application of explainable artificial intelligence for healthcare: A systematic review of the last decade (2011–2022). *Computer methods and programs in biomedicine*, 226, 107161.
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in neural information processing systems*, 30.
- Mak, K.-K., & Pichika, M. R. (2019). Artificial intelligence in drug development: present status and future prospects. *Drug discovery today*, 24(3), 773-780.
- Mankodiya, H., Jadav, D., Gupta, R., Tanwar, S., Alharbi, A., Tolba, A., . . . Raboaca, M. S. (2022). Xai-fall: Explainable ai for fall detection on wearable devices using sequence models and xai techniques. *Mathematics*, 10(12), 1990.
- Mankodiya, H., Jadav, D., Gupta, R., Tanwar, S., Hong, W.-C., & Sharma, R. (2022). Od-xai: Explainable ai-based semantic object detection for autonomous vehicles. *Applied Sciences*, 12(11), 5310.
- Mar, V., & Soyer, H. (2018). Artificial intelligence for melanoma diagnosis: how can we deliver on the promise? *Annals of Oncology*, 29(8), 1625-1628.
- Masters, K. (2019). Artificial intelligence in medical education. *Medical teacher*, 41(9), 976-980.
- McKinney, S. M., Sieniek, M., Godbole, V., Godwin, J., Antropova, N., Ashrafian, H., . . . Darzi, A. (2020). International evaluation of an AI system for breast cancer screening. *Nature*, 577(7788), 89-94.
- Miller, T. (2019). Explanation in artificial intelligence: Insights from the social sciences. *Artificial intelligence*, 267, 1-38.

- Mistry, C., Thakker, U., Gupta, R., Obaidat, M. S., Tanwar, S., Kumar, N., & Rodrigues, J. J. (2021). *MedBlock: An AI-enabled and blockchain-driven medical healthcare system for COVID-19*. Paper presented at the ICC 2021-IEEE International Conference on Communications.
- Mohanta, B., Das, P., & Patnaik, S. (2019). *Healthcare 5.0: A paradigm shift in digital healthcare system using artificial intelligence, IOT and 5G communication*. Paper presented at the 2019 International conference on applied machine learning (ICAML).
- Moradi, M., & Samwald, M. (2022). Deep learning, natural language processing, and explainable artificial intelligence in the biomedical domain. *arXiv preprint arXiv:2202.12678*.
- Nazar, M., Alam, M. M., Yafi, E., & Su'ud, M. M. (2021). A systematic review of human–computer interaction and explainable artificial intelligence in healthcare with artificial intelligence techniques. *IEEE Access*, 9, 153316-153348.
- Obermeyer, Z., Powers, B., Vogeli, C., & Mullainathan, S. (2019). Dissecting racial bias in an algorithm used to manage the health of populations. *Science*, 366(6464), 447-453.
- Oprescu, A. M., Miró-Amarante, G., García-Díaz, L., Rey, V. E., Chimenea-Toscano, A., Martínez-Martínez, R., & Romero-Ternero, M. d. C. (2022). Towards a data collection methodology for Responsible Artificial Intelligence in health: A prospective and qualitative study in pregnancy. *Information Fusion*, 83, 53-78.
- Pawar, U., O'Shea, D., Rea, S., & O'Reilly, R. (2020). *Incorporating Explainable Artificial Intelligence (XAI) to aid the Understanding of Machine Learning in the Healthcare Domain*. Paper presented at the Aics.
- Pawar, U., O'shea, D., Rea, S., & O'reilly, R. (2020). *Explainable AI in healthcare*. Paper presented at the 2020 international conference on cyber situational awareness, data analytics and assessment (CyberSA).
- Payrovnaziri, S. N., Chen, Z., Rengifo-Moreno, P., Miller, T., Bian, J., Chen, J. H., . . . He, Z. (2020). Explainable artificial intelligence models using real-world electronic health record data: a systematic scoping review. *Journal of the American Medical Informatics Association*, 27(7), 1173-1185.
- Preece, A., Harborne, D., Braines, D., Tomsett, R., & Chakraborty, S. (2018). Stakeholders in explainable AI. *arXiv preprint arXiv:1810.00184*.
- Rajkomar, A., Dean, J., & Kohane, I. (2019). Machine learning in medicine. *New England Journal of Medicine*, 380(14), 1347-1358.
- Rajpurkar, P., Irvin, J., Ball, R. L., Zhu, K., Yang, B., Mehta, H., . . . Langlotz, C. P. (2018). Deep learning for chest radiograph diagnosis: A retrospective comparison of the CheXNeXt algorithm to practicing radiologists. *PLoS medicine*, 15(11), e1002686.

- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). “ *Why should i trust you?*” *Explaining the predictions of any classifier*. Paper presented at the Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining.
- Saraswat, D., Bhattacharya, P., Verma, A., Prasad, V. K., Tanwar, S., Sharma, G., . . . Sharma, R. (2022). Explainable AI for healthcare 5.0: opportunities and challenges. *IEEE Access*, 10, 84486-84517.
- Sarkar, A. (2022). Is explainable AI a race against model complexity? *arXiv pre-print arXiv:2205.10119*.
- Shaban-Nejad, A., Michalowski, M., & Buckeridge, D. L. (2020). Explainable AI in healthcare and medicine. *Studies in Computational Intelligence*, 914.
- Shortliffe, E. H., & Cimino, J. J. (2014). Biomedical Informatics Computer Applications in Health Care and Biomedicine.
- Shrestha, A., & Mahmood, A. (2019). Review of deep learning algorithms and architectures. *IEEE Access*, 7, 53040-53065.
- Smith, H. (2021). Clinical AI: opacity, accountability, responsibility and liability. *Ai & Society*, 36(2), 535-545.
- Speith, T. (2022). *A review of taxonomies of explainable artificial intelligence (XAI) methods*. Paper presented at the Proceedings of the 2022 ACM conference on fairness, accountability, and transparency.
- Tekkeşin, A. İ. (2019). Artificial intelligence in healthcare: past, present and future. *Anatol J Cardiol*, 22(Suppl 2), 8-9.
- Tjoa, E., & Guan, C. (2020). A survey on explainable artificial intelligence (xai): Toward medical xai. *IEEE transactions on neural networks and learning systems*, 32(11), 4793-4813.
- Topol, E. (2019). *Deep medicine: how artificial intelligence can make healthcare human again*: Hachette UK.
- Tramèr, F., Zhang, F., Juels, A., Reiter, M. K., & Ristenpart, T. (2016). *Stealing machine learning models via prediction {APIs}*. Paper presented at the 25th USENIX security symposium (USENIX Security 16).
- Uzun, T. (2020). Yapay zeka Ve Sağlık Uygulamaları. İzmir Katip Çelebi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 3(1), 80-92.
- Von Eschenbach, W. J. (2021). Transparency and the black box problem: Why we do not trust AI. *Philosophy & Technology*, 34(4), 1607-1622.
- Xu, F., Uszkoreit, H., Du, Y., Fan, W., Zhao, D., & Zhu, J. (2019). *Explainable AI: A brief survey on history, research areas, approaches and challenges*. Paper presented at the Natural language processing and Chinese computing: 8th cCF international conference, NLPCC 2019, dunhuang, China, October 9–14, 2019, proceedings, part II 8.

