



**TÜRKİYE CUMHURİYETİ**

**KOCAELİ ÜNİVERSİTESİ**

**TIP FAKÜLTESİ**

# Kocaeli Üniversitesi Tıp Fakültesi'nde Çalışmakta olan Asistan Hekimlerin Üretken Yapay Zekâ Araçlarını Kullanım ve Yeterlik Düzeylerinin Değerlendirilmesi

**DR. MÜCAHİT ALTUNGÖK**

**AİLE HEKİMLİĞİ ANABİLİM DALI**

**UZMANLIK TEZİ**

**2025**

**TÜRKİYE CUMHURİYETİ**

**KOCAELİ ÜNİVERSİTESİ**

**TIP FAKÜLTESİ**

# Kocaeli Üniversitesi Tıp Fakültesi'nde Çalışmakta olan Asistan Hekimlerin Üretken Yapay Zekâ Araçlarını Kullanım ve Yeterlik Düzeylerinin Değerlendirilmesi

**DR. MÜCAHİT ALTUNGÖK**

**AİLE HEKİMLİĞİ ANABİLİM DALI**

**UZMANLIK TEZİ**

**TEZ DANIŞMANI: PROF. DR. TUNCAY MÜGE ALVUR**

**ETİK KURUL UYGUNLUK ONAYI**

**Karar No: KOÜ GOKAEK-2025/10/12 Proje No: 2025/228**

**2025**

**TEŞEKKÜR**

Asistanlık eğitimim boyunca her anımda yanımda hissettiğim, bizi koruyup kollayan, sevgisini ve emeğini esirgemeden veren, tecrübesi ve bilgisiyle hayatımıza dokunan değerli hocam Prof. Dr. Tuncay Müge ALVUR'a,

Tez sürecinde her zaman yanımda olan, candan ilgisi ve tükenmeyen yardımseverliğini hepimize gösteren kıymetli hocam Dr. Öğr. Üyesi Canan TUZ YILMAZ'a

Çalışmama istatistiksel analizlerle katkıda bulunan Biyoistatistik Anabilim Dalı öğretim üyesi Sayın Doç. Dr. Sibel BALCI'ya,

Eğitim süreci boyunca desteklerini hiç esirgemeden veren, bilgi ve deneyimlerini paylaşan, birlikte olmaktan hep mutluluk duyduğum tüm asistan arkadaşlarıma,

Doğduğumdan beri beni hep destekleyen, emeklerini esirgemeyen, her zaman yanımda olan aileme,

Hayatıma girdiğinden beri her anımı güzelleştiren, fedakârlığını ve desteğini her zaman hissettiğim, mutluluk yolunda beraber yürüdüğüm sevgili eşim Seher ALTUNGÖK'e ve varlığıyla bana yeryüzünde cenneti yaşatan kızım Elif ALTUNGÖK'e

SONSUZ TEŞEKKÜR…

Dr. Mücahit ALTUNGÖK

Kocaeli, 2025

**İÇİNDEKİLER**

TEŞEKKÜR ..... II
İÇİNDEKİLER ..... III
KISALTMALAR ..... VI
ÇİZELGELER DİZELGESİ ..... VII
ÇİZİMLER DİZELGESİ ..... VIII
1. GİRİŞ VE AMAÇ ..... 1
1.1. GİRİŞ ..... 1
1.2. AMAÇ ..... 2
2. GENEL BİLGİLER ..... 3
2.1. YAPAY ZEKÂ: TANIM VE KAPSAM ..... 3
2.2. YAPAY ZEKÂNIN TEMEL ALT ALANLARI ..... 4
2.2.1. MAKİNE ÖĞRENMESİ ..... 4
2.2.1.1. DENETİMLİ ÖĞRENME ..... 4
2.2.1.2. DENETİMSİZ ÖĞRENME ..... 5
2.2.1.3. PEKİŞTİRMELİ ÖĞRENME ..... 5
2.2.1.4. OTOMATİK KODLAYICILAR ..... 5
2.2.1.5. TRANSFORMER TABANLI MODELLER ..... 5
2.2.1.6. DERİN ÖĞRENME ..... 5
2.2.2. DOĞAL DİL İŞLEME ..... 6
2.2.3. BİLGİSAYARLA GÖRME ..... 7
2.2.4. ROBOTİK ..... 7
2.3. YAPAY ZEKÂDA MODEL TÜRLERİ VE ÖĞRENME YAKLAŞIMLARI ..... 8
2.3.1. AYRIŞTIRICI MODELLER ..... 8
2.3.2. ÜRETKEN MODELLER ..... 9
2.3.2.1. ÜRETKEN YAPAY ZEKÂ ..... 10
2.3.2.1.1. ÜRETİCİ DÜŞMAN AĞLAR ..... 10
2.3.2.1.2. VARYASYONEL OTOMATİK KODLAYICILAR ..... 11

2.3.2.1.3. DİFÜZYON MODELLERİ ..... 11
2.3.2.1.4. TRANSFORMER TABANLI BÜYÜK DİL MODELLERİ ..... 12
2.4. YAPAY ZEKÂNIN TARİHSEL GELİŞİMİ ..... 12
2.4.1. YAPAY ZEKÂ VE ÜRETKEN YAPAY ZEKÂNIN TARİHÇESİ ..... 12
2.4.2. TIPTA YAPAY ZEKÂ VE ÜRETKEN YAPAY ZEKÂNIN TARİHÇESİ ..... 14
2.5. YAPAY ZEKÂNIN TIPTA KULLANIM ALANLARI ..... 15
2.5.1. TANI VE TARAMADA KULLANIMI ..... 15
2.5.2. TEDAVİ SÜREÇLERİNDE KULLANIMI ..... 17
2.5.2.1. ROBOTİK TIPTA YAPAY ZEKÂ KULLANIMI ..... 17
2.5.2.2. KİŞİSELLEŞTİRİLMİŞ TEDAVİ VE KLİNİK KARAR DESTEK SİSTEMLERİ ..... 17
2.5.2.3. İLAÇ TEDAVİSİNDE YAPAY ZEKÂ UYGULAMALARI ..... 18
2.5.2.4. TEDAVİ İZLEME VE REHABİLİTASYON ..... 18
2.5.3. SAĞLIK KAYITLARI VE HASTANE YÖNETİMİNDE KULLANIMI ..... 18
2.5.4. TIP EĞİTİMİNDE KULLANIMI ..... 19
2.5.5. BİLİMSEL YAZMA VE LİTERATÜR TARAMADA DESTEK OLARAK KULLANIMI ..... 20
2.5.6. ÜRETKEN YAPAY ZEKÂNIN TIPTA KATKILARI ..... 20
2.6 YAPAY ZEKÂ VE ETİK BOYUTLAR ..... 22
2.7. YAPAY ZEKÂNIN GELECEĞİ VE ÜRETKEN YAKLAŞIMLARIN ROLÜ ..... 23
3. GEREÇ VE YÖNTEM ..... 24
3.1. ETİK KURUL ONAYI ..... 24
3.2. ARAŞTIRMANIN MODELİ ..... 24
3.3. ARAŞTIRMANIN YERİ VE ZAMANI ..... 24
3.4. ARAŞTIRMANIN EVRENİ VE ÖRNEKLEMİ ..... 24
3.5. ARAŞTIRMAYA DAHİL EDİLME VE DIŞLANMA KRİTERLERİ ..... 25
3.6. VERİ TOPLAMA YÖNTEMİ VE VERİ TOPLAMA ARAÇLARI ..... 26
3.7. İSTATİSTİKSEL ANALİZ ..... 27
4. BULGULAR ..... 27
4.1. SOSYODEMOGRAFİK ÖZELLİKLER ..... 28
4.2. BİLİŞİM ARACI KULLANIMI VE YAPAY ZEKÂ FARKINDALIĞI ..... 30
4.3. ÜRETKEN YAPAY ZEKÂ KULLANIM ÖZELLİKLERİ ..... 31
4.4. ÜRETKEN YAPAY ZEKÂ KULLANIM ALANLARI (MESLEKİ VE MESLEK DIŞI) ..... 36

4.5. ÜRETKEN YAPAY ZEKÂYA YÖNELİK TUTUMLAR VE TEZ SÜRECİYLE İLİŞKİLİ BULGULAR ..... 38
4.6. ÜRETKEN YAPAY ZEKÂ KULLANIM VE YETERLİK ÖLÇEĞİ BULGULARI ..... 40
5. TARTIŞMA ..... 47
5.1. ÇALIŞMANIN GÜÇLÜ YÖNLERİ ..... 59
5.2. ÇALIŞMANIN KISITLILIKLARI ..... 60
6. SONUÇ VE ÖNERİLER ..... **HATA! YER İŞARETİ TANIMLANMAMIŞ.**
TÜRKÇE ÖZET ..... 64
ABSTRACT ..... 65
EKLER ..... 66
EK-1: ÇALIŞMADA KULLANILAN ANKET FORMU ..... 66
EK-2: KOCAELİ ÜNİVERSİTESİ TIP FAKÜLTESİ ETİK KURUL BAŞKANLIĞI'NDAN ALINAN YAZI ..... 74
KAYNAKLAR ..... 75

## KISALTMALAR

BT: Bilgisayarlı tomografi

CNN: Evrişimsel sinir ağları (*Convolutional Neural Networks*)

GAN: Üretici düşman ağlar (*Generative Adversarial Networks*)

KOÜ: Kocaeli Üniversitesi

LLM: Büyük dil modelleri (*Large Language Models*)

LSTM: Uzun-kısa süreli bellek (*Long Short-Term Memory*) ağları

Maks: Maksimum

Min: Minimum

ML: Makine öğrenmesi (*Machine Learning*)

MRG: Manyetik rezonans görüntüleme

N: Sayı

Ort: Ortalama

Q1-Q3: 25. persentil- 75. Persentil

SS: Standart Sapma

ÜYZ: Üretken yapay zekâ

ÜYZKYÖ: Üretken Yapay Zekâ Kullanım ve Yeterlik Ölçeği

VAE: Varyasyonel otomatik kodlayıcılar (*Variational Autoencoder*)

YZ: Yapay zekâ

%: Yüzde

## ÇİZELGELER DİZELGESİ


‘‘Çizelge 1. Katılımcı yaşları’‘ ..... 28

‘‘Çizelge 2. Katılımcıların cinsiyet, medeni durum ve çocuk sahibi olma durumuna göre dağılımı’‘ ..... 28

‘‘Çizelge 3. Çalışmaya katılanların uzmanlık alanlarına göre dağılımı’‘ ..... 29

‘‘Çizelge 4: Haftalık çalışma süresine göre dağılım’‘ ..... 29

‘‘Çizelge 5: Katılımcıların bilişim aracı kullanımı ve günlük kullanım süresi’‘ ..... 30

‘‘Çizelge 6. Katılımcıların yapay zekâ alanındaki gelişmeleri takip etme sıklığı ve yapay zekâ teknolojileriyle ilgili öz-değerlendirilen bilgi düzeyine göre dağılımı’‘ ..... 31

‘‘Çizelge 7. Katılımcıların üretken yapay zekâ araçlarını kullanma durumu, haftalık kullanım süresi ve kullanılan üretken yapay zekâ araçlarına göre dağılımı’‘ ..... 32

‘‘Çizelge 8. Katılımcıların ücretli üretken yapay zekâ araçlarını kullanma durumu, haftalık kullanım süresi ve kullanılan ücretli üretken yapay zekâ araçlarına göre dağılımı’‘ ... 33

‘‘Çizelge 9. Üretken yapay zekâ kullanma durumuna göre yaş dağılımı’‘ ..... 34

‘‘Çizelge 10. Üretken yapay zekâ kullanma durumuna göre sosyodemografik özelliklerinin dağılımı (n=419)’‘ ..... 34

‘‘Çizelge 11. Üretken yapay zekâ kullanma durumuna göre çalışma özelliklerinin dağılımı (n=419)’‘ ..... 35

‘‘Çizelge 12. Katılımcıların üretken yapay zekâ araçlarını meslekle ilgili konularda kullanma durumu ve mesleki kullanım alanlarına göre dağılımı’‘ ..... 36

‘‘Çizelge 13. Katılımcıların üretken yapay zekâ araçlarını meslek dışı konularda kullanma durumu ve meslek dışı kullanım alanlarına göre dağılımı’‘ ..... 37

‘‘Çizelge 14. Katılımcıların tıp alanında üretken yapay zekâ kullanımının yaygınlaşmasına ilişkin görüşleri ve bu durumun yol açtığı endişe durumuna göre dağılımı’‘ ..... 38

‘‘Çizelge 15. Tıp alanında üretken yapay zekânın yaygınlaşmasını isteme ile yaygınlaşmanın endişe yaratması arasındaki ilişki’‘ ..... 39

‘‘Çizelge 16. Katılımcıların tez çalışmaları ve tez aşamalarına göre dağılımı’‘ ..... 39

‘‘Çizelge 17. Tezde ÜYZ kullanımı ve kullanma niyeti’‘ ..... 40

‘‘Çizelge 18. Üretken Yapay Zekâ Kullanım ve Yeterlik Ölçeği alt boyut ve toplam puanları’‘ ..... 42

‘‘Çizelge 19. Yaş ile ÜYZKYÖ arasındaki ilişki’‘ ..... 43

‘‘Çizelge 20. ÜYZKYÖ toplam puanının demografik değişkenlere göregöre dağılımı’‘ . 44

‘‘Çizelge 21. Uzmanlık alanına göre ÜYZKYÖ toplam puanlarının dağılımı’‘ ..... 45

‘‘Çizelge 22. Haftalık çalışma saatine göre ÜYZKYÖ toplam puanlarının dağılımı’‘ ..... 46

## ÇİZİMLER DİZELGESİ (ŞEKİLLER LİSTESİ)

‘‘Çizim 1. ÜYZKYÖ ölçeği maddelerine verilen yanıtların dağılımı’‘ ..... 40

# 1. GİRİŞ VE AMAÇ

## 1.1. GİRİŞ

Dijitalleşmenin hızlandığı son yıllarda, bilgi ve iletişim teknolojilerindeki gelişmeler toplumsal süreçlerin işleyişini önemli ölçüde değiştirmiş ve kurumları karar verirken daha çok veri temelli yöntemlere yöneltmiştir.[1] Bu durum, giderek artan ve karmaşık hale gelen veri yığınlarını anlamlandırabilen ve rutin iş akışlarını otomatikleştirebilen teknolojik çözümlere olan ihtiyacı da belirgin şekilde artırmıştır.[1] Bu bağlamda yapay zekâ (YZ), insanın öğrenme, çıkarım yapma ve karar verme gibi bilişsel yetilerini algoritmalar aracılığıyla modellemeyi amaçlayan geniş bir çalışma alanı olarak öne çıkmaktadır.[2]

Zaman içinde yapay zekâ alanındaki gelişmeler, daha çok tahmine dayalı modellerden, yeni içerik üretebilen üretken mimarilere doğru kaymıştır.[3] Bu çerçevede üretken yapay zekâ (ÜYZ) ve büyük dil modelleri, metin oluşturma, özetleme ve benzeri dil işlemlerini kısa sürede yapabilen güçlü araçlar hâline gelmiştir.[4] Üretken yapay zekâ araçlarının önem kazanmasında; kurumlarda giderek artan dokümantasyon yükü, yoğun iletişim trafiği ve hızlı içerik üretme gereksinimi etkili olmaktadır.[2] Bu özellikleri nedeniyle üretken yapay zekâ araçları, mevcut iş akışlarını tamamen dönüştüren sistemler yerine, bu akışları destekleyen ve süreçleri daha verimli hâle getiren yardımcı araçlar olarak değerlendirilmektedir.[3] Sağlık hizmetlerinde yapay zekâ uygulamalarının kullanım alanı giderek genişlemekte olup, özellikle birinci basamak dâhil olmak üzere klinik iş akışlarında belge oluşturma, iletişim süreçlerini kolaylaştırma ve bilginin hızlı erişimini sağlama gibi alanlarda destekleyici bir işlev üstlenmektedir.[2] Bunun yanında radyoloji ve patoloji gibi görüntü ağırlıklı uzmanlık alanlarında, yapay zekâ tabanlı çözümler hem raporlamada hem de hastaların önceliklendirilmesinde önemli katkılar sunabilmektedir.[5,6] Ayrıca giyilebilir teknolojilerle ve kenar bilişim yaklaşımlarıyla bütünleşen yapay zekâ sistemleri, kronik hastalıkların anlık izlenmesine olanak tanıyarak kişiye özel önerilerin geliştirilmesi için yeni fırsatlar ortaya koymaktadır.[7]

Tıp alanında yapay zekâya yönelik toplumsal tutumu belirleyen temel etkenler şeffaflık ve güvenin sağlanmasıdır; bu iki unsur, teknolojinin kabulünü doğrudan etkilemektedir.[8] Klinik uygulamalarda çalışan hekimlerin deneyimleri, yapay zekâ araçlarının benimsenmesinde yalnızca algılanan yararın değil, iş akışına uyum, sorumluluğun

paylaşımı ve eğitim ihtiyacının da önemli olduğunu göstermektedir.[2] Ülkemizde birinci basamak sağlık hizmetlerinde, artan iş yükü algısı ile birlikte yapay zekâya dair farkındalık yükselmiş; aile hekimliği pratiğinde hem beklentilerin hem de çeşitli çekincelerin aynı anda tartışıldığı bir ortam oluşmuştur.[9] Sağlık profesyonellerinin yapay zekâya ilişkin bilgi düzeyi ve hazır bulunuşluklarının değerlendirilmesi, bu teknolojilerin güvenli ve etkili kullanımını destekleyecek eğitim içerikleri ve müfredat düzenlemeleri için temel bir başlangıç sağlamaktadır.[10] Uluslararası literatürde tıp eğitiminde yapay zekâ uygulamalarını ele alan derlemelerde, yapay zekânın öğrenci seçimi, öğretim, ölçme–değerlendirme ve program geliştirme süreçlerine giderek daha fazla dahil olduğu; bu nedenle tıp eğitiminde yapay zekâ okuryazarlığı ve yapılandırılmış eğitim içeriklerinin önem kazandığı vurgulanmaktadır.[11] Ancak klinik güvenlik açısından önyargılı tahminler, genelleme sorunları ve bağlama uymayan çıktılar gibi risklerin de dikkatle yönetilmesi gerektiği belirtilmektedir.[12]

Genel olarak, hem birinci basamakta hem de hastane ortamlarında yapay zekâ uygulamalarının sağlayacağı yararların, güvenlik, etik ilkeler ve düzenleyici çerçeve güçlendikçe daha net ortaya çıkacağı öngörülmektedir.[13] Önümüzdeki dönemde ise giyilebilir teknolojilerle yapay zekânın entegrasyonu ve üretken modellerin klinik dokümantasyon ile iletişim süreçlerine kontrollü biçimde dâhil edilmesi, hem daha kişiselleştirilmiş hem de daha erişilebilir sağlık hizmeti sunumu için önemli fırsatlar sunmaktadır.[7,14]

### 1.2. AMAÇ

Kocaeli Üniversitesi Hastanesi'nde eğitim gören araştırma görevlisi hekimlerin üretken yapay zekâ araçları hakkındaki;

-Farkındalığı, bilgi düzeyi, kullanım durumu ve düzeyi

-Kullanım yeterliliği ve öğrenme motivasyonlarının ölçek aracılığıyla değerlendirilmesi

ve bu parametrelerin sosyodemografik değişkenlerle ilişkisinin değerlendirilmesi amaçlanmaktadır.

# 2. GENEL BİLGİLER

## 2.1. YAPAY ZEKÂ: TANIM VE KAPSAM

Yapay zekâ, bilgisayar ve diğer makine temelli sistemlerin insan zihninin öğrenme, akıl yürütme, problem çözme ve karar verme gibi bilişsel süreçlerini taklit edebilmesini amaçlayan yöntem ve teknolojilerin genel adı olarak tanımlanmaktadır.[15] Bu sistemler, yalnızca veriyi işleyen pasif araçlar olmaktan çıkıp çevresel koşulları algılayabilen, önceki deneyimlerinden öğrenebilen ve bu öğrenimi yeni durumlara uyarlayarak belirli bir düzeyde kendi kendine karar verebilen yapılar hâline gelmiştir.[16,17]

Matematik, özellikle olasılık ve istatistik alanları üzerinden, yapay zekâ algoritmalarının kuramsal temelini oluşturan başlıca disiplinlerden biri olarak görülmektedir.[18] Zihin ve bilişsel süreçleri inceleyen bilişsel bilim ise yapay zekâ ile çift yönlü bir ilişki içindedir; dikkat mekanizmaları ile uzun ve kısa süreli bellek (*LSTM, Long Short-Term Memory*) gibi bilişsel kuramlardan esinlenen modeller, derin öğrenme mimarilerinin tasarımını etkilemekte, aynı zamanda bilişsel araştırmalarda yapay zekâ temelli yöntemlerin bir araç olarak kullanılmasına olanak sağlamaktadır.[17]

Psikolojideki öğrenme kuramları, pekiştirmeye dayalı davranış modelleri ve duygu düzenleme süreçleri; pekiştirmeli öğrenme, duygusal hesaplama ve kişilik tanıma gibi yapay zekâ uygulamalarına kuramsal temel oluşturmaktadır. Buna karşılık yapay zekâ tabanlı sistemler, davranış örüntülerini ve ruh sağlığına ilişkin göstergeleri analiz etmede yeni imkânlar sunmaktadır.[17] Dilbilim alanında ise özellikle psikodilbilim ve hesaplamalı dilbilim, dilin yapısı ve kullanımıyla ilgili kuramsal çerçeveler sağlayarak doğal dil işleme, dil modelleme ve büyük dil modellerinin geliştirilmesi süreçleriyle yakından ilişkilidir. Yapay zekâ temelli dil modelleri de dil ve biliş arasındaki ilişkinin nicel olarak incelenmesine olanak tanıyarak bu etkileşimi daha görünür hâle getirmektedir.[17]

Genel olarak yapay zekâ, bilgisayar bilimi, matematik, istatistik, bilişsel bilim, psikoloji, sinirbilim, dilbilim, felsefe ve mühendislik gibi birçok disiplinden beslenen çok alanlı bir çalışma alanıdır. Bu disiplinlerin kavram ve yöntemlerini bir araya getirir ve aynı zamanda bu alanlardaki araştırma gündemini de yeniden şekillendirmektedir.[17]

## 2.2. YAPAY ZEKÂNIN TEMEL ALT ALANLARI

Yapay zekâ, bilgisayar bilimleri içinde makine öğrenmesi, doğal dil işleme, bilgisayarla görme, robotik, planlama ve uzman sistemler gibi birbiriyle ilişkili birçok alt alanı kapsayan geniş bir kavram olarak kabul edilmektedir. Bu alt alanların her biri, insan zihniyle ilişkili farklı bilişsel yetenekleri modellemeyi hedeflemektedir. [19] Bu bölümde, yapay zekâ şemsiyesi altında yer alan ve sağlık alanında özellikle öne çıkan bileşenler kısaca tanımlanacak ve bu bileşenlerin genel yapay zekâ içindeki yerleri özetlenecektir.

### 2.2.1. MAKİNE ÖĞRENMESİ

Makine öğrenmesi (*Machine Learning, ML*), yapay zekânın temel bileşenlerinden biri olup, sistemlerin açık bir programlama gerekmeksizin deneyimlerinden öğrenerek karar verebilmesine olanak tanıyan bir yaklaşım olarak tanımlanmaktadır.[20] Sağlık alanında ML yöntemlerinin kullanım alanı giderek genişlemekte; tanı koyma, prognoz belirleme ve tedavi planlamasında karmaşık klinik verileri analiz eden çok sayıda model geliştirilmektedir. Bu kapsamda özellikle **s**epsis gibi kritik klinik durumların erken tahmini için veri odaklı makine öğrenimi ve derin öğrenme modellerinin yaygın biçimde kullanıldığı rapor edilmiştir.[21]

Makine öğrenmesi algoritmaları, radyolojik görüntüler ve elektronik sağlık kayıtları gibi birden fazla veri kaynağını birlikte analiz ederek hastalık sınıflandırmalarında yüksek doğruluk oranlarına ulaşabilmektedir. Bu sayede klinik karar destek sistemlerinin performansı belirgin şekilde artmaktadır.[22] Makine öğrenmesi birkaç alt dala ayrılır;

#### 2.2.1.1. DENETİMLİ ÖĞRENME

Denetimli öğrenme (*Supervised Learning*) , doğru çıktıları içeren etiketli bir eğitim setiyle çalışan ve modelin bu örneklerden öğrenmesini sağlayan temel bir makine öğrenimi yöntemidir. Bu yöntemde amaç, verilen giriş verilerinden doğru çıktıyı tahmin edebilen bir fonksiyon oluşturmaktır. Örneğin bir klinik karar modeli, hastanın biyometrik özellikleri ve laboratuvar sonuçlarını değerlendirerek belirli bir hastalığın olup olmadığını öngörebilir.[23]

### 2.2.1.2. DENETİMSİZ ÖĞRENME

Denetimsiz öğrenme (*Unsupervised Learning*), sadece giriş verilerinden yararlanarak verinin içindeki gizli yapı ve örüntüleri ortaya çıkarmayı amaçlayan bir makine öğrenimi yöntemidir.[24]

### 2.2.1.3. PEKİŞTİRMELİ ÖĞRENME

Pekiştirmeli öğrenme (*Reinforcement Learning*), bir ajanın çevresiyle etkileşime girdiği, her eylem sonrası ödül ya da ceza şeklinde bir geri bildirim aldığı ve bu geri bildirimlerden yararlanarak toplam ödülü en yükseğe çıkaracak stratejileri zamanla öğrendiği bir yaklaşımdır.[25] Sağlık alanında ise bu yöntem, özellikle yoğun bakım ünitelerinde yatak ve ventilatör kullanımının planlanması gibi durumlarda yaygın olarak kullanılmaktadır.[26]

### 2.2.1.4. OTOMATİK KODLAYICILAR

Otomatik kodlayıcı mimarileri (*Autoencoders*), veriyi daha düşük boyutlu bir gösterime dönüştürüp yeniden oluşturabildikleri için, özellikle boyut indirgeme, gürültü azaltma ve tıbbi görüntülerde anomali saptama gibi birçok uygulamada yaygın olarak kullanılmaktadır.[27]

### 2.2.1.5. TRANSFORMER TABANLI MODELLER

Transformer mimarisi, çok başlıklı dikkat (*multi-head attention*) yapısının sağladığı güçlü temsil kapasitesi sayesinde özellikle doğal dil işleme ve görsel veri analizi alanlarında önemli bir dönüşüm yaratmıştır.[28]

### 2.2.1.6 DERİN ÖĞRENME

Derin öğrenme (*Deep Learning*), çok katmanlı yapay sinir ağlarını temel alan bir makine öğrenmesi yaklaşımı olup, geniş ölçekli veri setlerinden hiyerarşik özellikler çıkararak insan benzeri bilişsel süreçleri gerçekleştirebilme kapasitesine sahiptir.[29] Buradaki "derin" ifadesi, giriş ve çıkış katmanları arasında yer alan çok sayıdaki gizli katmana gönderme yapmaktadır.[30] Derin öğrenme yöntemleri, tıbbi görüntüleme ve klinik

karar destek uygulamaları başta olmak üzere farklı birçok alanda yaygın şekilde kullanılmaktadır.[31]

### 2.2.2. DOĞAL DİL İŞLEME

Doğal Dil İşleme (*Natural Language Processing – NLP*), bilgisayar bilimleri ve yapay zekânın bir alt alanı olarak, insan dilinin anlaşılması, yorumlanması ve anlamlandırılmasına yönelik teknikleri içermektedir.[32] Bu alan, dilin yapısının çözümlenmesiyle metin ve konuşma verilerinin otomatik olarak analiz edilmesine imkân sağlar.[33] Bu kapsam doğrultusunda NLP, farklı dilsel görevleri ele alan bir dizi alt dala ayrılmaktadır.

**Sözdizimsel (Sentaks) İşleme:** Sözdizimsel analiz, bir cümlenin yapısını inceleyerek kelimelerin gramer içindeki görevlerini ve aralarındaki ilişkileri ortaya koymayı amaçlar.[34]

**Anlamsal (Semantik) İşleme:** Anlamsal işleme, kelime ve cümlelerin taşıdığı gerçek anlamı belirlemeye ve metnin kavramsal bütünlüğünü korumaya odaklanan bir çözümleme sürecidir.[35]

**Metin Sınıflandırma:** Metin sınıflandırma, belgelerin içeriklerine göre önceden belirlenmiş kategorilere otomatik olarak ayrılmasını sağlayan bir yöntemdir ve spam e-posta tespiti ile konu belirleme gibi birçok alanda yaygın şekilde kullanılmaktadır.[36]

**Makine Çevirisi (*Machine Translation*):** Makine çevirisi, bir dildeki metnin başka bir dile otomatik olarak çevrilmesini sağlayan bir NLP uygulamasıdır. Başlangıçta kural tabanlı yöntemlere dayanırken, günümüzde büyük ölçüde yapay sinir ağı temelli modellere dönüşmüştür.[34]

**Otomatik Özetleme (*Text Summarization*):** Otomatik özetleme, uzun metinlerden temel fikirleri seçerek içeriği daha kısa ve okunabilir bir biçimde sunmayı amaçlar; özellikle bilimsel yayınlar, hukuki metinler ve haber yazılarında önemli ölçüde zaman kazandırmaktadır.[37]

**Konuşma Tanıma ve Üretimi (*Speech Recognition and Synthesis*):** NLP, yalnızca yazılı metinleri değil, konuşma verilerini de kapsar. Bu kapsamda konuşma tanıma, insan sesini metne dönüştürürken; konuşma sentezi (*text-to-speech*) yazılı ifadeleri doğal bir sesle

yeniden üretir. Her iki teknoloji de günümüzde sesli asistanlar gibi etkileşimli sistemlerin temel bileşenleri arasında yer almaktadır.[38]

### 2.2.3. BİLGİSAYARLA GÖRME

Bilgisayarla görme, dijital görüntü ve video verilerinden anlamlı ve yapısal bilgi çıkarabilen algoritmalar geliştirmeyi amaçlayan bir yapay zekâ alt alanıdır.[39] Bu alanda, görsel algı insan görme sistemine benzer şekilde modellenmeye çalışılır ve görüntü işleme, modelleme, örüntü tanıma, makine öğrenimi, bilgisayar grafikleri ve fizik gibi farklı disiplinlerden yararlanılır.[40]

Bilgisayarla görme uygulamalarında gürültü giderme, kontrast iyileştirme, renk düzeltme ve histogram eşitleme gibi ön işleme adımları, özellikle tıbbi görüntülerin daha sağlıklı analiz edilebilmesi için kritik kabul edilmektedir.[41] Kenar tespiti algoritmaları (Sobel, Canny vb.), görüntüdeki nesne sınırlarını, yüz hatlarını ve temel doku özelliklerini belirlemek amacıyla kullanılmaktadır.[42]

Segmentasyon yöntemleri ise pikselleri anlamlı bölgelere ayırarak, özellikle tıbbi görüntülerde organ ve lezyonların daha ayrıntılı gösterilmesinde önemli bir rol oynamaktadır.[43]

### 2.2.4. ROBOTİK

Sağlık hizmetlerinde robotik sistemler; cerrahi girişimler, rehabilitasyon uygulamaları, hastane lojistiği ve hasta ile etkileşim gibi farklı birçok alanda kullanılmaktadır.[44] Robotik cerrahi yaklaşımları, daha küçük kesiler ve daha az kan kaybı sağlayarak ameliyat travmasını azaltmayı ve hastaların iyileşme sürecini hızlandırmayı hedeflemektedir.[45] Meta-analiz düzeyindeki kanıtlar, yapay zekâ destekli robotik cerrahi uygulamalarında işlem süresi ve komplikasyon oranlarında azalma yönünde bir eğilim olduğunu göstermektedir.[46]

Rehabilitasyon alanında kullanılan robotik sistemler ise özellikle felç sonrası motor fonksiyonun desteklenmesi ve hastaya özgü egzersiz programlarının uygulanması için önemli bir araç olarak değerlendirilmektedir[47]

## 2.3. YAPAY ZEKÂDA MODEL TÜRLERİ VE ÖĞRENME YAKLAŞIMLARI

Yapay zekâ modelleri genel olarak iki grupta ele alınmaktadır: Girdilerden doğrudan çıktı veya etiket tahmini yapan ayrıştırıcı (*discriminative*) yaklaşımlar ve verinin ortak olasılık dağılımını öğrenerek yeni örnekler üreten üretici (*generative*) yaklaşımlar.[48]

### 2.3.1. AYRIŞTIRICI MODELLER

Ayrıştırıcı (*Discriminative*) modellerin temel amacı, verilen özelliklerden yararlanarak hedef etiketi doğrudan tahmin etmek ve sınıflar arasındaki ayrımı mümkün olduğunca net ortaya koymaktır.[49] Kısaca bu yaklaşım, verinin nasıl üretildiğini modellemek yerine etiketi açıklamaya odaklanır ve "girdi → çıktı" ilişkisine dayanarak karar üretir.[50] Örneğin bir hastanın "riskli/riskli değil" şeklinde sınıflandırılması ya da bir görüntünün "iyi huylu/kötü huylu" olarak ayrılması gibi durumlarda doğrudan sınıf tahmini yaparlar.[51]

Ayrıştırıcı modeller, farklı sınıfları birbirinden en iyi ayıran karar sınırını öğrenmeye odaklanır ve bu sayede günlük uygulamalarda hızlı ve genellenebilir kararlar üretebilir.[52]Tıbbi bir örnek olarak, erken tanı amacıyla kullanılan sistemlerde ayrıştırıcı modeller; yaş, vital bulgular ve laboratuvar değerleri gibi çok sayıda özelliği kullanarak "hastalık var/yok" şeklindeki kararları üretmek için etkili biçimde kullanılmaktadır.[53] Görsel ve işitsel alanlarda, derin sinir ağları gibi ayrıştırıcı yaklaşımlar; konuşma tanıma ve görüntü sınıflandırma görevlerinde doğrudan doğru sınıfı seçerek performansta belirgin iyileşmeler sağlamıştır.[54] Karar ağaçları, veriyi "eğer–ise" biçimindeki kurallarla dallara ayırarak yorumlanabilir ve görselleştirilebilir sınıflandırıcı modeller üretir.[55] Örneğin basit klinik tarama senaryolarında yaş, semptomlar ve test sonuçlarına göre dallanan yapı üzerinden triyaj kararları verilebilmektedir.[55] Rastgele Ormanlar, eğitim verisinden rastgele seçilen alt örneklemlerle kurulan çok sayıda karar ağacının bir araya geldiği ve sonucun bu ağaçların çoğunluk oyuna göre belirlendiği bir topluluk öğrenme yöntemidir.[56] Sağlıkta hastalık tanısı ve prognoz tahmini gibi pek çok sınıflandırma ve regresyon probleminde yaygın olarak kullanılmaktadır.[56]

### 2.3.2. ÜRETKEN MODELLER

Yapay zekâda üretken modellerin temel amacı, verilerin altında yatan olasılık dağılımını öğrenerek gerçek örneklere çok benzeyen yeni veriler üretebilmektir[57] Bu modeller yalnızca sınıflandırma yapmakla kalmayıp, verinin nasıl oluştuğunu öğrendiği için eğitim verisine benzeyen sentetik görüntü, metin ve diğer veri türlerini yeniden üretebilmektedir.[57] Üretken modeller, düşük kaliteli veya eksik görüntülerin iyileştirilmesi, gürültünün azaltılması ve çözünürlüğün artırılması gibi amaçlarla da kullanılmakta; özellikle düşük doz BT (Bilgisayarlı Tomografi) görüntülerinin tanısal kalitesini artırmada önemli rol oynamaktadır.[58]

Mühendislik ve malzeme bilimi alanlarında derin üretken modeller, karmaşık tasarım uzaylarını öğrenerek yeni tasarım adayları (örneğin mikro yapı geometrileri veya yeni malzeme konfigürasyonları) önermek için kullanılmakta ve otomatik tasarım sentezinde güçlü bir araç olarak değerlendirilmektedir.[59] Güncel çalışmalar, derin üretken modellerin yalnızca veri üretiminde değil; görüntü iyileştirme, ilaç keşfi, klinik karar desteği ve tıp eğitimi gibi birçok alanda da yenilikçi çözümler sunduğunu göstermektedir.[58]

Genel olarak üretken modeller, verideki karmaşık örüntüleri öğrendikten sonra bu örüntülere benzeyen ancak yeni ve özgün örnekler üreterek, hem ayrıştırıcı modeller için bir veri kaynağı hem de tasarım ve keşif süreçlerinde yaratıcı bir araç olarak işlev görmektedir.[57]

GAN (Üretici Düşman Ağlar, Generative Adversarial Networks), VAE (Varyasyonel Otomatik Kodlayıcılar, Variational Autoencoder ) ve difüzyon tabanlı üretken modeller, verinin olasılık dağılımını öğrenerek bu dağılımla uyumlu yeni örnekler üretebilmekte ve günümüzde birçok "Üretken Yapay Zekâ" uygulamasının temel bileşenleri olarak kabul edilmektedir.[60]

Genel olarak üretken yapay zekâ, büyük veri kümeleri üzerinde ön-eğitim yapılabilmesi ve çok sayıda göreve ya da farklı alana uyarlanabilme esnekliği sayesinde son yıllarda belirgin bir popülerlik kazanmıştır.[61]

### 2.3.2.1. ÜRETKEN YAPAY ZEKÂ

Üretken yapay zekâ (ÜYZ), yapay zekânın bir alt alanı olup, öğrenilmiş kalıplara dayanarak yeni içerikler (metin, görsel, ses, kod vb.) üretebilen model gruplarını ifade eden bir yaklaşımdır.[62] Yapay zekâda ayrıştırıcı (discriminative) modellerin temel amacı sınıflandırma ve tahmin yapmak iken, ÜYZ'de kullanılan üretici (generative) modeller verinin olasılık dağılımını öğrenerek bu dağılımla uyumlu yeni örnekler üretmeyi hedefler.[63] Daha basit bir ifadeyle, ayrıştırıcı modeller mevcut verilerden anlam ve sınıf bilgisi çıkarmaya odaklanırken, üretici modeller bu verilere benzeyen yeni veriler üretmeye çalışır.[64] Bununla birlikte, YZ ve ÜYZ; veri ön işleme, temsil öğrenimi ve model değerlendirme gibi ortak aşamalar içerdiğinden aynı kuramsal ve teknik temele dayanmaktadır.[65] Bu açıdan bakıldığında ÜYZ, yapay zekânın yöntemsel birikimini kullanan ancak üretilen içerik odaklı yaklaşımıyla ondan ayrılan ve genel YZ yaklaşımlarını tamamlayan bir alt alan olarak değerlendirilebilir.[65] ÜYZ kapsamında kullanılan temel derin üretici model aileleri; Varyasyonel Otomatik Kodlayıcılar (VAE), Üretici Düşman Ağlar (*Generative Adversarial Network* ,GAN), difüzyon modelleri ve Transformer tabanlı büyük dil modelleri olarak sınıflandırılmaktadır.[66]

#### 2.3.2.1.1. ÜRETİCİ DÜŞMAN AĞLAR

Üretici düşman ağlar, üreteç ve ayrıştırıcı olmak üzere iki derin sinir ağının oyun kuramına dayalı bir rekabet içinde eğitildiği ve bu sayede gerçek verilere oldukça benzeyen sentetik örnekler üretebilen bir üretici model ailesi olarak tanımlanmaktadır.[67] GAN mimarisinde üreteç (*generator*), rastgele gürültüden yeni örnekler üretmeye çalışırken; ayrıştırıcı (*discriminator*) gerçek ve sahte örnekleri ayırt etmeye odaklanır ve iki ağ arasındaki bu karşılıklı süreç, verinin dağılımının öğrenilmesine imkân sağlar.[68] Bu rekabetçi eğitim yaklaşımı, GAN modellerinin eğitim verisine benzer istatistiksel özelliklere sahip yeni örnekler üretebilen güçlü üretici modeller olarak kabul edilmesine yol açmıştır.[68] Görüntü işleme alanında GAN'ler; veri kümelerini genişletme, farklı tarzlarda resim veya karikatür oluşturma, süper çözünürlüklü görüntü üretme ve bir görüntüdeki dokuyu başka bir görüntüye aktarma gibi çok sayıda görevde yaygın olarak kullanılmaktadır.[67] Tıbbi görüntülemede ise GAN tabanlı modeller, düşük çözünürlüklü MRG(Manyetik Rezonans Görüntüleme), retina ve ultrason görüntülerini daha yüksek çözünürlüğe dönüştürerek tanısal ayrıntıların daha net görülebilmesine katkı sağlamak

amacıyla uygulanmaktadır.[69] Yapılan çalışmalar, GAN modellerinin gerçek MRG ve diğer tıbbi görüntülerin dağılımını yakalayarak, tanısal açıdan kullanılabilecek düzeyde yüksek gerçekçilik gösteren sentetik beyin görüntüleri üretebildiğini ortaya koymaktadır.[70] Genel olarak literatürde GAN'ler, geleneksel üretici modellere göre daha esnek yapıları ve görüntü, zaman serisi ile metin gibi farklı veri tiplerine uyarlanmış pek çok çeşidi sayesinde, güncel derin öğrenme uygulamalarında önemli bir konuma sahip görünmektedir.[71]

#### 2.3.2.1.2. VARYASYONEL OTOMATİK KODLAYICILAR

Varyasyonel Otomatik Kodlayıcılar (VAE), girdileri düşük boyutlu ve sürekli bir saklı uzaya kodlayıp buradan yeniden üreten, bu sayede olasılıksal bir temsil öğrenerek yeni örnekler üretebilen derin üretici modellerdir.[72] Tıbbi görüntülemede VAE'ler, MRG ve BT gibi yüksek boyutlu görüntüleri saklı bir uzaya eşleyerek veri sıkıştırma, gürültü azaltma ve anomali tespiti amacıyla kullanılmaktadır.[73] İlaç tasarımı alanında ise VAE tabanlı yaklaşımlar, molekülleri sürekli bir saklı uzaya kodlayıp bu uzayda gezinerek istenen fizikokimyasal özelliklere sahip yeni bileşik adayları önermek için diğer derin öğrenme yöntemleriyle birlikte kullanılmaktadır.[74]

#### 2.3.2.1.3. DİFÜZYON MODELLERİ

Difüzyon (*Diffusion*) modelleri, veriye eklenmiş gürültüyü kademeli olarak azaltarak verinin dağılımını öğrenen ve bu sayede eğitim verisine benzeyen, ancak birebir aynı olmayan yeni görüntü, ses veya diğer veri türlerini üretebilen üretken modellerdir.[75] Üretken yapay zekâ içinde difüzyon modelleri, özellikle görüntü üretiminde yüksek çözünürlüklü ve ayrıntılı çıktılar sağlayabildikleri için, GAN tabanlı birçok yaklaşıma güçlü bir alternatif olarak öne çıkan temel mimarilerden biri hâline gelmiştir.[75] Metinden-görüntü (prompt tabanlı) sistemlerde, kullanıcı yalnızca kısa bir metinsel açıklama girdiğinde difüzyon modeli, gürültüden başlayarak bu metne uygun görüntüyü adım adım oluşturmaktadır.[75] Tıbbi alanda difüzyon modelleri; BT ve MRG gibi görüntülerde gürültü giderme, çözünürlük artırma ve eksik bölgeleri tamamlama gibi işlemlerde, gerçek görüntülere yüksek benzerlik taşıyan sentetik tıbbi görüntüler üretmek için kullanılmaktadır.[75] Koşullu (*conditional*) difüzyon yaklaşımları ise belirli bir tümör tipi

veya belirli bir anatomik bölge gibi ek klinik bilgileri koşul olarak kullanarak, istenen özelliklere sahip sentetik tıbbi görüntüler oluşturabilmektedir.[76]

#### 2.3.2.1.4. TRANSFORMER TABANLI BÜYÜK DİL MODELLERİ

Transformer tabanlı büyük dil modelleri (LLM), çok geniş metin kümeleri üzerinde eğitilen, doğal dili hem anlamlandırabilen hem de yeni metin üretebilen üretken yapay zekâ sistemleri olarak tanımlanmaktadır.[77] Bu modeller temelde, bir sonraki kelimeyi tahmin etmeye dayalı bir görevle eğitilmekte; aynı mimari sayesinde soru yanıtlama, metin tamamlama, özetleme ve çeviri gibi birçok dil görevini de yerine getirebilmektedir.[65,78] Sağlık alanında LLM'ler; klinik sorulara yanıt verilmesi, epikriz ve rapor taslaklarının oluşturulması, kılavuzların özetlenmesi ve hasta iletişim metinlerinin hazırlanması gibi süreçlerde karar destek aracı olarak kullanılmaya başlanmıştır.[65]

Eğitim bağlamında ise Transformer tabanlı LLM'ler, tıp öğrencileri ve asistan hekimlere yönelik kişiselleştirilmiş açıklamalar, vaka senaryoları ve sınav tarzı sorular üreterek uyarlanabilir bir öğrenme aracı olarak değerlendirilmektedir.[79]

## 2.4. YAPAY ZEKÂNIN TARİHSEL GELİŞİMİ

### 2.4.1. YAPAY ZEKÂ VE ÜRETKEN YAPAY ZEKÂNIN TARİHÇESİ

Yapay zekâ kavramının kökleri, sinir sistemi ile hesaplama süreçlerini birlikte ele alan erken dönem kuramsal çalışmalara dayanmaktadır. McCulloch ve Pitts, 1943 tarihli makalelerinde nöronları mantıksal kapılar üzerinden modelleyerek, biyolojik sinir sistemini taklit eden yapay sinir ağı fikrini matematiksel bir çerçeveye oturtmuşlardır.[80] Bu çizgiyi devam ettiren Alan Turing, 1950'de yayımladığı "Computing Machinery and Intelligence" başlıklı makalesinde "Makineler düşünebilir mi?" sorusunu gündeme getirmiş ve Turing Testi ile makinelerin zekâsını değerlendirmeye yönelik dönüştürücü nitelikte bir ölçüt önermiştir.[81]

1956 yılında McCarthy, Minsky, Rochester ve Shannon öncülüğünde düzenlenen Dartmouth Summer Research Project on Artificial Intelligence (Dartmouth Konferansı), yapay zekânın bağımsız bir araştırma alanı olarak tanımlanmasına zemin hazırlamış ve disiplinin kurumsal başlangıcı olarak kabul edilmiştir.[82] Bunu izleyen dönemde Rosenblatt'ın 1958'de tanıttığı Perceptron modeli, girdilerden öğrenerek çıktı üretebilen

basit bir yapay nöron yapısı sunmuş; istatistiksel öğrenme ve sınıflandırma temelli sinir ağlarının gelişimine önemli katkı sağlamıştır.[83] 1980'lerle birlikte bağlantısalcı yaklaşımlar güç kazanmış, Rumelhart, Hinton ve Williams'ın 1986'da ortaya koyduğu geri yayılım algoritması çok katmanlı ağların etkin biçimde eğitilmesini sağlayarak derin öğrenme anlayışının çekirdeğini oluşturmuştur.[84] Hochreiter ve Schmidhuber'in 1997'de tanımladığı LSTM mimarisi, tekrarlayan sinir ağlarının uzun vadeli bağımlılıkları öğrenebilmesini mümkün kılmış ve sıralı veri modellemesinde önemli bir dönüm noktası olarak öne çıkmıştır.[85]

LeCun ve çalışma arkadaşları, 1998 tarihli çalışmalarında evrişimsel sinir ağlarını (CNN, Convolutional Neural Networks) el yazısı karakter tanıma problemine uygulayarak, derin öğrenme yaklaşımlarının görsel tanımadaki pratik gücünü somut biçimde göstermişlerdir.[86]

2012'de Krizhevsky, Sutskever ve Hinton tarafından geliştirilen AlexNet modeli ise büyük ölçekli görüntü veri setlerinde derin CNN mimarisi ile elde ettiği doğruluk artışı ve hesaplama verimliliği sayesinde modern derin öğrenme dönemini başlatan çalışma olarak kabul edilmektedir.[87] Mikolov ve arkadaşlarının 2013'te tanıttığı word2vec modeli, kelimeleri sürekli vektör uzayında temsil eden dağıtımsal dil modelleri sunarak, daha sonra büyük dil modellerinin temsili gücünü besleyen önemli bir yapıtaşı hâline gelmiştir.[88]

Bu genel tarihsel gelişim içerisinde üretken modellerin evrimi ise, olasılıksal yaklaşımlardan derin sinir ağlarına uzanan ayrı bir eksen olarak ortaya çıkmıştır. 1950–1970 döneminde özellikle Gizli Markov Modelleri **(***Hidden Markov Models***)** ve Gauss karışım modelleri **(***Gaussian Mixture Models***)**, konuşma ve diğer sıralı verilerde verinin nasıl üretildiğini açıklamaya çalışan üretken bakışın erken örnekleri olarak öne çıkmıştır. [64]

2000'li yıllarla birlikte veri hacmindeki artış ve hesaplama gücündeki ilerleme sayesinde üretici modelleme, sinir ağlarıyla birleşerek çok katmanlı derin üretici modellere dönüşmüş ve bu modellerin biyomedikal veriler dâhil pek çok alanda kullanılabilirliği tartışılmaya başlanmıştır.[89] Kingma ve Welling'in 2013–2014 dönemindeki çalışmalarıyla tanımlanan Variational Autoencoder (VAE) yaklaşımı, veriyi sürekli bir gizil uzaya kodlayıp bu uzaydan örnekleyerek yeniden üretebilmeyi mümkün kılmış; hem temsil öğrenimi hem de yeni örnek üretimi açısından önemli bir dönüm noktası yaratmıştır.[72] Aynı yıllarda Goodfellow ve arkadaşları tarafından geliştirilen Generative Adversarial

Networks (GAN) mimarisi, üreteci ile ayırt edicinin rekabet ettiği yapısı sayesinde gerçeğe çok benzeyen görüntüler üretebilmiş ve üretken modelleme alanında önemli bir dönüm noktası olmuştur.[90]

2017'de Vaswani ve arkadaşlarının "Attention Is All You Need" başlıklı makalesiyle sundukları Transformer mimarisi, tamamen dikkat mekanizmasına dayalı yapısı sayesinde dizisel verilerin işlenmesinde yeni bir standart tanımlamış ve sonraki büyük dil modelleri için temel mimari zemin hazırlamıştır.[91] OpenAI tarafından geliştirilen GPT-1 (2018), GPT-2 (2019) ve GPT-3 (2020) modelleri, Transformer mimarisine dayalı olarak büyük metin koleksiyonları üzerinde ön-eğitim almış ve çok çeşitli görevlerde insan benzeri metin üretebilen otoregresif dil modelleri olarak öne çıkmıştır.[61]

Devlin ve arkadaşları tarafından 2018'de tanıtılan BERT modeli, çift yönlü ön-eğitim yaklaşımı ile dilin bağlamsal temsilini güçlendirmiş, anlama odaklı bileşeni zenginleştirerek üretken sistemlerin metin kalitesine dolaylı katkı sağlamıştır.[92]

Görüntü alanında Ho ve arkadaşlarının 2020 tarihli çalışması, denoising difüzyon modelleriyle veriye kademeli olarak gürültü ekleyip bu süreci tersine çevirerek yalnızca gürültüden yüksek kaliteli görüntüler üretebilen yeni bir üretici sınıf tanımlamış ve pek çok görüntüleme görevinde kalite standartlarını yeniden tanımlamıştır.[93] Rombach ve arkadaşları, 2022'de Latent Diffusion yaklaşımıyla difüzyon sürecini saklı uzaya taşıyarak üretim sürecini hızlandırmış ve daha düşük hesaplama maliyetiyle yüksek çözünürlüklü sentez olanağı sunmuştur.[94]

Ramesh ve arkadaşlarının geliştirdiği DALL·E modeli, metin girdilerinden görsel üretimini yaygınlaştırarak üretken yapay zekânın çok kipli (multimodal) kapasitesini görünür kılmış ve metin–görüntü sentezi alanına yeni bir ivme kazandırmıştır.[95]

### 2.4.2. TIPTA YAPAY ZEKÂ VE ÜRETKEN YAPAY ZEKÂNIN TARİHÇESİ

Tıpta yapay zekâ uygulamalarının erken dönemi, ağırlıklı olarak uzman sistemler üzerinden geliştirilen kural tabanlı klinik karar destek yaklaşımlarına dayanmaktadır; 1970'lerin başında Stanford Üniversitesi'nde geliştirilen MYCIN sistemi, bakteriyel enfeksiyonların tanısı ve uygun antibiyotik tedavisine yönelik öneriler sunan öncü bir danışman sistem olarak tanımlanmıştır.[96] Aynı dönemde geliştirilen INTERNIST-1 sistemi ise iç hastalıkları alanında kural tabanlı bir tanısal danışman olarak tasarlanmış ve genel

dahiliye pratiğinde bilgisayar destekli tanı kavramının uygulanabilirliğini ortaya koymuştur.[97]

1980'ler ve 1990'larda geri yayılım algoritmasının ve evrişimli sinir ağlarının geliştirilmesiyle, özellikle el yazısı ve doküman tanıma gibi görüntü tanıma görevlerinde yüksek performans sağlayan derin öğrenme mimarileri ortaya çıkmıştır.[86] 2010'lu yıllarda AlexNet'in büyük ölçekli görüntü veri setlerindeki başarısı, derin CNN mimarilerinin sınıflama performansını ve hesaplama verimliliğini belirgin biçimde artırarak tıbbi görüntü sınıflama, segmentasyon ve karar destek sistemlerinde doğruluk ve hızın anlamlı şekilde iyileşmesine zemin hazırlamıştır.[87]

Bu genel tarihsel çizgi, pek çok alanda olduğu gibi tıpta da başlangıçta etiket tahmini odaklı sistemlerden, verinin dağılımını öğrenip yeni örnekler üretebilen üretken modellere doğru bir evrime zemin hazırlamıştır.[60]

Kingma ve Welling'in VAE yaklaşımı, medikal görüntü ve biyomedikal verilerin saklı uzaya kodlanıp bu uzaydan örnek çekilerek yeniden üretilmesini mümkün kılmış; veri artırma, anomali tespiti ve nadir durumların modellenmesi için yeni olanaklar sunmuştur.[72] Koshino ve çalışma arkadaşlarının bulguları, GAN tabanlı üretken modellerin MRG, BT ve retina görüntüleri gibi farklı tıbbi modalitelerde gerçeğe çok yakın sentetik görüntüler üreterek veri dengesizliği ve gizlilik sorunlarına çözüm potansiyeli taşıdığını göstermiştir.[98] Ho ve arkadaşlarının difüzyon modellerine ilişkin çalışmaları, tıbbi görüntülerde tamamen gürültüden başlayarak yüksek kaliteli örnekler üretebilen yeni bir üretici çerçeve sunmuş ve görüntü kalitesi açısından güçlü kanıtlar ortaya koymuştur.[93,99]

Maity ve arkadaşları, Transformer tabanlı büyük dil modellerinin tıbba uyarlandığında klinik soru-cevap, epikriz ve rapor taslağı üretimi, kılavuz özetleme ve hasta iletişim metinlerinin oluşturulması gibi üretken metin görevlerinde karar desteği sağlayabildiğini ortaya koymuştur.[65]

## 2.5. YAPAY ZEKÂNIN TIPTA KULLANIM ALANLARI

### 2.5.1. TANI VE TARAMADA KULLANIMI

Yapay zekâ (YZ), tıbbi tanı ve tarama süreçlerinde köklü değişimlere yol açarak tanısal yaklaşımların kapsamını ve niteliğini dönüştürmektedir.[100]

YZ teknolojilerinin, karmaşık klinik verilerin analizinde yüksek performans göstererek hastalıkların daha erken dönemde saptanmasına ve zamanında, etkili müdahalelerin planlanmasına katkı sağladığı bildirilmektedir.[101]

Radyolojik görüntüleme, yapay zekâ uygulamalarının en hızlı geliştiği ve en yaygın biçimde kullanıldığı alanlardan biri hâline gelmiştir.[102] Derin öğrenme algoritmaları; BT, MRG, ultrason ve direkt grafi gibi farklı görüntü modalitelerinde anormalliklerin saptanması amacıyla uyarlanmış ve klinik tanı süreçlerine entegre edilmeye başlanmıştır.[103] Akciğer kanseri gibi patolojilerin otomatik olarak algılanması, radyologların iş yükünü azaltırken tanısal süreçlerde hem zaman kazancı sağlamış hem de doğruluk oranlarının artmasına katkıda bulunmuştur.[104]

Dijital patoloji, patolojik örneklerin yüksek çözünürlüklü dijital görüntülere dönüştürülerek bu görüntülerin yapay zekâ algoritmalarıyla analiz edildiği, giderek önem kazanan yenilikçi bir uygulama alanı olarak tanımlanmaktadır.[105] Bu bağlamda yapay zekâ temelli sistemler; hücrelerin şekil ve boyut özellikleri, nükleer ayrıntılar, dokuların mimarisi ve düzeni gibi mikroskobik ölçekteki morfolojik parametreleri nicel olarak değerlendirerek kanserli ve sağlıklı dokuları ayırt etmede kullanılmakta ve tanısal doğruluğu destekleyen tamamlayıcı araçlar olarak konumlanmaktadır.[106]

Dermatoloji alanında yapay zekâ tabanlı algoritmalar, özellikle cilt kanseri ve malign melanomun erken tanısında yüksek doğruluk düzeylerine ulaşan yardımcı araçlar olarak bildirilmektedir.[107]. Mobil uygulamalar, hastaların erken başvuru ve değerlendirmeye erişimini kolaylaştırırken, aynı zamanda uzman dermatologların iş yükünü hafifleterek iş akışının daha verimli yönetilmesine katkı sağlamaktadır.[108]

Kardiyolojide YZ destekli modeller, elektrokardiyogram verilerinin analizi yoluyla aritmi, özellikle de atriyal fibrilasyon gibi ritim bozukluklarının saptanmasında yüksek performans sergileyen tanısal araçlar olarak kullanılmaktadır.[109] Benzer şekilde YZ tabanlı risk modelleri, atriyal fibirlasyon gibi durumlar için erken dönemde risk skorlaması yaparak klinik karar süreçlerini desteklemekte ve önleyici yaklaşımların planlanmasına yardımcı olmaktadır.[110]

Oftalmoloji pratiğinde ise, retinal görüntülerin YZ ile analizi, diyabetik retinopati ve glokom gibi görme kaybına yol açabilen hastalıkların erken ve tarama temelli tespitinde

etkin bir araç olarak öne çıkmakta; bu sayede hem hastalık yükünün azaltılması hem de tarama programlarının verimliliğinin artırılması hedeflenmektedir.[111]

### 2.5.2. TEDAVİ SÜREÇLERİNDE KULLANIMI

#### 2.5.2.1. ROBOTİK TIPTA YAPAY ZEKÂ KULLANIMI

Minimal invaziv cerrahide kullanılan robotik cerrahi sistemler, cerrahın el becerisini desteklemek ve ameliyat sırasında hassasiyet ile kontrolü artırmak amacıyla geliştirilmiştir.[112]

Yapay zekâ, cerrahi girişimlerden önce ayrıntılı bir operasyon planı hazırlanmasında önemli bir bileşen hâline gelmiştir.[113] Hastadan elde edilen üç boyutlu görüntüler üzerinde ayrıntılı analizler yaparak, robotik cerrahi sırasında izlenecek yol haritasının belirlenmesine katkı sağlar.[114] Ayrıca simülasyon tabanlı eğitim ortamlarında yapay zekâ, cerrahların robotik sistemleri önceden denemelerine ve teknik becerilerini güvenli koşullarda geliştirmelerine olanak tanıyan gerçekçi uygulama senaryoları sunmaktadır.[115]

Robotik teknolojiler, yalnızca cerrahi uygulamalarla sınırlı kalmayıp, ameliyat sonrasındaki iyileşme döneminde de hastaların rehabilitasyon süreçlerine aktif olarak entegre edilmektedir.[116]

#### 2.5.2.2. KİŞİSELLEŞTİRİLMİŞ TEDAVİ VE KLİNİK KARAR DESTEK SİSTEMLERİ

Yapay zekâ, hastaya özgü genetik, biyokimyasal ve yaşam tarzı verilerinin ayrıntılı analizinde yüksek performans göstererek, bireyselleştirilmiş tedavi planlarının oluşturulmasına olanak sağlamaktadır.[117] Klinik karar destek sistemleri, hasta verilerini mümkün olduğunca gerçek zamana yakın biçimde değerlendirerek tedavi seçeneklerinin karşılaştırılmasına yardımcı olmakta ve böylece etkinliği yüksek, yan etki olasılığı daha düşük yaklaşımların belirlenmesini desteklemektedir.[118] Özellikle onkoloji pratiğinde, tümörün biyolojik özellikleri ve hastanın genetik profili dikkate alınarak tedavi planlamasında yapay zekâ tabanlı algoritmalardan giderek daha fazla yararlanıldığı bildirilmektedir. Bu tür sistemler, tedavi yanıtının öngörülmesi ve olası komplikasyonların önceden belirlenmesi gibi kritik karar aşamalarında hekimlere ek bilgi ve destek

sağlayarak klinik sürecin daha güvenli ve öngörülebilir şekilde yönetilmesine katkıda bulunmaktadır.[119]

### 2.5.2.3. İLAÇ TEDAVİSİNDE YAPAY ZEKÂ UYGULAMALARI

Klinik farmakoloji pratiğinde, hastaların metabolizma hızları, olası ilaç etkileşimleri ve yan etki profilleri dikkate alınarak bireye özgü doz ayarlamalarının yapılmasına imkân tanıyan modellerin geliştirilmesinde kullanılmaktadır.[120] Ayrıca ilaç geliştirme sürecinde YZ algoritmaları, çok sayıda potansiyel molekülün hızlı biçimde taranması, toksikolojik özelliklerin öngörülmesi ve klinik deneme aşamalarının daha verimli şekilde planlanması için kullanılmaktadır.[121]

### 2.5.2.4 TEDAVİ İZLEME VE REHABİLİTASYON

Yapay zekâ, tedavi sonrasında hastaların izleminde de giderek daha fazla önem kazanan bir araç olarak öne çıkmaktadır.[122] Sensörler, giyilebilir teknolojiler ve mobil uygulamalar üzerinden toplanan veriler, yapay zekâ algoritmaları ile işlenerek hastaların tedaviye uyumları, olası komplikasyonların ortaya çıkışı ve genel sağlık durumlarındaki değişimler yakından takip edilebilmektedir.[123] Özellikle kronik hastalıkların yönetiminde, bu tür uzaktan izlem uygulamalarının hastaların yaşam kalitesini artırmaya ve yeniden hastaneye yatış oranlarını azaltmaya katkı sağladığı belirtilmektedir.[124]

### 2.5.3. SAĞLIK KAYITLARI VE HASTANE YÖNETİMİNDE KULLANIMI

Elektronik sağlık kayıtları, hastaların tıbbi özgeçmişi, laboratuvar sonuçları, reçete bilgileri ve klinik notlar gibi geniş kapsamlı veriyi içeren dijital sistemlerdir.[125] Bu veri kümelerinin elle değerlendirilmesi zor olduğundan, yapay zekâ temelli yöntemler veri işleme ve analiz süreçlerinde hız ve kolaylıklar kazandırmaktadır.[125]

Giyilebilir teknolojiler ve mobil sensör altyapıları üzerinden sürekli toplanan veriler, kronik hastalık yönetimi kapsamında YZ algoritmaları ile analiz edilerek hastanın klinik durumundaki değişimlerin gerçeğe yakın zamanlı takibine imkân sağlamaktadır.[126]

Hastane yönetiminde iş gücü planlaması ve yatak kapasitesinin doğru kullanımı, hasta bakım kalitesinin sürdürülebilmesi açısından temel unsurlar olarak görülmektedir.[127] Yapay zekâ tabanlı algoritmalar, geçmiş kayıtları ve gerçek zamanlı verileri birlikte

değerlendirerek vardiya düzenlemeleri, acil durumlarda hazır bulunması gereken ekiplerin belirlenmesi gibi kritik planlama süreçlerinde yönetime destek sunmaktadır.[128] Yoğun bakım üniteleri ve klinik servislerde yatak doluluk oranlarının dinamik olarak izlenmesi sayesinde hasta kabulü ve taburculuk süreçleri daha dengeli yönetilebilmekte, böylece kapasite kullanımı optimize edilebilmektedir.[128]

Yapay zekâ tabanlı sistemlerin kullanımı sayesinde hastane operasyonlarında maliyetlerin daha kontrollü yönetilmesi ve iş süreçlerinin genel verimliliğinin artırılması mümkün hâle gelmektedir.[129] Sağlık kurumlarında malzeme ve ilaç stoklarının yönetiminde kullanılan yapay zekâ/makine öğrenmesi temelli talep tahmin sistemleri, stok düzeylerini daha dengeli tutarak hem aşırı stok hem de stok yetersizliği riskini azaltmakta; böylece israfı azaltarak maliyet kontrolünü desteklemektedir.[130] Ayrıca gereksiz veya yinelenen tetkik ve testlerin belirlenmesi yoluyla, hem hastaların üzerindeki yük hem de toplam sağlık harcamaları azaltılabilmektedir.[131]

### 2.5.4. TIP EĞİTİMİNDE KULLANIMI

Yapay zekâ destekli sanal simülasyon ortamları, tıp öğrencilerinin gerçek hasta karşılaşmalarına benzeyen klinik deneyimler yaşamalarına imkân vermektedir.[132] Yapay zekâ ile çalışan sanal hasta uygulamaları, senaryoya göre değişebilen ve duruma özgü tepkiler üreterek, öğrencilerin eleştirel düşünme, klinik akıl yürütme ve karar verme becerilerini yapılandırılmış bir eğitim çerçevesinde geliştirmesine yardımcı olmaktadır.[133] Özellikle cerrahi eğitimde kullanılan artırılmış gerçeklik ve sanal gerçeklik tabanlı simülasyonlar, ameliyat öncesi operasyon basamaklarının düşük riskli bir ortamda tekrar prova edilmesine olanak sağlayarak teknik becerilerin pekişmesine ve olası hataların gerçek hastaya yansımadan eğitim ortamında görülüp düzeltilmesine katkı sunmaktadır.[134] Buna ek olarak acil servis ve kritik hasta yönetimi gibi yüksek riskli klinik durumlar, yapay zekâ destekli simülasyon ve sanal hasta platformları üzerinden gerçekçi ve etkileşimli biçimde çalışılabilmekte; böylece öğrencilerin zaman baskısı altında hızlı ve doğru klinik karar verme becerilerinin güvenli bir ortamda geliştirilmesi hedeflenmektedir.[135]

Yapay zekâ tabanlı öğrenme yönetim sistemleri, öğrencilerin önceki performans ve etkileşim verilerini ayrıntılı şekilde analiz ederek bireysel gereksinim ve öğrenme stiline uygun içerikler ve öğrenme yolları önerebilmekte, böylece kişiselleştirilmiş eğitim

planlarının oluşturulmasına katkıda bulunmaktadır.[136] Bu uygulamaların sonucunda, yapay zekâ destekli sanal hasta ortamları, simülasyon temelli eğitim, öğrenme yönetim sistemleri ve kişiselleştirilmiş öğrenme analitiğinin tıp eğitiminde giderek daha sık kullanıldığı bildirilmektedir.[11,137]

### 2.5.5. BİLİMSEL YAZMA VE LİTERATÜR TARAMADA DESTEK OLARAK KULLANIMI

Tıp eğitiminde bilimsel araştırma yapma ve akademik yazım becerilerinin planlı şekilde geliştirilmesi, mesleki yetkinliğin önemli bir bileşeni olarak kabul edilmektedir.[138] Yapay zekâ uygulamaları, öğrencilerin literatür tarama süreçlerini hızlandırarak daha verimli ve hedefe yönelik hâle getirebilmekte; böylece araştırma sürecinin ilk basamaklarını kolaylaştırmaktadır.[139] Doğal dil işleme algoritmaları, geniş veri tabanlarındaki yayınları otomatik biçimde tarayarak ilgili çalışmaları öne çıkarabilmekte, temel bilgileri özetleyebilmekte ve araştırmacılara uygun kaynak önerilerinde bulunabilmektedir.[139] Yazım asistanı niteliğindeki yapay zekâ araçları ise, dilbilgisi, terminoloji ve akademik üslup açısından metinleri gözden geçirerek bilimsel yazıların biçimsel ve içeriksel kalitesini artırmaya yardımcı olmaktadır.[140] Tüm bu araçların birlikte kullanılması sonucunda, öğrencilerin daha hızlı ve daha isabetli literatür değerlendirmesi yapabildiği ve güncel bilimsel kanıtlara dayanan çalışmalar üretebildiği bildirilmektedir.[140]

### 2.5.6 ÜRETKEN YAPAY ZEKÂNIN TIPTA KATKILARI

**Görüntü iyileştirme:** Üretken yapay zekâ yaklaşımları, özellikle düşük doz BT ve hızlı çekim gerektiren MRG gibi zorlayıcı görüntüleme koşullarında gürültüyü azaltarak ve yapısal ayrıntıları daha belirgin hâle getirerek tanısal görüntü kalitesini artırmaktadır.[141]

**Anomali/lesyon belirleme:** Üretken yapay zekâ modelleri, önce "sağlıklı" anatomik yapıyı öğrenip yeniden oluşturarak, yeniden yapılandırma hatasının yüksek olduğu bölgeleri olası anomali ya da lezyon alanları olarak işaretleyebilmektedir.[142] Böylece ek bir etiketleme gerekmeksizin, özellikle beyin MRG görüntülerinde beklenmedik odakların ortaya çıkarılmasına ve erken lezyon saptanmasına katkı sağlamaktadır.[142]

**Klinik metin üretimi ve dokümantasyon**: Üretken yapay zekâ tabanlı büyük dil modelleri, epikriz, poliklinik notu ve benzeri klinik belgelerin ilk taslaklarını oluşturup

düzenleyerek hekimlerin dokümantasyona ayırdığı zamanı ve iş yükünü azaltma potansiyeline sahiptir.[78,143] Klinik kılavuzlar ve kapsamlı notlar da bu modeller kullanılarak daha kısa, anlaşılır ve sade özetlere dönüştürülebilmekte; bu özetler hasta bilgilendirme metinleri için temel oluşturabilmektedir.[65]

**Eğitim ve simülasyon**: Tıp eğitiminde üretken yapay zekâ destekli uygulamalar hem kuramsal öğrenmeyi hem de simülasyon temelli beceri eğitimini dönüştüren araçlar olarak öne çıkmaktadır.[144] ÜYZ tabanlı büyük dil modelleri, farklı zorluk düzeylerinde vaka senaryoları ve sınav formatına benzer sorular üreterek kişiselleştirilmiş, hızlı geri bildirim içeren öğrenme süreçlerini desteklemektedir.[144,145] Büyük dil modelleri, öğrencilerin performans kayıtlarını ve değerlendirme notlarını özetleyip yapılandırılmış geri bildirim taslakları hazırlayarak eğiticilerin değerlendirme yükünü azaltmakta ve öğrenme döngüsünün daha hızlı işlemesine katkı sunmaktadır.[78]

**İlaç ve molekül/protein tasarımı:** Üretken yapay zekâ, ilaç keşfinin erken basamaklarında yeni küçük molekül adayları tasarlayarak etkinlik, seçicilik ve güvenlilik özelliklerinin birlikte optimize edilmesine katkı sağlayabilmektedir.[146]

**Klinik araştırma ve literatür destek:** ÜYZ ve LLM tabanlı sistemler, literatür tarama, özetleme ve kanıtların derlenmesi gibi aşamaları hızlandırarak sistematik derleme ve inceleme süreçlerindeki iş yükünü belirgin ölçüde azaltabilmektedir.[78] Yarı otomatik yazılımlar; çalışma seçimi, veri çıkarımı ve yanlılık (bias) değerlendirmesi gibi adımları kısmen otomatikleştirerek kanıt sentezi süreçlerine teknik destek sunmaktadır.[147]

**Akademik yazılarda kullanımı:** Üretken yapay zekâ, tıpta yürütülen tez çalışmalarında; veri analizi, metin taslağı oluşturma ve literatürün özetlenmesi gibi aşamaların daha kısa sürede tamamlanmasına katkı sağlayabilmektedir.[78] Akademik yazım sürecinde ÜYZ tabanlı modeller; ilgili kaynakların önerilmesi, cümlelerin yeniden yapılandırılması ve metin genelinde bilimsel dil bütünlüğünün korunması gibi konularda araştırmacıya destek aracı olarak kullanılabilmektedir.[65] Tezin yazım ve yerleşim aşamalarında, verilerin sistematik biçimde düzenlenmesi, Çizelgelar ve grafiklerin oluşturulması ile özet bölümlerin yapılandırılmasında da bu sistemlerden yararlanılabileceği belirtilmektedir.[148] Ancak, bu araçlardan elde edilen çıktılardan akademik bağlamda yararlanılırken etik ilkelerin gözetilmesi, bilgilerin doğrulanabilir olması ve süreç boyunca insan denetiminin sürdürülmesi gerekliliği vurgulanmaktadır.[149] Bu koşullar sağlandığında, ÜYZ destekli

yazım süreçlerinin tez çalışmalarında zaman yönetimini kolaylaştırdığı, dilsel tutarlılığı artırdığı ve kaynakların düzenli şekilde kullanılmasına imkân vererek araştırmacının esas bilimsel içeriğe daha fazla odaklanmasını sağladığı ifade edilmektedir.[77]

## 2.6 YAPAY ZEKÂ VE ETİK BOYUTLAR

Yapay zekâ uygulamalarında kullanılan hasta verileri çoğu zaman kimliği belirlenebilir unsurlar içerdiğinden, bu verilerin mahremiyetinin korunması temel ve vazgeçilmez bir etik yükümlülük olarak kabul edilmektedir.[150] Sağlık verilerinin ikincil amaçlarla, örneğin yapay zekâ modellerinin eğitimi için kullanılması durumunda, sürecin açık, şeffaf ve bilgilendirilmiş onam çerçevesinde yürütülmesi gerekmektedir.[151] Kurumsal düzeyde güçlü bir veri yönetişimi yapısının oluşturulması; erişim kontrol mekanizmaları ve ayrıntılı denetim kayıtlarının tutulması, yapay zekâ sistemlerinde yetkisiz erişim ve veri sızıntısı risklerini azaltmada kritik rol oynamaktadır.[152] Hastaya, bakım sürecinde yapay zekâ kullanımının açıkça bildirilmesi ve anlaşılır bir dille açıklanması (*notice & explanation* ) yaklaşımı, hem hasta özerkliğini desteklemekte hem de hasta-hekim arasındaki güven ilişkisinin güçlenmesine katkı vermektedir.[153]

Yapay zekâ tabanlı sistemlerin ürettiği tıbbi içerikler hata veya yanlış bilgi içerebileceğinden, bu çıktılar için sistematik doğruluk denetimi yapılması zorunludur.[154] Yapay zekâ uygulamalarının güvenilirlik düzeyi, büyük ölçüde modelin eğitildiği verinin niteliği, kapsamı ve çeşitliliği ile belirlenmektedir.[155] Bağımsız doğrulama süreçlerinden geçirilmemiş yapay zekâ modelleri, performanslarını olduğundan daha yüksek gösterebilir ve bu durum klinik uygulamalarda yanıltıcı sonuçlara yol açabilir.[156] Klinik karar verme sürecine geçilmeden önce, yapay zekâ sistemlerinin ürettiği çıktılar mutlaka ilgili alanın uzmanları tarafından gözden geçirilmeli ve klinik bağlam içinde değerlendirilmelidir.[78] Yapay zekâ tabanlı sistemlerde ortaya çıkan hataların düzenli olarak izlenmesi, kayıt altına alınması ve düzeltici-geliştirici iyileştirmelerle giderilmesi, zaman içinde modelin güvenilirliğini ve tutarlılığını artırmaktadır.[157]

Klinik karar süreçlerinde yapay zekâ önemli bir destek aracı olarak kullanılmakla birlikte, ortaya çıkan kararların etik ve mesleki sorumluluğu nihai olarak sağlık profesyonellerine aittir.[158] Bu nedenle, sorumluluğun hangi aşamada kime ait olduğunu netleştirecek şekilde; sistemi geliştiren ekip, doğrulayan ve onaylayan otoriteler, uygulamayı hayata geçiren kurumlar ve klinisyenler arasında paylaşımlı bir sorumluluk

modelinin açık biçimde tanımlanması gerekmektedir.[159] Öte yandan, otomasyon yanlılığı nedeniyle klinisyenlerin hatalı ya da eksik önerilere aşırı güven duyup bunlara uyma riskinin artabileceği, bu yüzden kararın gerekçelendirilmesi ve nihai sorumluluğunun klinik ekipte kalmasının etik açıdan zorunlu olduğu vurgulanmaktadır.[160]

Sağlık alanında yapay zekâya yönelik yasal düzenlemelerin temel amacı, bu sistemlerin güvenliğini ve etkinliğini kanıtlayan şeffaf raporlama ve düzenli denetim mekanizmalarını hayata geçirmektir.[161] Etik kurullar, yapay zekâ içeren araştırmalarda risk–yarar dengesini, veri kullanım biçimlerini, bilgilendirilmiş onam süreçlerini ve adalet ilkesine uyumu değerlendirerek projelerin etik açıdan kabul edilebilirliğini gözden geçirir.[162]

## 2.7. YAPAY ZEKÂNIN GELECEĞİ VE ÜRETKEN YAKLAŞIMLARIN ROLÜ

Yapay zekânın, önümüzdeki dönemde klinik tanı ve tedavi karar süreçlerinde hekimi ikame eden değil, onu tamamlayan bir karar destek aracı olarak giderek daha yaygın kullanılacağı öngörülmektedir.[163] Üretken yapay zekâ araçlarının, özellikle klinik dokümantasyon, yazılı kayıtların oluşturulması ve metin özetleme gibi bilişsel açıdan zaman alan işlerde hekimlerin yükünü hafifleterek zihinsel iş yoğunluğunu azaltma potansiyeli bulunmaktadır.[4,164] Yapay zekâ sistemlerinin, sağlık hizmet sunumu, bilimsel araştırma ve halk sağlığı uygulamaları başta olmak üzere geniş bir yelpazede kullanım alanı bularak etkisini artıracağı ifade edilmektedir.[165] Gizlilik odaklı yaklaşımlar, özellikle verinin kurumdan çıkmadan yerinde tutulduğu federatif öğrenme (federated learning) gibi yöntemler aracılığıyla, ölçeklenebilir ve mahremiyeti gözeten yapay zekâ çözümlerinin geliştirilmesine temel oluşturacaktır.[166] Toplum ve hastalar açısından bakıldığında, yapay zekânın hekimle birlikte çalışan, tamamlayıcı bir araç olarak konumlandırılması, bu teknolojilerin kabulünü ve benimsenmesini artıran bir unsur olarak öne çıkmaktadır.[8] Üretken yapay zekâ, klinik yazışmaların ve tıbbi özetlerin hazırlanmasında iş yükünü azaltarak süreç verimliliğini artırma potansiyeli taşımaktadır.[4] Klinik uygulamalarda bu sistemlerin güvenilir biçimde kullanılabilmesi için, sürekli insan denetimiyle birlikte şeffaf ve izlenebilir raporlama süreçlerinin işletilmesi gerekmektedir.[165] Üretken modellerin gerçeğe dayanmayan veya uydurma bilgiler üretebilme riski, hasta güvenliği açısından önemli bir tehdit oluşturduğundan bu durum yakından izlenmelidir.[165]

# 3. GEREÇ VE YÖNTEM

## 3.1. ETİK KURUL ONAYI

Bu çalışma, Kocaeli Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu'nun KOÜ GOKAEK-2025/10/12 karar numarası ve 2025/228 proje numarası ile 2025 yılında etik açıdan uygun bulunarak onaylanmıştır. Çalışma, Helsinki Bildirgesi'nin güncel ilkeleri ve ilgili ulusal mevzuat ile etik ilkelere uygun olarak yürütülmüştür. Etik kurul uygunluk belgesi tez eklerinde sunulmuştur (Ek-2).

## 3.2. ARAŞTIRMANIN MODELİ

Bu araştırma, Kocaeli Üniversitesi Tıp Fakültesi'nde görev yapan asistan hekimlerin üretken yapay zekâ (ÜYZ) araçlarını kullanım durumları ve bu araçlara yönelik yeterlik düzeylerini belirlemeyi amaçlayan tanımlayıcı ve kesitsel nitelikte bir anket çalışmasıdır.

## 3.3. ARAŞTIRMANIN YERİ VE ZAMANI

Araştırma, Kocaeli Üniversitesi Tıp Fakültesi Hastanesi bünyesinde yer alan dahili, cerrahi ve temel tıp bilimleri ana bilim dallarında görev yapan araştırma görevlisi hekimler arasında yürütülmüştür. Veri toplama süreci, etik kurul onayını takiben Haziran 2025 – Eylül 2025 tarihleri arasında gerçekleştirilmiştir. Anket formu, hem çevrimiçi (Google Forms) ortamda hem de yüz yüze (basılı anket formu) uygulanmış; yüz yüze doldurulan formlar daha sonra çevrimiçi forma aktarılmıştır. Çalışmada kullanılan anket formu tez eklerinde sunulmuştur. (Ek-1)

## 3.4. ARAŞTIRMANIN EVRENİ VE ÖRNEKLEMİ

Araştırmanın evrenini, Kocaeli Üniversitesi Hastanesi'nde uzmanlık eğitimi alan tüm araştırma görevlisi hekimler oluşturmaktadır. Hastanede eğitim görmekte olan araştırma görevlisi hekim sayısı;

Dahili bilimler: 474

Cerrahi bilimler: 259

Temel tıp bilimleri: 27

olmak üzere toplam 760 kişidir.

Örneklem hesabında %95 güven aralığı ve %5 hata payı temel alınarak her bir ana bilim grubu için minimum ulaşılması gereken katılımcı sayısı hesaplanmış; dahili bilimler için en az 213, cerrahi bilimler için en az 156 ve temel tıp bilimleri için en az 25 kişiye ulaşılması hedeflenmiştir.

Veri toplama süreci sonunda, hedeflenen örneklem büyüklüğü aşılmış ve toplam 419 araştırma görevlisi hekime ulaşılmıştır. Katılımcıların ana bilim dallarına göre dağılımı şu şekildedir:

-Dahili bilimler asistanları: 234 kişi

-Cerrahi bilimler asistanları: 160 kişi

-Temel tıp bilimleri asistanları: 25 kişi

Bu dağılımla, hem örneklem büyüklüğü istatistiksel açıdan yeterli düzeye ulaşmış hem de tüm ana bilim gruplarının temsili sağlanmıştır.

### 3.5. ARAŞTIRMAYA DAHİL EDİLME VE DIŞLANMA KRİTERLERİ

Dahil edilme kriterleri:

-Kocaeli Üniversitesi Tıp Fakültesi Hastanesi'nde araştırma görevlisi hekim olarak görev yapıyor olmak,

-Araştırmanın yürütüldüğü dönemde kurumda aktif olarak çalışıyor olmak,

-Araştırmaya katılmaya gönüllü olmak ve çevrimiçi veya yazılı bilgilendirilmiş onamı vermek,

-Anket formunu yeterli düzeyde tamamlamış olmak.

Dışlanma kriterleri:

-Araştırma döneminde Kocaeli Üniversitesi Hastanesi'nde aktif görevi bulunmayan hekimler,

-Anket formunu doldurmaya engel ciddi bir sağlık sorunu bulunanlar,

-Anketi büyük oranda eksik dolduran ya da yanıtları istatistiksel analiz için uygun olmayanlar.

## 3.6. VERİ TOPLAMA YÖNTEMİ VE VERİ TOPLAMA ARAÇLARI

Veri toplama aracı olarak standartlaştırılmış bir anket formu kullanılmıştır. Anket formu çevrimiçi ortamda (Google Forms) hazırlanmış, Kocaeli Üniversitesi asistan hekim iletişim grupları üzerinden bağlantı linki paylaşılmıştır. Yüz yüze ulaşılan katılımcılara ise aynı form basılı olarak uygulanmış; doldurulan formlar daha sonra araştırmacı tarafından çevrimiçi forma işlenmiştir. Katılımcılar formun başında yer alan bilgilendirme metnini okuyup "ankete katılmayı onaylıyorum" kutucuğunu işaretleyerek gönüllü olduklarını beyan ettikten sonra sorulara yönlendirilmiştir. Katılım tamamen gönüllülük esasına dayandırılmış, çalışmaya katılmama ya da dilediği anda çalışmadan ayrılma hakkı olduğu tüm katılımcılara belirtilmiştir.

Anketin birinci bölümünde, araştırmacı tarafından literatür taranarak oluşturulmuş ve asistan hekimlerin hem sosyodemografik özelliklerini hem de yapay zekâ/üretken yapay zekâ kullanım özelliklerini değerlendiren 30 soru yer almaktadır.

Sosyodemografik veri formunda yer alan "Kronik hastalık varlığı" sorusu, katılımcıların ankete katılımını kısıtlayabilecek nitelikte bir sağlık sorununun bulunup bulunmadığını belirlemek amacıyla eklenmiştir. Bu ifade, çalışmanın güvenli biçimde yürütülmesini sağlamak ve anket uygulamasına katılımı engelleyebilecek olası durumları önceden saptamaya yönelik olup, kronik hastalık varlığının ÜYZ kullanımına ilişkin istatistiksel analizlerde bağımsız bir değişken olarak kullanılmasını hedeflememektedir.

Anketin ikinci bölümünde, asistan hekimlerin üretken yapay zekâ araçlarını kullanım düzeyleri ve bu araçlara ilişkin yeterlik algılarını değerlendirmek amacıyla "Üretken Yapay Zekâ Kullanım ve Yeterlik (ÜYZKYÖ) Ölçeği" yer almaktadır.[167] Ölçek, Veysel Bilal Arslankara ve Ertuğrul Usta tarafından geliştirilmiş olup toplam 19 maddeden ve iki alt boyuttan oluşmaktadır. Ölçeğin ilk 10 maddesi "Yapay zekâ kullanım yeterliği", son 9 maddesi "YZ destekli öğrenme motivasyonu" alt boyutlarını değerlendirmektedir; 7, 17 ve 18. maddeler ters kodlanmıştır. Pozitif maddeler 1–5 puan arasında değerlendirilmektedir. Toplam puan 19–95 arasında değişmekte olup 19–34 çok düşük, 35–49 düşük, 50–64 orta,

65–79 yüksek, 80–95 çok yüksek düzeyde ÜYZ kullanım ve yeterlik olarak yorumlanmaktadır.

Ölçeğin geliştirilmesine yönelik geçerlik ve güvenirlik çalışmaları sonucunda; iki faktörlü yapının anlamlı olduğu, açıklanan toplam varyansın yeterli düzeyde bulunduğu ve Cronbach alfa katsayılarının hem alt boyutlar hem de toplam ölçek için kabul edilebilir/güçlü iç tutarlılık gösterdiği rapor edilmiştir. Bu tez çalışmasında ölçek, geliştiricilerinden e-posta yoluyla izin alınarak, Türkçe formu ile uygulanmıştır.

### 3.7. İSTATİSTİKSEL ANALİZ

İstatistiksel değerlendirme IBM SPSS 29.0 (IBM Corp., Armonk, NY, USA) programı ile yapıldı. Normal dağılıma uygunluk Kolmogorov-Smirnov ve Shapiro-Wilk testleri ile değerlendirildi. Normal dağılım gösteren değişkenler ortalama ± standart sapma, normal dağılım göstermeyen değişkenler medyan (25.-75. yüzdelik) olarak verildi. Sürekli değişkenler arasındaki ilişki Spearman rho korelasyon testi ile değerlendirildi. Kategorik değişkenler frekans (yüzde) olarak verildi. Gruplar arasındaki farklılık Mann-Whitney U ve Kruskal-Wallis testleri ile belirlendi. Çoklu karşılaştırmalarda Dunn testi kullanıldı. Kategorik değişkenler arasındaki ilişkiler Bonferroni düzeltmesi kullanılarak Ki-kare analizi ile belirlendi. Ölçeğin güvenirlik analizinde Cronbach α iç tutarlılık katsayısı kullanıldı. Hipotez testlerinde $p<0,05$ istatistiksel önemlilik için yeterli kabul edildi.

# 4. BULGULAR

## 4.1. SOSYODEMOGRAFİK ÖZELLİKLER

Çalışmamız Haziran 2025 - Eylül 2025 arasında 419 asistan hekim ile gerçekleştirilmiştir.

Araştırmaya katılan kişilerin yaş ortalaması 29,74 ± 3,66 olarak bulunmuştur (Çizelge 1).

***Çizelge 1. Katılımcı yaşları***

| | **Ort. ± SS (yıl)** | **Min–Maks (yıl)** |
|---|---|---|
| **Yaşınız** | 29,74 ± 3,66 | 20-50 |

Katılımcıların %59,2'si (n=247) kadın, %40,8'i (n=170) erkektir. Medeni durumu sorgulandığında asistan hekimlerin %50,2'si (n=208) evli, %49,8'i (n=206) bekâr olduğunu bildirmiştir. Asistan hekimlerin %77,8'inin (n=326) çocuğu bulunmazken, %22,2'sinin (n=93) en az bir çocuğa sahip olduğu öğrenilmiştir (Çizelge 2).

***Çizelge 2. Katılımcıların cinsiyet, medeni durum ve çocuk sahibi olma durumuna göre dağılımı***

| | | **n*** | **%** |
|---|---|---|---|
| **Cinsiyet** | Kadın | 247 | 59,2 |
| | Erkek | 170 | 40,8 |
| **Medeni durum** | Evli | 208 | 50,2 |
| | Bekâr | 206 | 49,8 |
| **Çocuk durumu** | Çocuğu yok | 326 | 77,8 |
| | En az bir çocuğu var | 93 | 22,2 |

**Toplam n, ilgili soruya yanıt veren katılımcı sayısını göstermektedir.*

Araştırmaya katılanların aktif hekimlik süresi medyan 4 (3–6) yıldır. Katılımcıların mezuniyet yılları 1998 ile 2024 arasında değişmekte olup, ortanca mezuniyet yılı 2020'dir. Büyük çoğunluğun ilk yıllardaki hekimlik döneminde olduğu görülmüştür.

Asistan hekimlerin asistanlıktaki kaçıncı yıllarında olduğu sorgulandığında %36'sı (n=151) 2. yıl ve öncesi, %64'ü (n=268) 2 yıldan uzun olduğu görülmüştür.

Araştırmaya katılan asistan hekimlerin eğitim aldığı uzmanlık alanı sorgulandığında %38'i (n=151) Cerrahi Bilimler, %56'sı (n=234) Dahili Bilimler ve %6'sı (n=25) Temel Bilimler olduğu görülmüştür (Çizelge 3).

***Çizelge 3. Çalışmaya katılanların uzmanlık alanlarına göre dağılımı***

| | **n** | **%** |
|---|---|---|
| **Cerrahi Bilimler** | 151 | 38 |
| **Dahili Bilimler** | 234 | 56 |
| **Temel Bilimler** | 25 | 6 |

Katılımcıların haftalık çalışma süreleri incelendiğinde, en büyük grubun haftada 40–50 saat çalışanlardan oluştuğu (%40,6) görülmüştür. Diğer katılımcılar ise 40 saatin altında (%14,6), 50–60 saat (%14,3), 60–70 saat (%13,8) ve 70 saat ve üzeri (%16,7) çalıştığını bildirmiştir (Çizelge 4).

***Çizelge 4: Haftalık çalışma süresine göre dağılım***

| | **n** | **%** |
|---|---|---|
| **40 saatten az** | 61 | 14,6 |
| **40-50 saat** | 170 | 40,6 |
| **50-60 saat** | 60 | 14,3 |
| **60-70 saat** | 58 | 13,8 |
| **70 saat ve üstü** | 70 | 16,7 |

## 4.2. BİLİŞİM ARACI KULLANIMI VE YAPAY ZEKÂ FARKINDALIĞI

Çalışmaya katılan asistan hekimlerin neredeyse tamamı akıllı telefon ve bilgisayar kullandığını belirtmiş, yaklaşık yarısı tablet, daha küçük bir kısmı ise akıllı saat ve oyun konsolu kullandığını ifade etmiştir. Günlük bilişim aracı kullanım süresi açısından bakıldığında, katılımcıların yaklaşık üçte birinden fazlası günde 3–5 saat, yine önemli bir bölümü 5–7 saat aralığında kullanım bildirmiş; 1 saatten az ya da 7 saatin üzerinde kullanım bildirenler daha sınırlı bir grupta kalmıştır (Çizelge 5).

***Çizelge 5: Katılımcıların bilişim aracı kullanımı ve günlük kullanım süresi***

| | | **n** | **%** |
|---|---|---|---|
| **Kullanılan bilişim araçları*** *(birden fazla seçenek işaretlenebilir)* | Akıllı telefon | 417 | 99,5 |
| | Bilgisayar | 397 | 94,7 |
| | Tablet | 217 | 51,8 |
| | Akıllı saat | 155 | 37 |
| | Oyun konsolu | 67 | 16 |
| | Diğer | 1 | 0,2 |
| **Günlük bilişim aracı kullanım süresi** | 1 saatten az | 4 | 1 |
| | 1–3 saat | 97 | 23,2 |
| | 3–5 saat | 153 | 36,5 |
| | 5–7 saat | 57 | 25,8 |
| | 7 saat ve üzeri | 39 | 13,6 |

*Katılımcılar birden fazla üretken yapay zekâ aracı seçebildiğinden, bu bölümdeki yüzdelerin toplamı %100'ü aşabilmektedir

Katılımcıların yapay zekâ alanındaki gelişmeleri takip etme sıklığına bakıldığında, çoğunluğun gelişmeleri "bazen" takip ettiğini, geri kalanların ise ağırlıklı olarak "sıklıkla" veya "nadiren" yanıtını verdiğini söylemek mümkündür; gelişmeleri her zaman ya da hiç takip ettiğini belirtenler ise oldukça sınırlı bir grubu oluşturmaktadır. YZ teknolojileriyle ilgili öz-değerlendirilen bilgi düzeyi incelendiğinde, katılımcıların yarıdan fazlası kendisini "orta" düzeyde değerlendirirken, kayda değer bir kısmın bilgi düzeyini "kötü/çok kötü" olarak tanımladığı, "iyi/çok iyi" düzeyde olduğunu belirtenlerin ise daha küçük bir grubu oluşturduğu görülmektedir (Çizelge 6).

*Çizelge 6. Katılımcıların yapay zekâ alanındaki gelişmeleri takip etme sıklığı ve yapay zekâ teknolojileriyle ilgili öz-değerlendirilen bilgi düzeyine göre dağılımı*

| | | n | % |
|---|---|---|---|
| **YZ alanındaki gelişmeleri takip etme sıklığı** | Her zaman | 15 | 3,6 |
| | Sıklıkla | 101 | 24,1 |
| | Bazen | 205 | 48,9 |
| | Nadiren | 87 | 20,8 |
| | Hiçbir zaman | 11 | 2,6 |
| **YZ teknolojileriyle ilgili bilgi düzeyi** | Çok iyi | 10 | 2,4 |
| | İyi | 50 | 11,9 |
| | Orta | 234 | 55,8 |
| | Kötü | 113 | 27,0 |
| | Çok kötü | 12 | 2,9 |

## 4.3. ÜRETKEN YAPAY ZEKÂ (ÜYZ) KULLANIM ÖZELLİKLERİ

Çalışmaya katılanların büyük çoğunluğu (%84,7) en az bir üretken yapay zekâ aracı kullandığını belirtmiştir. ÜYZ kullananlar arasında haftalık kullanım süresinin genellikle düşük düzeyde yoğunlaştığı, önemli bir kısmın haftada bir saatten az, bir bölümün ise 1–3 saat aralığında kullanım bildirdiği, daha uzun süre kullananların ise daha sınırlı bir grubu oluşturduğu görülmektedir. Kullanılan ÜYZ araçları değerlendirildiğinde, tercihin neredeyse tamamının ChatGPT üzerinde toplandığı, Google Gemini ve DeepSeek gibi diğer araçların ise daha düşük oranlarda kullanıldığı saptanmıştır (Çizelge 7).

***Çizelge 7. Katılımcıların üretken yapay zekâ araçlarını kullanma durumu, haftalık kullanım süresi ve kullanılan üretken yapay zekâ araçlarına göre dağılımı***

| | | n | % |
|---|---|---|---|
| **ÜYZ araçlarını kullanma durumu** | Evet | 355 | 84,7 |
| | Hayır | 64 | 15,3 |
| **ÜYZ kullanma süresi (haftalık) *** | 1 saatten az | 163 | 45,9 |
| *(yalnızca ÜYZ kullananlar arasında)* | 1–3 saat | 113 | 31,8 |
| | 3–5 saat | 49 | 13,8 |
| | 5–7 saat | 14 | 3,9 |
| | 7 saat ve üzeri | 13 | 3,7 |
| **Kullanılan üretken yapay zekâ araçları**** | ChatGPT (OpenAI) | 351 | 99,2 |
| *(birden fazla seçenek işaretlenebilir)* | Google Gemini (Bard) | 79 | 22,3 |
| | DeepSeek | 36 | 10,2 |
| | DALL·E (OpenAI) | 11 | 3,1 |
| | Midjourney | 4 | 1,1 |
| | Claude (Anthropic) | 4 | 1,1 |
| | ElevenLabs | 1 | 0,3 |
| | Jasper AI | 1 | 0,3 |
| | Replica | 1 | 0,3 |
| | Runway ML | 0 | 0 |
| | Ocaya | 0 | 0 |
| | Writesonic | 0 | 0 |
| | Descript | 0 | 0 |
| | Diğer | 14 | 4 |

* ÜYZ araçları kullanma süresi, yalnızca “ÜYZ araçları kullanıyorum” diyen katılımcılar üzerinden hesaplanmıştır. Ayrıca bu soruyu 2 kişi boş bırakmıştır.
** Katılımcılar birden fazla üretken yapay zekâ aracı seçebildiğinden, bu bölümdeki yüzdelerin toplamı %100’ü aşabilmektedir.

ÜYZ aracı kullanan katılımcıların yaklaşık üçte ikisi herhangi bir ücretli üretken yapay zekâ aracı kullanmadığını, yaklaşık üçte birinin ise en az bir ücretli ÜYZ hizmetinden yararlandığını bildirmiştir. Ücretli ÜYZ kullananlar arasında haftalık kullanım süresinin genellikle 1–3 saat aralığında yoğunlaştığı, daha kısa ya da daha uzun süreli kullanımın ise daha sınırlı bir grupta kaldığı görülmektedir. Ücretli ÜYZ aracı tercihlerine bakıldığında,

kullanıcıların neredeyse tamamının ChatGPT'yi tercih ettiği, diğer ücretli platformların ise oldukça düşük oranlarda kullanıldığı belirlenmiştir (Çizelge 8).

***Çizelge 8. Katılımcıların ücretli üretken yapay zekâ araçlarını kullanma durumu, haftalık kullanım süresi ve kullanılan ücretli üretken yapay zekâ araçlarına göre dağılımı***

| | | n | % |
|---|---|---|---|
| **Ücretli ÜYZ araçlarını kullanma durumu*** | Evet | 139 | 39,4 |
| | Hayır | 214 | 60,6 |
| **Ücretli ÜYZ kullanma süresi (haftalık) **** | 1 saatten az | 37 | 26,8 |
| *(Yalnızca ücretli ÜYZ kullananlar arasında)* | 1–3 saat | 58 | 42,0 |
| | 3–5 saat | 25 | 18,1 |
| | 5–7 saat | 9 | 6,5 |
| | 7 saat ve üzeri | 9 | 6,5 |
| **Kullanılan Ücretli ÜYZ araçları***** | ChatGPT (OpenAI) | 134 | 97,8 |
| *(Birden fazla seçenek işaretlenebilir)* | Midjourney | 1 | 0,7 |
| | ElevenLabs | 0 | 0 |
| | Jasper AI | 0 | 0 |
| | Runway ML | 0 | 0 |
| | Ocaya | 0 | 0 |
| | Writesonic | 0 | 0 |
| | Descript | 0 | 0 |
| | Diğer | 4 | 4,4 |

* Bu soruya yalnızca ÜYZ kullananlar yanıt vermiş olup, 2 kişi yanıt vermemiştir.

**Ücretli ÜYZ araçlarını kullanma süresi, yalnızca "ücretli ÜYZ araçları kullanıyorum" diyen katılımcılar üzerinden hesaplanmıştır.

*** Katılımcılar birden fazla üretken yapay zekâ aracı seçebildiğinden, bu bölümdeki yüzdelerin toplamı %100'ü aşabilmektedir.

Üretken yapay zekâ kullanan asistan hekimlerin yaş ortalaması 29,7±3,4 yıl, kullanmayanların yaş ortalaması ise 30,2±4,7 yıl olup, iki grup arasında yaş açısından istatistiksel olarak anlamlı bir fark saptanmamıştır (p=0,594) (Çizelge 9).

*Çizelge 9. Üretken yapay zekâ kullanma durumuna göre yaş dağılımı*

| | ÜYZ kullanan (n=355) | ÜYZ kullanmayan (n=64) | Toplam (n=419) | p |
|---|---|---|---|---|
| **Yaş (yıl), Ort ± SS** | 29,7 ± 3,4 | 30,2 ± 4,7 | 29,7 ± 3,7 | 0,594 |
| **Yaş (yıl), Medyan (Q1–Q3)** | 29,0 (27,0–31,0) | 29,5 (28,0–32,0) | 29,0 (27,0–31,0) | |
| **Yaş (yıl), Min–Maks** | 24–50 | 20–50 | 20–50 | |

Üretken yapay zekâ (ÜYZ) kullanma durumu, cinsiyet, medeni durum ve çocuk sahibi olma değişkenlerine göre anlamlı fark göstermemiştir (tümü için p>0,05; Çizelge 10).

*Çizelge 10. Üretken yapay zekâ kullanma durumuna göre sosyodemografik özelliklerinin dağılımı (n=419)*

| Değişken | Kategori | ÜYZ kullananlar n (%) | ÜYZ kullanmayanlar n (%) | Toplam n (%) | p* |
|---|---|---|---|---|---|
| **Cinsiyet (S2)** | | | | | |
| | Erkek | 146 (41,2%) | 24 (38,1%) | 170 (40,8%) | **0,678** |
| | Kadın | 208 (58,8%) | 39 (61,9%) | 247 (59,2%) | |
| **Medeni durum (S3)** | | | | | |
| | Bekar | 176 (50,0%) | 30 (48,4%) | 206 (49,8%) | **0,891** |
| | Evli | 176 (50,0%) | 32 (51,6%) | 208 (50,2%) | |
| **Çocuk durumu (S4)** | | | | | |
| | Çocuk yok | 280 (78,9%) | 46 (71,9%) | 326 (77,8%) | **0,282** |
| | En az bir çocuk var | 75 (21,1%) | 18 (28,1%) | 93 (22,2%) | |

Uzmanlık alanı açısından değerlendirildiğinde, cerrahi, dahili ve temel bilimler arasında ÜYZ kullanma oranlarının benzer olduğu ve branşlara göre anlamlı bir farklılık saptanmadığı görüldü (p=0,165). Haftalık çalışma süresi ile ÜYZ kullanımı arasında da belirgin bir farklılık izlenmedi; grupların dağılımları birbirine yakındı (p=0,992). Benzer şekilde, günlük bilişim aracı kullanım süresine göre ÜYZ kullanma oranları anlamlı düzeyde farklılık göstermedi (p=0,725).

***Çizelge 11. Üretken yapay zekâ kullanma durumuna göre çalışma özelliklerinin dağılımı (n=419)***

| Değişken | Kategori | ÜYZ kullananlar n (%) | ÜYZ kullanmayanlar n (%) | Toplam n (%) | p* |
|---|---|---|---|---|---|
| **Uzmanlık alanı (S9)** | | | | | **0,165** |
| | Cerrahi bilimler | 131 (36,9%) | 29 (45,3%) | 160 (38,2%) | |
| | Dahili bilimler | 200 (56,3%) | 34 (53,1%) | 234 (55,8%) | |
| | Temel bilimler | 24 (6,8%) | 1 (1,6%) | 25 (6,0%) | |
| **Haftalık çalışma süresi (S10)** | | | | | **0,992** |
| | 40 saatten az | 52 (14,6%) | 9 (14,1%) | 61 (14,6%) | |
| | 40–50 saat | 145 (40,8%) | 25 (39,1%) | 170 (40,6%) | |
| | 50–60 saat | 51 (14,4%) | 9 (14,1%) | 60 (14,3%) | |
| | 60–70 saat | 49 (13,8%) | 9 (14,1%) | 58 (13,8%) | |
| | 70 saat ve üzeri | 58 (16,3%) | 12 (18,8%) | 70 (16,7%) | |
| **Günlük bilişim süresi (S12)** | | | | | **0,725** |
| | 1 saatten az | 3 (0,8%) | 1 (1,6%) | 4 (1,0%) | |
| | 1–3 saat | 79 (22,3%) | 18 (28,1%) | 97 (23,2%) | |
| | 3–5 saat | 132 (37,2%) | 21 (32,8%) | 153 (36,5%) | |
| | 5–7 saat | 94 (26,5%) | 14 (21,9%) | 108 (25,8%) | |
| | 7 saat ve üzeri | 47 (13,2%) | 10 (15,6%) | 57 (13,6%) | |

## 4.4. ÜYZ KULLANIM ALANLARI (MESLEKİ VE MESLEK DIŞI)

Çalışmada ÜYZ kullanan asistan hekimlerin büyük çoğunluğunun (%92,2 ; n=320) bu araçları mesleki alanlarda kullandığı, yalnızca küçük bir kısmının (%7,8 ; n=27) meslek dışı kullanım bildirmediği görülmüştür. Bunun yanı sıra hastalık teşhisi ve tanı, tedavi planlaması, tıbbi görüntüleme, istatistiksel hesaplamalar, simülasyon ve sanal hasta uygulamaları gibi alanlarda kullanım oranları daha düşük düzeyde kalmıştır (Çizelge 12).

***Çizelge 12. Katılımcıların üretken yapay zekâ araçlarını meslekle ilgili konularda kullanma durumu ve mesleki kullanım alanlarına göre dağılımı***

| | | n | % |
|---|---|---|---|
| **ÜYZ'yi meslekle ilgili konularda kullanma durumu *** | Evet | 320 | 92,2 |
| | Hayır | 27 | 7,8 |
| **Mesleki ÜYZ kullanım alanları **** | Hastalık teşhisi ve tanı | 118 | 37,0 |
| | Yapay zekâ destekli çeviri | 221 | 69,2 |
| | Tedavi planlaması ve kişiselleştirilmiş sağlık | 67 | 21,0 |
| | Eğitim materyali oluşturma (sunum vb.) | 205 | 64,5 |
| | Tıbbi görüntüleme ve radyoloji | 45 | 14,1 |
| | Tıbbi araştırma (literatür tarama vb.) | 233 | 73,0 |
| | İstatistiksel hesaplamalar | 74 | 23,1 |
| | Simülasyon ve sanal hastalar | 25 | 7,8 |
| | Diğer | 4 | 1,3 |

* ÜYZ'yi meslekle ilgili konularda kullanma durumu , üretken yapay zekâ kullanan (n=355) katılımcılar üzerinden hesaplanmıştır. 8 katılımcı bu soruyu boş bırakmıştır.

** Mesleki ÜYZ kullanım alanları , yalnızca ÜYZ'yi meslekle ilgili konularda kullanma durumu sorusuna "Evet" yanıtı veren katılımcılar (n=320) için değerlendirilmiş olup, birden fazla seçenek işaretlenebildiğinden yüzdelerin toplamı %100'ü aşabilmektedir.

Çalışmada ÜYZ kullanan asistan hekimlerin büyük çoğunluğunun (%94,4; n=334) bu araçları meslek dışı alanlarda da kullandığı, yalnızca küçük bir kısmının (%5,6; n=20) meslek dışı kullanım bildirmediği görülmüştür.

Meslek dışı kullanım alanları incelendiğinde, ÜYZ'nin en sık eğitim ve öğrenme yardımcıları (%68,6), eğlence amaçlı (%51,5), konuşma ve sohbet etme (%35,3) ve görsel tasarım/grafik oluşturma (%31,7) için kullanıldığı saptanmıştır. Diğer kullanım alanları ise daha düşük oranlarda bildirilmiştir (Çizelge 13).

***Çizelge 13. Katılımcıların üretken yapay zekâ araçlarını meslek dışı konularda kullanma durumu ve meslek dışı kullanım alanlarına göre dağılımı***

| | | **n** | **%** |
|---|---|---|---|
| **ÜYZ'yi meslek dışı konularda kullanma durumu *** | Evet | 334 | 94,4 |
| | Hayır | 20 | 5,6 |
| **Meslek dışı ÜYZ kullanım alanları (S24)**** | İçerik üretimi ve yaratıcılık | 73 | 21,9 |
| | Görsel tasarım ve grafik oluşturma | 106 | 31,7 |
| | Video ve fotoğraf düzenleme | 77 | 23,1 |
| | Eğitim ve öğrenme yardımcıları | 229 | 68,6 |
| | Sosyal medya içerik planlaması | 41 | 12,3 |
| | Konuşma ve sohbet etmek | 118 | 35,3 |
| | Eğlence amaçlı | 172 | 51,5 |
| | Yaratıcı metinler yazma | 55 | 16,5 |
| | Diğer | 10 | 3,0 |

* ÜYZ'yi meslek dışı konularda kullanma durumu , üretken yapay zekâ kullanan (n=355) katılımcılar üzerinden hesaplanmıştır. 1 katılımcı bu soruyu boş bırakmıştır.

** Meslek dışı ÜYZ kullanım alanları , yalnızca ÜYZ'yi meslek dışı konularda kullanma durumu sorusuna "Evet" yanıtı veren katılımcılar (n=334) için değerlendirilmiş olup, birden fazla seçenek işaretlenebildiğinden yüzdelerin toplamı %100'ü aşabilmektedir.

## 4.5. ÜYZ'YE YÖNELİK TUTUMLAR VE TEZ SÜRECİYLE İLİŞKİLİ BULGULAR

Katılımcıların büyük çoğunluğu, tıp alanında üretken yapay zekânın destekleyici amaçla kullanımının yaygınlaşmasını istediğini belirtmiştir; buna göre asistan hekimlerin %94,3'ü (n=395) "Evet" yanıtını verirken, %5,7'si (n=24) bu yaygınlaşmayı istemediğini ifade etmiştir . Tıp alanında ÜYZ kullanımının yaygınlaşmasının kendilerinde endişe oluşturup oluşturmadığına ilişkin soruya ise katılımcıların %24,1'i (n=101) "Evet", %75,9'u (n=318) "Hayır" yanıtını vermiştir(Çizelge 14).

***Çizelge 14. Katılımcıların tıp alanında üretken yapay zekâ kullanımının yaygınlaşmasına ilişkin görüşleri ve bu durumun yol açtığı endişe durumuna göre dağılımı***

| | | n | % |
|---|---|---|---|
| **Tıp alanında ÜYZ'nin destekleyici amaçla kullanımının yaygınlaşmasını ister misiniz? (S25)** | Evet | 395 | 94,3 |
| | Hayır | 24 | 5,7 |
| **Tıp alanında ÜYZ kullanımının yaygınlaşması sizde endişeye yol açar mı? (S26)** | Evet | 101 | 24,1 |
| | Hayır | 318 | 75,9 |

Tıpta ÜYZ'nin destekleyici amaçla kullanımının yaygınlaşmasını isteme durumu ile bu yaygınlaşmanın endişe yaratması arasında istatistiksel olarak anlamlı bir ilişki saptandı ($p<0,001$). ÜYZ'nin yaygınlaşmasını isteyen katılımcıların %78,5'i (n=310) bu durumun kendilerinde endişe oluşturmadığını, %21,5'i (n=85) ise endişe duyduğunu belirtirken; yaygınlaşmasını istemeyen grupta endişe oranı belirgin derecede yüksekti (%66,7; n=16). Toplamda katılımcıların yaklaşık dörtte üçü "yaygınlaşsın ve endişe duymuyorum" (%74,0), beşte biri ise "yaygınlaşsın ama endişeliyim" (%20,3) grubunda yer almıştır (Çizelge 15).

*Çizelge 15. Tıp alanında üretken yapay zekânın yaygınlaşmasını isteme ile yaygınlaşmanın endişe yaratması arasındaki ilişki*

| S25 – Tıpta ÜYZ'nin yaygınlaşmasını ister misiniz? | S26 – ÜYZ'nin yaygınlaşması bende endişe yaratmaz (Hayır) n (%) | S26 – ÜYZ'nin yaygınlaşması bende endişe yaratır (Evet) n (%) | Toplam n (%) |
|---|---|---|---|
| **Hayır, yaygınlaşmasını istemem (S25=0)** | 8 (33,3) | 16 (66,7) | 24 (100,0) |
| **Evet, yaygınlaşmasını isterim (S25=1)** | 310 (78,5) | 85 (21,5) | 395 (100,0) |
| **Toplam** | 318 (75,9) | 101 (24,1) | 419 (100,0) |

Katılımcıların %54,9'u tez ile ilgili çalışmalara başladığını belirtmiş; tez çalışmalarına başlayanlar arasında en sık 'tez savunması ve sınavı' ve 'tez konusu belirleme' aşamalarında bulunulduğu bildirilmiştir (Çizelge 16).

*Çizelge 16. Katılımcıların tez çalışmaları ve tez aşamalarına göre dağılımı*

| | | n | % |
|---|---|---|---|
| **Tez ile ilgili çalışmalara başladınız mı?** | Evet | 230 | 54,9 |
| | Hayır | 189 | 45,1 |
| **Şu an tezde hangi aşamadasınız?*** | Tez konusunu belirleme | 52 | 22,6 |
| | Etik kurul onayı | 23 | 10,0 |
| | Literatür tarama / hipotez oluşturma | 8 | 3,5 |
| | Araştırma yöntemi / örneklem belirleme | 3 | 1,3 |
| | Veri toplama | 42 | 18,3 |
| | Veri analizi / istatistik | 11 | 4,8 |
| | Tez yazma | 36 | 15,7 |
| | Tez savunması ve sınavı | 55 | 23,9 |

* S28, yalnızca tez çalışmalarına başladığını belirten katılımcılar(n=230) üzerinden hesaplanmıştır.

Tez hazırlığında üretken yapay zekâ araçlarından yararlandığını belirten katılımcılar, en sık literatür tarama/hipotez oluşturma ve tez yazma aşamalarında bu araçları kullandıklarını ifade etmiştir. Asistan hekimlerin %89,7 si tez ile ilgili çalışmalarda ÜYZ araçlarını kullanmayı düşündüğünü belirtirken, %10,3'ü kullanmayı düşünmediğini bildirmiştir (Çizelge 17).

***Çizelge 17. Tezde ÜYZ kullanımı ve kullanma niyeti***

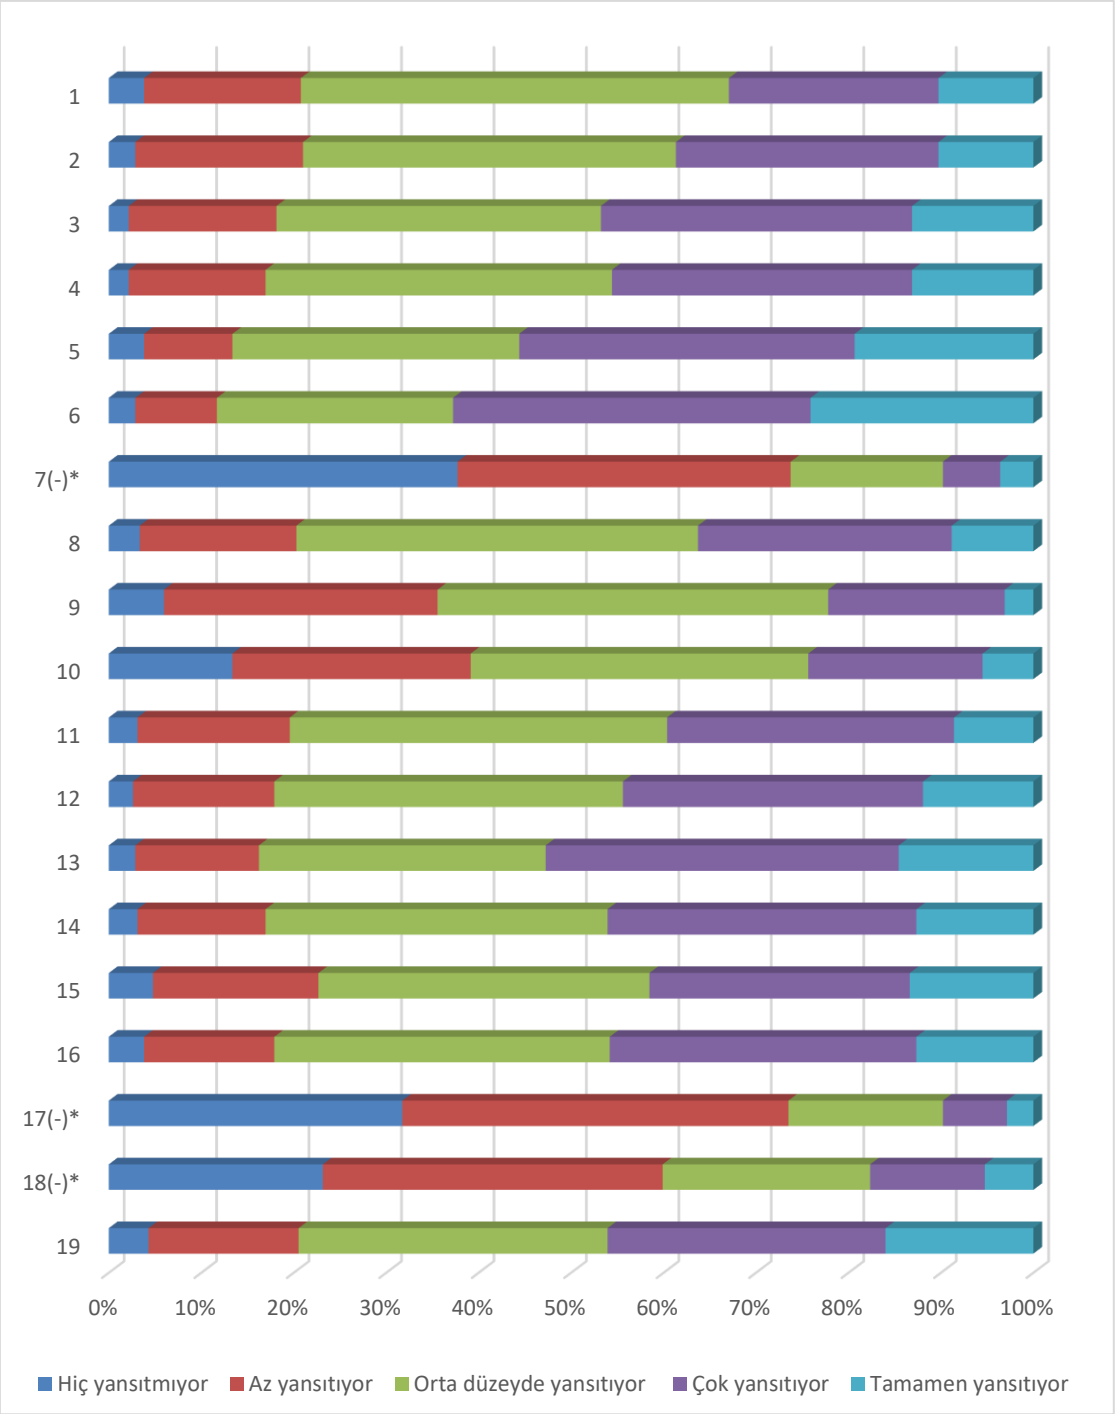
| | | n | % |
|---|---|---|---|
| **Tez hazırlarken ÜYZ'den yardım alınan aşamalar *** | Herhangi bir yardım almadım | 97 | 42,2 |
| | Tez konusunu belirleme | 37 | 16,1 |
| | Etik kurul onayı | 31 | 13,5 |
| | Literatür tarama / hipotez oluşturma | 69 | 30,0 |
| | Araştırma yöntemi / örneklem belirleme | 24 | 10,4 |
| | Veri toplama | 11 | 4,8 |
| | Veri analizi / istatistik | 22 | 9,6 |
| | Tez yazma | 55 | 23,9 |
| | Tez savunması ve sınavı | 6 | 2,6 |
| **Tez ile ilgili çalışmalarda ÜYZ kullanmayı düşünür müsünüz?** | Evet | 376 | 89,7 |
| | Hayır | 43 | 10,3 |

* Tez hazırlığına başlayan tüm katılımcılar üzerinden değerlendirilmiş olup(n=230) , birden fazla seçenek işaretlenebildiğinden yüzdelerin toplamı %100'ü aşabilmektedir.

## 4.6. ÜRETKEN YAPAY ZEKÂ KULLANIM VE YETERLİK ÖLÇEĞİ BULGULARI

ÜYZKYÖ madde düzeyindeki yanıtlar incelendiğinde, ölçeğin her iki faktöründe de olumlu maddelere verilen yanıtların büyük ölçüde "orta düzeyde" ve üzeri kategorilerde yoğunlaştığı, ters kodlanan maddelerde ise yanıtların çoğunlukla "hiç yansıtmıyor" ve "az yansıtıyor" seçeneklerinde toplandığı saptanmıştır (Çizim 1).

Çizim 1. ÜYZKYÖ ölçeği maddelerine verilen yanıtların dağılımı




* Ters kodlanan maddeler: 7., 17. ve 18. maddeler ölçeğin olumsuz ifadeleridir ve toplam/alt boyut puanları hesaplanırken ters puanlanmıştır.

ÜYZKYÖ toplam puanları için tüm katılımcılardan geçerli veri elde edilmiştir (N=419). Toplam puan ortalaması 64,36±12,21, medyanı 64,00 ve puan aralığı 30–95 olarak

bulunmuştur (Çizelge 19). Ölçek için tanımlanan düzey aralıkları dikkate alındığında, katılımcıların yaklaşık %39'unun orta, %38'inin yüksek, %12'sinin çok yüksek; yaklaşık %11'inin ise düşük veya çok düşük düzeyde ÜYZKYÖ toplam puanı aldığı saptanmıştır (Çizelge 19).

Alt boyut puanları incelendiğinde, "Yapay zekâ kullanım yeterliği" alt boyutunda ortalamanın 33,34±6,86 (min–maks: 14–50), "Yapay zekâ destekli öğrenme motivasyonu" alt boyutunda ise 31,02±5,99 (min–maks: 14–45) olduğu görülmüştür. Her iki alt boyutta da 25.–75. persentil aralıklarının orta–üst düzeyde yoğunlaştığı ve madde başına ortalama puanın yaklaşık 3,3–3,4/5 düzeyinde seyrettiği belirlenmiştir (Çizelge 19).

Ölçeğin iç tutarlılık katsayıları, "Yapay zekâ kullanım yeterliği" alt boyutu için Cronbach α=0,88, "Yapay zekâ destekli öğrenme motivasyonu" alt boyutu için α=0,83 ve toplam ölçek için α=0,92 olarak hesaplanmış; bu değerler ölçeğin bu örneklemde yüksek iç tutarlılık gösterdiğini ortaya koymuştur (Çizelge 18).

***Çizelge 18. Üretken Yapay Zekâ Kullanım ve Yeterlik Ölçeği alt boyut ve toplam puanları***

| **Ölçek / Alt boyut** | **Madde sayısı** | **Min–Maks** | **Ort ± SS** | **Cronbach α** |
|---|---|---|---|---|
| **ÜYZKYÖ Faktör 1 – Yapay zekâ kullanım yeterliği** | 10 | 14–50 | 33,34 ± 6,86 | 0,88 |
| **ÜYZKYÖ Faktör 2 – YZ destekli öğrenme motivasyonu** | 9 | 14–45 | 31,02 ± 5,99 | 0,83 |
| **ÜYZKYÖ Toplam puan** | 19 | 30–95 | 64,36 ± 12,21 | 0,92 |

Spearman korelasyon analizine göre yaş ile ÜYZKYÖ toplam puanı arasında zayıf ve istatistiksel olarak anlamlı olmayan, negatif yönlü bir ilişki belirlenmiştir (r=-0,08; p=0,102). Yaş ile ÜYZKYÖ Faktör 1 (Yapay zekâ kullanım yeterliği) puanı arasında zayıf

düzeyde, negatif yönlü ve istatistiksel olarak anlamlı bir ilişki saptanmıştır (r=-0,11; p=0,030). Buna karşın yaş ile ÜYZKYÖ Faktör 2 (YZ destekli öğrenme motivasyonu) puanı arasında istatistiksel olarak anlamlı bir ilişki bulunmamıştır (r=-0,05; p=0,335). (Çizelge 19).

***Çizelge 19. Yaş ile ÜYZKYÖ arasındaki ilişki***

| **Yaş (yıl) ile ilişki** | **n** | **Spearman korelasyon katsayısı (r)** | **p *** |
|---|---|---|---|
| **ÜYZKYÖ toplam puanı** | 419 | -0,080 | 0,102 |
| **YZ kullanım yeterliği** | 419 | -0,106 | 0,030 |
| **YZ destekli öğrenme motivasyonu** | 419 | -0,047 | 0,335 |

* Spearman's rho korelasyon testi; p<0,05 istatistiksel olarak anlamlı kabul edilmiştir.

Çalışmada ÜYZKYÖ toplam puanı ile "Yapay Zekâ Kullanım Yeterliği" ve "Yapay Zekâ Destekli Öğrenme Motivasyonu" alt boyutlarının cinsiyet, medeni durum ve çocuk sahibi olma durumuna göre dağılımı incelenmiştir (Çizelge 21). Cinsiyete göre bakıldığında, erkek hekimlerin ÜYZKYÖ toplam puanlarının kadın hekimlere göre anlamlı düzeyde daha yüksek olduğu saptanmıştır (medyanlar sırasıyla 67,00 ve 63,00; p=0,004). Benzer şekilde, her iki alt boyutta da erkeklerin puanları kadınlara göre daha yüksektir (p=0,001 ve p=0,040). Medeni duruma göre yapılan karşılaştırmada, bekar ve evli hekimler arasında ÜYZKYÖ toplam puanı ve alt boyut puanları açısından anlamlı bir fark bulunmamıştır (tümü için p>0,05). Buna karşılık, çocuk sahibi olma durumuna göre ÜYZKYÖ toplam puanları ve alt boyut puanları anlamlı biçimde farklılaşmış; çocuğu olmayan hekimlerin hem toplam ölçekte hem de iki alt boyutta çocuğu olanlara kıyasla daha yüksek puan aldığı belirlenmiştir (toplam puan için p=0,009; alt boyutlar için p=0,011 ve p=0,014; Çizelge 20).

*Çizelge 20. ÜYZKYÖ toplam puanının demografik değişkenlere göre dağılımı*

| Değişken | ÜYZKYÖ Toplam Puan | Yapay Zekâ Kullanım Yeterliği | Yapay Zekâ Destekli Öğrenme Motivasyonu |
|---|---|---|---|
| **CİNSİYET** | | | |
| Erkek (n=170) | 67,00 (57,00–74,00) | 35,00 (30,00–39,00) | 32,00 (27,00–36,00) |
| Kadın (n=247) | 63,00 (55,00–72,00) | 32,00 (28,00–37,00) | 30,00 (27,00–35,00) |
| **p-değeri** | **0,004** | **0,001** | **0,040** |
| **MEDENİ DURUM** | | | |
| Bekar (n=206) | 65,00 (57,00–73,00) | 34,00 (30,00–38,00) | 31,00 (27,00–36,00) |
| Evli (n=208) | 64,00 (55,00–73,25) | 33,00 (28,00–38,00) | 31,00 (27,00–35,00) |
| **p-değeri** | **0,244** | **0,213** | **0,393** |
| **ÇOCUK DURUMU** | | | |
| Var (n=93) | 62,00 (52,00–71,00) | 31,00 (26,00–37,50) | 30,00 (25,50–34,00) |
| Yok (n=326) | 65,00 (57,00–73,00) | 34,00 (30,00–38,00) | 31,00 (27,00–36,00) |
| **p-değeri** | **0,009** | **0,011** | **0,014** |

Asistan hekimlerin uzmanlık alanına göre ÜYZKYÖ toplam ve alt boyut puanlarının dağılımı Çizelge 21'de gösterilmiştir. Yapılan istatistiksel analizler, uzmanlık alanı ile ÜYZKYÖ toplam puanı ve "Yapay Zekâ Kullanım Yeterliği" ile "Yapay Zekâ Destekli Öğrenme Motivasyonu" alt boyut puanları arasında anlamlı farklılık olduğunu ortaya koymuştur (toplam puan için p=0,002; alt boyutlar için p=0,007 ve p=0,001).ÜYZKY toplam puan medyanı cerrahi bilimlerde 62, dahili bilimlerde 64 iken, temel bilimlerde 73 'tür(Çizelge 21). Yapılan post-hoc ikili karşılaştırmalar, temel bilimlerde çalışan asistan hekimlerin ÜYZKYÖ toplam puanı ve her iki alt boyut puanının da cerrahi ve dahili bilimlerde çalışanlara göre anlamlı düzeyde daha yüksek olduğunu, cerrahi ve dahili bilimler arasında ise anlamlı fark bulunmadığını göstermiştir.

***Çizelge 21. Uzmanlık alanına göre ÜYZKYÖ toplam puanlarının dağılımı***

| | **Cerrahi Bilimler (n=160) Medyan (Q1–Q3)** | **Dahili Bilimler (n=234) Medyan (Q1–Q3)** | **Temel Bilimler (n=25) Medyan (Q1–Q3)** | **p** |
|---|---|---|---|---|
| **ÜYZKY Toplam Puan** | 62,00 (56,00–71,00) | 64,00 (57,00–73,00) | 73,00 (65,50–78,50) | **0,002** |
| **Yapay Zekâ Kullanım Yeterliği** | 33,00 (29,00–38,00) | 33,00 (29,00–38,00) | 38,00 (33,50–41,00) | **0,007** |
| **Yapay Zekâ Destekli Öğrenme Motivasyonu** | 29,00 (26,00–35,00) | 32,00 (27,00–36,00) | 35,00 (31,50–37,50) | **0,001** |

Haftalık çalışma süresi kategorilerine göre ÜYZKYÖ toplam puanı ve alt boyut puanlarının medyan değerleri Çizelge 22'de gösterilmiştir. Yapılan istatistiksel değerlendirme sonucunda, haftalık çalışma süresi ile ÜYZKYÖ toplam puanı (p=0,296), "Yapay Zekâ Kullanım Yeterliği" (p=0,369) ve "Yapay Zekâ Destekli Öğrenme Motivasyonu" (p=0,117) arasında istatistiksel olarak anlamlı bir fark saptanmamıştır. Çalışma süresi 40 saatin altında olan, 40–50, 50–60, 60–70 ve 70 saat ve üzerinde çalışan gruplarda ÜYZKYÖ toplam puan medyanlarının birbirine yakın seyrettiği ve haftalık çalışma süresi arttıkça puanlarda belirgin bir artış ya da azalış eğilimi görülmediği dikkati çekmektedir (Çizelge 22).

***Çizelge 22. Haftalık çalışma saatine göre ÜYZKYÖ toplam puanlarının dağılımı***

| **Haftalık çalışma süresi** | **ÜYZKY Toplam Puan Medyan (Q1–Q3)** | **YZ Kullanım Yeterliği Medyan (Q1–Q3)** | **YZ Destekli Öğrenme Motivasyonu Medyan (Q1–Q3)** |
|---|---|---|---|
| **40 saatten az (n=61)** | 65,00 (59,50–76,00) | 34,00 (29,50–39,00) | 32,00 (29,50–36,50) |
| **40–50 saat (n=170)** | 64,00 (55,75–73,00) | 33,00 (28,00–38,00) | 31,00 (27,00–35,00) |
| **50–60 saat (n=60)** | 63,50 (56,00–73,25) | 32,50 (28,25–36,00) | 30,00 (27,00–35,00) |
| **60–70 saat (n=58)** | 63,00 (56,00–71,25) | 31,00 (28,00–37,25) | 29,50 (26,75–36,00) |
| **70 saat ve üzeri (n=70)** | 66,50 (57,00–75,00) | 35,00 (30,00–40,00) | 31,00 (27,00–37,00) |
| **p** | **0,296** | **0,369** | **0,117** |

## 5. TARTIŞMA

Araştırmamız, Kocaeli Üniversitesi Tıp Fakültesi'nde çalışan, çoğunluğu 30'lu yaşların başında olan ve uzmanlık eğitiminin ilk yıllarındaki görece genç asistan hekimleri kapsamaktadır. Bu durum, mesleki deneyim süresinin henüz sınırlı olduğunu ve katılımcıların yoğun klinik iş yükü altında, yeni teknolojilerin hızla gündeme girdiği bir dönemde eğitim aldığını göstermektedir. Cinsiyet dağılımında kadınlarda hafif bir üstünlük vardır. Katılımcıların yaklaşık yarısı evli olsa da önemli bir kısmının henüz çocuğu yoktur. Bu bulgular, ÜYZ kullanımına ve ÜYZ'ye yönelik tutumlara ilişkin sonuçların, daha çok genç ve aile sorumluluğu görece az olan bir hekim grubunu yansıttığını düşündürmektedir.

Örneklemimizin önemli bir bölümü, asistanlığın ileri yıllarındaki hekimlerden oluşmaktadır. Bu hekimler, klinik ve akademik sorumlulukları artmış, yoğun çalışan ve aynı zamanda sınav ve tez süreciyle uğraşan bir gruptur. Bu nedenle, ÜYZ kullanımına ilişkin bulguların, bu yoğun iş yükü ile sınav ve tez baskısı göz önünde bulundurularak yorumlanması gerektiği düşünülmelidir.

Bizim çalışmamızda yer alan asistan hekimlerin çoğu dahili ve cerrahi branşlarda, hastanede çalışan hekimlerdir. Temel bilimlerde çalışan hekim sayısı daha az olduğu için, bulgularımızın özellikle klinikte aktif çalışan branşlar için daha açıklayıcı olduğu, temel bilimler için ise genelleme yapılırken daha dikkatli olunması gerektiğini düşünülebilir.

Çalışmamızda haftalık çalışma sürelerine bakıldığında, asistan hekimlerin önemli bir kısmının 40 saatin oldukça üzerinde çalıştığı ve yoğun mesai ile nöbet yükü taşıdığı görülmektedir. Bu durum, klinik ve akademik beklentilerin yüksek olduğu, zaman baskısının da belirgin hissedildiği bir çalışma ortamını göstermektedir. Böyle bir ortamda üretken yapay zekâ araçlarının, klinik iş akışını sadeleştirme, dokümantasyonu hızlandırma ve karar vermeyi destekleme açısından daha çok ihtiyaç duyulan bir araç hâline geldiği düşünülebilir.

Katılımcıların neredeyse hepsi akıllı telefon ve bilgisayar yaklaşık yarısı ise tablet kullanmaktadır. Bu durum, hekimlerin birden fazla dijital platforma aktif olarak erişebildiğini göstermektedir. Günlük dijital cihaz kullanım süresinin çoğunlukla birkaç saatin üzerinde olması ve sadece az sayıda katılımcının günde bir saatten az kullandığını belirtmesi, asistan hekimlerin hem klinik hem de sosyal yaşamlarında yoğun bir dijital maruziyete sahip olduğunu düşündürmektedir. Bu dijital profil, üretken yapay zekâ temelli

karar destek ve eğitim uygulamalarının yaygınlaştırılması için uygun ve güçlü bir zemin sunmaktadır.

Çalışmamızda asistan hekimlerin sadece küçük bir kısmının yapay zekâ alanındaki gelişmeleri düzenli ve sürekli takip ettiği görülmüştür. Katılımcıların çoğu bu gelişmeleri daha çok "ara sıra" izlediğini belirtirken, kayda değer bir grup ise neredeyse hiç takip etmediğini söylemiştir. Özellikle "her zaman" ve "sıklıkla" takip ettiğini belirtenlerin oranının düşük kalması, yapay zekâya ilginin tüm gruba eşit dağılmadığını düşündürmektedir. Oysa ülkemizde üniversite öğrencileriyle yapılan bir çalışmada, katılımcıların büyük çoğunluğu (Evet+Kısmen=%79,3) yapay zekâ teknolojilerindeki gelişmeleri yakından takip ettiğini bildirmiştir.[168] Bu durum, genç nüfus ve öğrencilerde yüksek olan YZ takibinin, asistan hekimlik döneminde artan klinik ve kurumsal iş yükü gibi nedenlerle daha sınırlı kalabildiğine işaret ediyor olabilir.

Yapay zekâ ile ilgili öznel bilgi düzeyine baktığımızda, asistan hekimlerin önemli bir kısmı kendini "orta" düzeyde görmektedir. Bunun yanında, kayda değer bir grup bilgi düzeyini "kötü/çok kötü" olarak tanımlarken, daha küçük bir grup kendisini "iyi" ya da "çok iyi" düzeyde değerlendirmektedir. Benzer şekilde, Pakistan'da sağlık alanındaki lisans öğrencileriyle yapılan bir çalışmada da yapay zekâ ile ilgili öznel bilgi düzeyi "orta" olarak bildirilmiştir.[169] Yunanistan'da sağlık personeliyle yapılan bir çalışmada da genel yapay zekâ bilgi düzeyi yine "orta" bulunmuştur.[170] Hem gelişmeleri takip etme sıklığının hem de öznel bilgi düzeyinin çoğunlukla "orta" düzeyde olması, asistan hekimler arasında yapay zekâya yönelik bir farkındalık ve ilgi olduğunu, ancak bu ilginin henüz derin ve güvenli bir bilgi düzeyine tam olarak dönüşmediğini düşündürmektedir. Bu durum, özellikle aile hekimliği pratiğinde klinik kararlara entegre edilecek yapay zekâ uygulamaları için yapılandırılmış eğitim programlarına ve yol gösterici kurumsal politikalara ihtiyaç olduğunu göstermektedir.

Çalışmamızda asistan hekimlerin büyük çoğunluğunun (%84,7; n=355) en az bir üretken yapay zekâ aracını kullandığı, daha küçük bir grubun ise (%15,3; n=64) hiç ÜYZ aracı kullanmadığı görülmüştür. Benzer şekilde, Kanada'da tıp öğrencileriyle yapılan bir çalışmada ÜYZ kullanım oranı %78,9, Mısır'da tıp öğrencileriyle yapılan bir çalışmada %89,8, Almanya'da tıp öğrencilerine yönelik yapılan bir başka çalışmada ise ChatGPT kullanım oranı %76,2 olarak bildirilmiştir.[171–173] Bu sonuçlar birlikte ele alındığında,

üretken yapay zekâ araçlarının hem tıp öğrencileri hem de asistan hekimler için artık yeni veya sadece merak için denenen bir teknoloji olmaktan çıktığı söylenebilir. Aksine, bu araçlar klinik eğitim, bilimsel çalışma ve kişisel kullanımda giderek daha fazla yer alan, günlük rutine girmiş araçlar hâline gelmiştir.

Bizim çalışmamızda ÜYZ araçlarını kullanan asistan hekimlerin haftalık kullanım sürelerine baktığımızda, kullanımın yaygın olduğunu ama çoğunlukla düşük–orta düzeyde kaldığını görüyoruz. Katılımcıların yaklaşık yarısı haftada "1 saatten az", önemli bir kısmı ise "1–3 saat" arası ÜYZ kullandığını söylemiştir. Bu durum, hekimlerin bu araçları genelde kısa süreli ve sınırlı şekilde kullandığını düşündürüyor. Haftada 3 saatin üzerinde kullanım bildirenlerin ("3–5 saat", "5–7 saat" ve "7 saat ve üzeri") giderek azalması da bunu destekliyor. Literatürde ise ChatGPT ve benzeri araçların daha çok günlük ya da haftalık kullanım sıklığı üzerinden değerlendirildiği görülmektedir. Örneğin, Zhang ve arkadaşları tıp öğrencilerinin yaklaşık yarısının bu aracı haftalık veya günlük düzeyde kullandığını bildirmiştir.[174] Bizim bulgularımız da asistan hekimlerin ÜYZ araçlarını daha çok belirli klinik veya akademik işleri kolaylaştıran "destekleyici" bir araç gibi gördüğünü, ancak kullanımın henüz günlük çalışma rutinine tam olarak yerleşmediğini göstermektedir.

Kullanılan ÜYZ araçlarının türlerine bakıldığında, asistan hekimlerin tercihlerinin belirgin biçimde birkaç platformda yoğunlaştığı görülmektedir. ÜYZ kullandığını bildiren katılımcıların neredeyse tamamının ChatGPT'yi tercih etmesi (%99,2; n=351), bu aracın asistan hekimler arasında açık ara baskın konumda olduğunu göstermektedir. Ülkemizde tıp ve diş hekimlerine yönelik yapılan bir çalışmada katılımcıların %90,2'sinin ChatGPT, %9,8'inin ise DALL-E gibi üretken araçları kullandığını bildirmesi; ayrıca Kanada'da yapılan çalışmada da benzer şekilde %90,8 oranında ChatGPT kullanımının saptanmış olması, bu sonucu desteklemektedir.[171,175] Bu tablo, asistan hekimlerin ÜYZ deneyiminin büyük ölçüde tek bir metin tabanlı büyük dil modeli etrafında şekillendiğini düşündürmektedir.

Bununla birlikte, ChatGPT dışındaki araçların da az da olsa kullanılmaya başlandığı görülmektedir. Google Gemini kullanımının %22,3 (n=79), DeepSeek kullanımının ise %10,2 (n=36) olması, asistan hekimler arasında araç çeşitliliğinin yavaş yavaş arttığını göstermektedir. Öte yandan, DALL·E (%3,1; n=11), Midjourney (%1,1; n=4), Claude (%1,1; n=4), ElevenLabs, Jasper AI ve Replica gibi görsel, ses veya farklı türde içerik

üreten araçların çok az sayıda kullanıcıya sahip olması, ÜYZ kullanımının hâlâ daha çok metin üretme, özetleme, soru–yanıt ve yazılı içerik düzenleme gibi işlevlerde yoğunlaştığını göstermektedir. Bu durum, asistan hekimlerin üretken yapay zekâyı ağırlıklı olarak klinik ve akademik metin işlerinde "yardımcı bir araç" olarak gördüğünü; görsel, ses veya video tabanlı modellerin ise henüz günlük pratiklerine anlamlı düzeyde girmediğini düşündürmektedir.

Genel olarak bu tablo, asistan hekimler arasında ÜYZ araçlarının yüksek oranda benimsendiğini, ancak kullanımın yoğunluk ve çeşitlilik açısından hâlâ tam olarak oturmadığını göstermektedir. Katılımcıların büyük çoğunluğunun en az bir ÜYZ aracı kullanıyor olması, bu teknolojilerin genç hekimler tarafından benimsendiğine işaret etmektedir. Buna karşılık, haftalık kullanım sürelerinin görece düşük olması ve kullanımın neredeyse tamamen tek bir platformda (ChatGPT) toplanması, ÜYZ entegrasyonunun henüz derin ve çok yönlü bir yapıya ulaşmadığını düşündürmektedir.

Çalışmamızda asistan hekimlerin büyük kısmının üretken yapay zekâ (ÜYZ) araçlarını sadece ücretsiz sürümler üzerinden kullandığı, ücretli ÜYZ aracı kullananların oranının ise daha düşük kaldığı görülmüştür. ÜYZ kullananlar arasında ücretli ÜYZ aracı kullandığını belirtenlerin oranı %39,4 (n=139), kullanmadığını söyleyenlerin oranı ise %60,6 (n=214) olarak bulunmuştur. Literatürde de benzer bir durum göze çarpmaktadır. Avustralya'da medikal fizikçi akademisyenler arasında ücretli ÜYZ aracı kullanım oranı %23 olarak bildirilmiştir.[176] ABD'de tıp öğrencileriyle yapılan bir çalışmada, ÜYZ araçlarının ücretli hâle gelmesi durumunda katılımcıların %60'ı bu araçları kullanmayı bırakacağını ifade etmiştir.[177] Bu bulgular birlikte değerlendirildiğinde, asistan hekimlerde olduğu gibi öğrenciler ve akademisyenlerde de ÜYZ'ye ilginin yüksek olmasına rağmen, para ödenmesi gereken aboneliklere geçişte daha temkinli davranıldığı anlaşılmaktadır. Bunun ekonomik nedenler, ücretsiz sürümlerin çoğu ihtiyacı karşılaması ve ücretli sürümlerin ek katkısının çok güçlü algılanmaması ile ilişkili olabileceği düşünülebilir.

Çalışmamızda haftalık ücretli ÜYZ kullanım süresine bakıldığında, katılımcıların %38,9'unun (n=163) bu araçları haftada "1 saatten az", %27,0'ının (n=113) ise "1–3 saat" kullandığı görülmüştür. Yani ücretli ÜYZ aboneliği olan asistan hekimlerin yaklaşık üçte ikisi, bu araçları haftada toplam 3 saatin altında kullanmaktadır. Bu durum, ücretli ÜYZ aboneliği olanların bile çoğunlukla bu araçları günlük iş akışının merkezine

yerleştirmediğini, daha çok ihtiyaç duyduklarında belirli klinik veya akademik işler için yardımcı bir araç olarak kullandıklarını düşündürmektedir.

Ücretli ÜYZ araçlarına bakıldığında, tercihin neredeyse tamamen tek bir platformda toplandığı görülmektedir. Ücretli ÜYZ kullandığını söyleyen katılımcılar arasında ChatGPT (OpenAI) %97,8 (n=134) ile açık ara en sık kullanılan araçtır. Bu durum, asistan hekimlerin ücretli ÜYZ tercihlerinin büyük ölçüde metin temelli, çok amaçlı ve klinik/akademik yazı süreçlerini destekleyen tek bir araca yöneldiğini düşündürmektedir. Buna karşılık, görsel üretim ya da ses/video düzenleme odaklı ücretli ÜYZ araçlarının asistanlık pratiğinde neredeyse hiç kullanılmadığı anlaşılmaktadır.

Genel olarak bu bulgular, asistan hekimler arasında ÜYZ'ye yönelik belirgin bir merak ve kabul olduğunu, ancak ücretli sürümlere geçişin daha çok ihtiyaç–maliyet dengesi ve ek fayda algısına bağlı kaldığını göstermektedir. Ücretli kullanımın neredeyse tamamen tek bir platformda toplanması, bir yandan bu sık kullanılan araç için kurumsal düzeyde eğitim, rehberlik ve veri güvenliği çerçevelerinin netleştirilmesini gerektirirken, diğer yandan tek bir ticari platforma bağımlılığın uzun vadede erişim, maliyet ve etik/veri mahremiyeti açısından bazı riskler taşıyabileceğini düşündürmektedir. Bu nedenle, kurumlarda alternatif ve daha çok merkezli çözüm seçeneklerinin de tartışılması yararlı olabilir.

Çalışmamızda ÜYZ kullanan asistan hekimlerin yaş ortalaması 29,7±3,4 yıl (medyan 29,0; 27,0–31,0), ÜYZ kullanmayanların yaş ortalaması ise 30,2±4,7 yıl (medyan 29,5; 28,0–32,0) olarak bulunmuştur. Her iki grubun yaş aralığı da büyük ölçüde benzerdir (ÜYZ kullananlar: 24–50; kullanmayanlar: 20–50) ve aradaki fark istatistiksel olarak anlamlı değildir (p=0,594). Bu sonuç, asistan hekimler arasında ÜYZ kullanımının belirli bir yaş grubunda toplanmadığını ve yaşın ÜYZ kullanımı açısından belirleyici bir faktör olmadığını göstermektedir. Benzer şekilde, Suudi Arabistan'da tıp öğrencileriyle yapılan bir çalışmada da yaş ile ChatGPT kullanımı arasında anlamlı bir ilişki saptanmamıştır (p=0,585).[178] Tayvan'daki okul ve üniversite hemşirelerinde yapılan başka bir çalışmada genç yaştaki hemşireler ileri yaştaki hemşirelere göre ChatGPT'yi daha sık kullandığı bildirilmiştir..[179] Bu paralellik, sağlık alanındaki genç ve genç erişkin gruplarda ÜYZ kullanımını etkileyen asıl etmenlerin yaştan çok dijital okuryazarlık, kişisel ilgi, eğitim ortamı ve kurumsal kültür gibi başka faktörler olabileceğini düşündürmektedir.

Çalışmamızda cinsiyet dağılımına bakıldığında, ÜYZ kullananlar arasında erkeklerin oranı %41,2 (n=146), kadınların oranı %58,8 (n=208) iken; ÜYZ kullanmayan grupta erkekler %38,1 (n=24), kadınlar %61,9 (n=39) olarak bulunmuştur. Oranların birbirine yakın olması ve p-değerinin anlamlı çıkmaması (p=0,742), asistan hekimler arasında ÜYZ kullanımı açısından belirgin bir cinsiyet farkı olmadığını göstermektedir. Suudi Arabistan'da tıp öğrencileriyle yapılan bir çalışmada ise cinsiyet ile ChatGPT kullanımı arasında anlamlı ilişki bulunmuş ve erkek öğrencilerin daha önce ChatGPT kullanma olasılığının kadınlara göre daha yüksek olduğu bildirilmiştir.[178] Bu farkın, o çalışmadaki örneklemde erkek (n=96) ve kadın (n=324) sayılarının dengesiz olmasından veya kültürel/toplumsal cinsiyet rollerinden etkilenmiş olabileceği düşünülebilir. Bizim çalışmamızda cinsiyetler arasında ÜYZ kullanım oranlarının benzer olması, asistanlar hekimler arasında dijital araçlara erişim ve ÜYZ kullanımını benimseme konusunda daha dengeli bir tabloya işaret etmektedir.

Çalışmamızda medeni duruma baktığımızda, ÜYZ kullanan asistan hekimler arasında bekâr ve evli oranlarının eşit olduğu, ÜYZ kullanmayan grupta da benzer bir dağılım olduğu görülmüştür. İki grup arasındaki fark istatistiksel olarak anlamlı değildir (p=0,923). Bu sonuç, bizim örneklemimizde ÜYZ kullanımının bekâr veya evli olmaktan bağımsız olduğunu ve medeni durumun ÜYZ kullanımında belirleyici bir faktör gibi görünmediğini düşündürmektedir. Buna karşılık, Sudan'da tıp öğrencileriyle yapılan bir çalışmada bekâr olmanın ChatGPT gibi ÜYZ araçlarına yönelimi artırdığı bildirilmiştir. Bu çalışmada bekâr öğrencilerde ÜYZ farkındalığı (%66,6'ya karşı %25,0) ve kullanım oranları (%42,4'e karşı %16,7) evli öğrencilere göre anlamlı derecede daha yüksek bulunmuştur (p<0,001 ve p=0,041).[180] Bu farklılık, medeni durumun ÜYZ kullanımına etkisinin bağlama, yaş grubuna ve kültürel/sosyal koşullara göre değişebileceğini düşündürmektedir. Bizim örneklemimizde medeni durumun öne çıkmaması ise asistan hekimler arasında ÜYZ kullanımında yaş, mesleki kıdem, dijital okuryazarlık veya önceki deneyim gibi başka etkenlerin daha güçlü rol oynayabileceğine işaret ediyor olabilir.

Çalışmamızda asistan hekimlerin büyük çoğunluğunun çocuk sahibi olmadığı görülmüştür; tüm örneklemde katılımcıların %77,8'inin çocuğu yokken, sadece %22,2'sinin en az bir çocuğu vardır. ÜYZ kullanım durumu çocuk sahibi olma durumuna göre incelendiğinde, ÜYZ kullanan grupta çocuk sahibi olmayanların oranı %78,9, en az bir çocuğu olanların oranı %21,1'dir. ÜYZ kullanmayan grupta ise bu oranlar sırasıyla

%71,9 ve %28,1'dir ve aradaki fark istatistiksel olarak anlamlı değildir (p=0,282). Bu sonuç, çalışmamızda ÜYZ kullanımının çocuk sahibi olmaktan belirgin şekilde etkilenmediğini, kullanım davranışının aile sorumluluğundan çok başka bireysel ve mesleki etkenlerle ilişkili olabileceğini düşündürmektedir. Öte yandan, üniversite hastanesinde hemşirelerle yapılan bir çalışmada, çocuk sahibi olmayan hemşirelerin yapay zekâya yönelik pozitif tutum puanlarının, çocuk sahibi olanlara göre daha yüksek bulunması, bazı sağlık profesyoneli gruplarında çocuk durumunun YZ tutumunu etkileyebileceğini göstermektedir.[181] Bu açıdan bakıldığında, bizim örneklemimizde ÜYZ kullanımının çocuk durumundan çok bireysel tercih, dijital okuryazarlık, uzmanlık eğitiminin gereklilikleri ve iş yükünün niteliğiyle daha yakından ilişkili olduğu; çocuk sahibi olmanın ise asistan hekimlik bağlamında belirleyici bir değişken olarak öne çıkmadığı söylenebilir.

Çalışmamızda uzmanlık alanına göre ÜYZ kullanımına bakıldığında, cerrahi (n=160), dahili (n=234) ve temel bilimler (n=25) arasında oranların birbirine oldukça yakın olduğu görülmüştür. Cerrahi bilimlerde kullanım %81,9, dahili bilimlerde %85,5, temel bilimlerde ise %96'dır ve bu fark istatistiksel olarak anlamlı değildir (p=0,169). Bu durum, ÜYZ kullanımının belirli bir branşa özel bir uygulama değil, farklı uzmanlık alanlarına yayılmış ortak bir araç olduğunu düşündürmektedir. Portekiz'de farklı branşlardan 1013 hekimle yapılan bir çalışmada da, yapay zekâya yönelik tutumların branşlar arasında genel olarak benzer olduğunu, sadece radyologlarda klinik kullanıma istekliliğin biraz daha yüksek olduğunu bildirmiştir.[182] Bu iki sonuç birlikte değerlendirildiğinde, ÜYZ'nin cerrahi, dahili ve temel bilimler arasında keskin farklar oluşturmaktan çok, branşlar üstü ortak bir mesleki araç olarak benimsendiği ve uzmanlık alanından bağımsız şekilde klinik ve akademik süreçlere girdiği söylenebilir.

Çalışmamızda asistan hekimlerin haftalık çalışma süresi ile ÜYZ kullanma durumu arasında anlamlı bir ilişki bulunmamıştır; farklı çalışma saati gruplarında ÜYZ kullanma oranları birbirine çok benzer düzeydedir (p=0,993). Bu durum, haftalık çalışma süresinin tek başına ÜYZ kullanımını artıran veya azaltan belirleyici bir etken olmadığını düşündürmektedir. Jendly ve arkadaşlarının İsviçre'de birinci basamak hekimleriyle yaptığı çalışmada ise dijital sağlık kullanım puanlarının, haftalık çalışma süresi arttıkça hafif düzeyde yükseldiği gösterilmiştir.[183] Bu sonuç, bazı ortamlarda daha uzun çalışma saatlerinin dijital araç kullanımını bir miktar artırabileceğini göstermektedir. Bizim

çalışmamızda böyle bir ilişki görülmemesi, ÜYZ kullanımının daha çok bireysel teknolojiye yatkınlık, dijital okuryazarlık, kurum kültürü ve eğitim sürecinde ÜYZ ile karşılaşma gibi faktörlerle ilişkili olabileceğini düşündürmektedir.

Çalışmamızda asistan hekimlerin %92,2'si ÜYZ'yi mesleki amaçla kullandığını belirtmiştir. En sık kullanım alanları tıbbi araştırma ve literatür taraması (%73,0), yapay zekâ destekli çeviri (%69,2) ve eğitim materyali ile sunum hazırlamadır (%64,5). Buna karşılık hastalık teşhisi ve tanı (%37,0), tedavi planlaması ve kişiselleştirilmiş sağlık (%21,0), istatistiksel hesaplamalar (%23,1), tıbbi görüntüleme/radyoloji (%14,1) ve simülasyon–sanal hasta (%7,8) gibi alanlarda kullanım oranları daha düşüktür. Uganda'daki tıp öğrencilerinde ÜYZ'nin ödev, sınav hazırlığı ve araştırma yazımı gibi akademik işlerde yaygın kullanıldığı (Ajalo ve ark.), ABD'de tıp öğrencilerinde ise ChatGPT'nin özellikle yazma, metin düzenleme ve özetleme için tercih edildiği gösterilmiştir (Zhang ve ark.).[184,185] Birleşik Krallık'ta aile hekimleriyle yapılan bir çalışmada da üretken yapay zekânın daha çok klinik dokümantasyon ve ayırıcı tanı desteği için kullanıldığı bildirilmiştir (Blease ve ark.).(2) Asistan hekimler arasında yapılan bir derleme çalışmasında, yapay zekâ araçlarını genellikle eğitim ve öğrenme desteği, değerlendirme ve sınav ve simülasyon ve senaryo gibi amaçlarla kullandığı belirlenmiştir.[186] Bu bulgular birlikte değerlendirildiğinde, asistan hekimlerin ÜYZ'yi ağırlıklı olarak metin üretimi, çeviri ve literatür taraması gibi bilgi ve dokümantasyon ağırlıklı işlerde yoğun şekilde kullandığı; bunun yanında tanı, tedavi planlaması ve istatistiksel analiz gibi doğrudan klinik ve araştırma karar süreçlerinde de kayda değer bir oranda kullanmaya başladığı söylenebilir.

Araştırmamızda asistan hekimlerin çok büyük çoğunluğunun ÜYZ'yi meslek dışı alanlarda da kullandığı görülmüştür. Katılımcıların %94,4'ü meslek dışında da ÜYZ kullandığını belirtmiştir. En sık kullanım alanları "eğitim ve öğrenme" (%68,6), "eğlence" (%51,5) ve "konuşma/sohbet" (%35,3) olarak öne çıkmıştır. Bu oran, Çin'de tıp öğrencilerinin %62,9'unun ChatGPT'yi daha çok bilgi arama ve ödev desteği için kullandığını bildiren çalışma ile karşılaştırıldığında, asistan hekimlerde ÜYZ'nin sadece eğitim için değil, günlük hayat ve boş zamanlarda da daha güçlü şekilde kullanıldığını düşündürmektedir.[187]

Çalışmamızda asistan hekimlerin çok büyük çoğunluğunun, üretken yapay zekânın tıpta destekleyici amaçla kullanımının yaygınlaşmasını istediği görülmüştür (%94,3). Kanada'daki tıp öğrencileriyle yapılan bir çalışmada da öğrencilerin önemli bir kısmının bu araçları gelecekte klinik pratiklerine entegre etmek istediği bildirilmiştir.[171] İngiltere'de aile hekimleriyle yapılan bir çalışmada ise hekimlerin %59'u, ÜYZ kullanımının sağlık hizmetlerinde verimliliği artıracağını ifade etmiştir.[188] Bizim örneklemimizdeki yüksek "yaygınlaşsın" oranı da ÜYZ'nin klinik ve akademik süreçlerde hızla benimsendiğini, bu sürecin sağlıklı ve güvenli ilerleyebilmesi için yapılandırılmış eğitim ve kurumsal rehberliğe ihtiyaç olduğunu düşündürmektedir. Öte yandan, çalışmamızda ÜYZ kullanımının yaygınlaşmasının kendilerinde endişe yarattığını söyleyenlerin oranı %24,1 (n=101) iken, katılımcıların dörtte üçünden fazlası (%75,9; n=318) endişe duymadığını belirtmiştir. Türkiye'de aile hekimleri üzerinde yapılan bir çalışmada da genel yapay zekâ kaygı düzeylerinin düşük olduğu gösterilmiştir.[189] Bu bulgular, asistan hekimler arasında ÜYZ'nin destekleyici bir araç olarak kullanımına yönelik güçlü bir kabul olduğunu, ancak yine de belirli bir grubun bu sürece bir miktar kaygıyla yaklaştığını düşündürmektedir.

Bu çalışmada, tıpta ÜYZ'nin destekleyici amaçla kullanımının yaygınlaşmasını isteme durumu ile ÜYZ'nin yaygınlaşmasının katılımcılarda endişe oluşturup oluşturmadığı arasındaki ilişki incelendiğinde, iki değişken arasında istatistiksel olarak anlamlı bir ilişki saptanmıştır ($p<0,001$). ÜYZ'nin yaygınlaşmasını isteyen grubun büyük çoğunluğu endişe bildirmezken [%78,5'i endişe duymuyor (n=310), %21,5'i endişe duyuyor (n=85)], yaygınlaşmasını istemeyen küçük grupta endişe oranının belirgin şekilde daha yüksek olduğu görülmüştür [%66,7'si endişe duyuyor (n=16), %33,3'ü endişe duymuyor (n=8)]. Asistan hekimler arasında yapılan bir derleme çalışmasında, yapay zekânın öğrenmeyi hızlandıran, iş yükünü azaltan ve ek bir destek aracı olarak olumlu karşılandığı; buna karşın hatalı/uydurma bilgi (*hallucination*) riski, bazı branşlarda orta düzeyde "yerimizi alır mı?" endişesi ile etik ve hukuki belirsizlikler nedeniyle yaygın kaygıların da devam ettiği bildirilmiştir.[186] Tıp öğrencileriyle yapılan daha geniş ölçekli bir çalışmada da, öğrencilerin çoğu yapay zekânın bilgiye erişimi kolaylaştıracağını ve karar verme süreçlerine katkı sağlayacağını belirtirken, önemli bir kısmının mesleğin itibarı ve rolünün değişmesi konusunda kaygı taşıdığı bildirilmiştir.[190] Bu bulgular birlikte değerlendirildiğinde, ÜYZ'nin yaygınlaşmasını destekleyen asistan hekimlerin duygusal

olarak daha az endişe yaşadığı, buna karşın yaygınlaşmaya karşı olan küçük bir grubun belirgin düzeyde daha kaygılı olduğu söylenebilir.

Çalışmamızda asistan hekimlerin yaklaşık yarısının (%54,9; n=230) uzmanlık tezine yönelik çalışmalara başladığı, geri kalan önemli bir kısmın ise henüz tez sürecine başlamadığı (%45,1; n=189) görülmüştür. Teze başlayanlar arasında sürecin farklı aşamalara yayıldığı görülmektedir. Katılımcıların bir bölümü hâlâ tez konusu belirleme (%22,6) veya etik kurul onayı (%10,0) gibi başlangıç aşamasındadır. Bir kısmı veri toplama (%18,3) ya da veri analizi/istatistik (%4,8) ile uğraşırken, diğerleri tez yazma (%15,7) veya tez savunması/sınavı (%23,9) aşamasına ilerlemiştir. Bu tablo, aynı kurumda çalışan asistan hekimler arasında tez sürecine başlama ve ilerleme düzeylerinin oldukça farklı olduğunu; bazılarının sürecin ileri aşamalarına gelmişken, önemli bir kısmın henüz başlamadığı veya erken aşamalarda kaldığını göstermektedir.

Çalışmamızda tez sürecinde üretken yapay zekâ (ÜYZ) kullanımı incelendiğinde, tez aşamasındaki katılımcıların %42,2'sinin (n=97) tezle ilgili hiçbir aşamada ÜYZ kullanmadığı görülmüştür. Buna karşılık, katılımcıların önemli bir kısmı en az bir basamakta ÜYZ'den yararlandığını belirtmiştir. En sık ÜYZ desteği alınan alanlar; literatür tarama/hipotez oluşturma (%30,0; n=69), tez yazımı (%23,9; n=55) ve tez konusunu belirleme (%16,1; n=37) olarak öne çıkmaktadır. Bu durum, asistan hekimlerin ÜYZ'yi özellikle zihinsel yükü yüksek, metin ve bilgi işlemeye dayalı akademik işlerde tercih ettiğini düşündürmektedir. Benzer şekilde, Endonezya'da lisans öğrencileriyle yapılan bir çalışmada da öğrencilerin akademik makale yazarken dil çevirisi için %79,9 oranında YZ destekli yazma araçları kullandığı bildirilmiştir.[191]

Çalışmamızda katılımcıların %89,7'si (n=376) gelecekte tezle ilgili çalışmalarda ÜYZ kullanmayı düşündüğünü belirtmiştir. Tıp öğrencilerinde ChatGPT kullanımını inceleyen Hu ve ark.'nın çalışmasında da katılımcıların %60,7'si akademik araştırmalarda ChatGPT'nin gelecekteki kullanımına olumlu bakmaktadır.(179) Bu sonuçlar birlikte değerlendirildiğinde, ÜYZ kullanmayan belirli bir grup olsa bile, tez süreçlerine ÜYZ entegrasyonu konusunda güçlü bir eğilim ve genel bir kabul olduğu söylenebilir.

Üretken Yapay Zekâ Kullanım ve Yeterlik Ölçeği (ÜYZKYÖ), Arslankara ve Usta (2024) tarafından geliştirilmiş, yeni bir ölçektir ve literatürde henüz çok yaygın kullanılmamaktadır. [167] Literatür taramasında, ÜYZKYÖ'nün şu ana kadar yalnızca az

sayıda çalışmada ve çoğunlukla konferans bildirimi düzeyinde kullanıldığı görülmüştür. Aydın ve Güntepe'nin farklı programlardaki lisansüstü öğrencilerle yaptıkları çalışmada, öğrencilerin genel olarak orta düzeyde üretken yapay zekâ kullanım ve yeterlik düzeyine sahip olduğu; ÜYZKYÖ'nün iki boyutu olan "yapay zekâ kullanım yeterliği" ile "yapay zekâ destekli öğrenme motivasyonu" arasında anlamlı fark bulunmadığı ve ÜYZ'nin özellikle araştırma, literatür tarama ve ödev hazırlamada tercih edildiği bildirilmiştir.[192] Arslankara ve Usta'nın öğretmenlerle yaptıkları çalışmada ise öğretmenlerin üretken yapay zekâ kullanım ve yeterlik düzeyleri ÜYZKYÖ ile, dijital iyi oluş düzeyleri ise Dijital İyi Oluş Ölçeği ile değerlendirilmiş; üretken yapay zekâ yeterliklerinin dijital iyi oluş üzerinde anlamlı bir etkisi olduğu gösterilmiştir.[193] Bu tezde elde edilen bulguların, ÜYZKYÖ'nün literatürdeki kullanımını artıracağı ve yapay zekâ okuryazarlığı ile dijital iyi oluş alanında yapılacak gelecekteki çalışmalara katkı sağlayacağı düşünülmektedir.

Çalışmamızda Üretken Yapay Zekâ Kullanım ve Yeterlik Ölçeği'nden elde edilen puanlar, asistan hekimlerin genel olarak ÜYZ'ye yönelik yeterlik ve öğrenme motivasyonunun orta–yüksek düzeyde olduğunu göstermektedir. Ölçek düzey aralıklarına göre katılımcıların yaklaşık dörtte üçü orta, yüksek veya çok yüksek düzeyde puan alırken, sadece yaklaşık onda biri düşük/çok düşük düzeydedir. Bu durum, örneklemde ÜYZ'ye karşı belirgin bir olumsuz tutum ya da direnç olmadığını düşündürmektedir. Alt boyut ortalamalarının her iki faktörde de madde başına yaklaşık 3,3–3,4/5 düzeyinde olması ve Cronbach alfa katsayılarının 0,83–0,92 arasında bulunması, ölçeğin bu grupta iyi bir iç tutarlılığa sahip olduğunu göstermektedir. Aynı zamanda, asistan hekimlerin kendilerini ÜYZ kullanımı ve YZ destekli öğrenme konusunda genel olarak yeterli ve istekli gördüklerini de desteklemektedir. Yaş ile toplam ölçek puanı ve "kullanım yeterliği" alt boyutu arasında anlamlı bir ilişki saptanmamış, yalnızca "YZ destekli öğrenme motivasyonu" alt boyutunda yaş arttıkça puanın çok hafif azaldığı görülmüştür. Bu da genç asistan hekimlerin, daha ileri yaştaki meslektaşlarına göre ÜYZ'yi öğrenme ve eğitim süreçlerine entegre etmeye bir miktar daha açık olabileceğini düşündürmekte, ancak etkinin düşük olması nedeniyle bu farkın pratikte sınırlı olduğu şeklinde yorumlanması uygun görünmektedir.

Çalışmamızda yaş ile ÜYZKYÖ toplam puanı arasında zayıf, negatif ve istatistiksel olarak anlamlı olmayan bir ilişki bulunmuştur ($r=-0,080$; $p=0,102$). Bu durum, asistan hekimlerin genel ÜYZ kullanım ve yeterlik düzeylerinin yaşa göre belirgin şekilde

değişmediğini göstermektedir. Alt boyutlar incelendiğinde, yaş arttıkça "YZ kullanım yeterliği" puanının hafifçe azaldığı ve bu ilişkinin istatistiksel olarak anlamlı olduğu görülmüştür (r=-0,106; p=0,030). Buna karşılık, "YZ destekli öğrenme motivasyonu" ile yaş arasında anlamlı bir ilişki saptanmamıştır (r=-0,047; p=0,335). Başka bir ifadeyle, farklı yaş grupları ÜYZ'yi öğrenme amaçlı kullanma isteği açısından benzer görünmekte, ancak daha genç asistan hekimler kendilerini ÜYZ kullanımı konusunda biraz daha yeterli hissetmektedir. r değerlerinin yaklaşık -0,1 düzeyinde olması, bu etkinin oldukça sınırlı olduğunu ve temkinle yorumlanması gerektiğini göstermektedir.

Cinsiyete göre ÜYZKYÖ puanlarına bakıldığında, erkek asistan hekimlerin hem toplam puanda hem de her iki alt boyutta kadınlardan anlamlı düzeyde daha yüksek puan aldığı görülmüştür (toplam puan medyanı: erkek 67, kadın 63; p=0,004; kullanım yeterliği: 35'e karşı 32; p=0,001; YZ destekli öğrenme motivasyonu: 32'ye karşı 30; p=0,040). Bu durum, erkek hekimlerin üretken yapay zekâ araçlarını kullanma yeterliğini ve öğrenme sürecine katma isteğini kadın meslektaşlarına göre biraz daha yüksek algıladığını düşündürmektedir. Ancak medyan puanların birbirine yakın olması, cinsiyetler arasındaki farkın çok büyük olmadığını göstermektedir.

Bizim çalışmamızda medeni duruma göre bakıldığında, bekâr ve evli asistan hekimler arasında ÜYZKYÖ toplam ve alt boyut puanlarında anlamlı bir fark görülmemiştir (tüm p>0,05). Bu sonuç, üretken yapay zekâya yönelik yeterlik ve motivasyonun sadece evli ya da bekâr olmakla değişmediğini düşündürmektedir. Çocuk durumuna bakıldığında ise, çocuk sahibi olan asistan hekimlerin, hem toplam ölçek puanında hem de kullanım yeterliği ve öğrenme motivasyonu alt boyutlarında, çocuğu olmayanlara göre anlamlı derecede daha düşük puan aldığı görülmüştür (toplam puan medyanları 62'ye karşı 65; p=0,009; kullanım yeterliği p=0,011; öğrenme motivasyonu p=0,014). Bu durum, çocuğu olmayan, görece daha genç asistan hekimlerin ÜYZ kullanımında kendini biraz daha yetkin hissettiğini ve bu araçları öğrenme sürecine katmaya daha istekli olabileceğini düşündürmektedir. Ancak medyan farklarının sadece birkaç puan düzeyinde olması ve yaş ile mesleki kıdem gibi karıştırıcı etkenler nedeniyle, bu farkın pratik açıdan sınırlı yorumlanması daha uygun görünmektedir.

Uzmanlık alanına göre ÜYZKYÖ puanlarına bakıldığında, temel bilimlerde çalışan asistan hekimlerin hem toplam ölçek puanının hem de her iki alt boyut puanının cerrahi ve

dahili bilimlere göre daha yüksek olduğu görülmüştür (toplam puan medyanları: cerrahi 62, dahili 64, temel bilimler 73; p=0,002). Benzer şekilde, "Yapay zekâ kullanım yeterliği" alt boyutunda cerrahi ve dahili bilimlerde medyan değer 33 iken, temel bilimlerde 38'e yükselmektedir (p=0,007). "YZ destekli öğrenme motivasyonu" alt boyutunda ise medyan puanlar cerrahi bilimlerde 29, dahili bilimlerde 32, temel bilimlerde 35 olarak saptanmıştır (p=0,001). Bu bulgular, temel bilimlerde çalışan asistan hekimlerin, üretken yapay zekâ araçlarını kullanma yeterliklerini ve bu araçları öğrenme süreçlerine dâhil etme motivasyonlarını klinik branşlardaki meslektaşlarına göre daha yüksek algıladıklarını düşündürmektedir. Ancak temel bilimlerdeki örneklem sayısının görece az olması (n=25) ve cerrahi ile dahili branşlar arasındaki medyan farklarının sınırlı kalması nedeniyle, bu sonuçların temkinli yorumlanması ve ileride daha büyük ve dengeli örneklemlerle desteklenmesi uygun olacaktır.

Haftalık çalışma süresi gruplarına göre ÜYZKYÖ toplam puanı ve her iki alt boyut puanı arasında anlamlı bir fark görülmemiştir (tüm p>0,05). Farklı çalışma saatlerine sahip grupların medyan puanlarının birbirine yakın olması, bu örneklemde üretken yapay zekâ kullanım yeterliği ve YZ destekli öğrenme motivasyonunun haftalık çalışma süresinden bağımsız olduğunu düşündürmektedir. Başka bir deyişle, daha uzun ya da daha kısa çalışan hekimler arasında ÜYZ'ye yönelik yeterlik ve motivasyon açısından belirgin bir avantaj veya dezavantaj izlenmemiştir; bu durumun çalışma süresinden çok bireysel ilgi, teknolojiye yatkınlık ve kişisel öğrenme tercihlerine bağlı olabileceği düşünülebilir.

## 5.1. ÇALIŞMANIN GÜÇLÜ YÖNLERİ

-Ulaşılan örneklemin büyüklüğü ve yapısal çeşitliliği (Cerrahi, dahili ve temel bilim branşlarından katılımın bulunması, farklı anabilim dallarından ve uzmanlık alanlarından çok sayıda asistan hekimin çalışmaya dâhil edilmiş olması)

-Çok sayıda boyutun sistematik biçimde sorgulanması (sosyodemografik özellikler, bilişim aracı kullanımı, ÜYZ kullanım pratikleri, tutumlar ,tez süreci ve Üretken Yapay Zekâ Kullanım ve Yeterlik Ölçeği kullanımı gibi birçok boyut bulunması)

-Hedef grubun asistan hekim gibi spesifik bir kitleden oluşması

- Literatürde ÜYZ'ye özgü ölçek temelli çalışmaların henüz sınırlı sayıda olması

- ÜYZKYÖ ölçeğinin toplam puan ve alt boyutlarında yüksek iç tutarlılık değerleri elde edilmesi

- Asistan hekimlerin uzmanlık tezlerinde ÜYZ'den nasıl ve hangi aşamalarda yararlandığını detaylı olarak irdeleyen çalışma sayısının oldukça sınırlı olması

## 5.2. ÇALIŞMANIN KISITLILIKLARI

- Çalışmanın kesitsel olması, nedensel yorumlamayı kısıtlıyor.

-Araştırmanın tek merkezli yürütülmesi genellenebilirliği sınırlıyor.

- Verilerin özbildirime dayalı anket aracılığıyla toplanmış olması.

## 6. SONUÇ VE ÖNERİLER

Bu tezde, Kocaeli Üniversitesi Tıp Fakültesi'nde görev yapan asistan hekimlerin üretken yapay zekâ (ÜYZ) araçlarını ne düzeyde kullandığı, bu araçlara ilişkin yeterlik ve öğrenme motivasyonları ile bunları etkileyen bazı sosyodemografik ve mesleki faktörler değerlendirilmiştir. Çalışmanın bulguları genel olarak, genç ve dijital ortamlara hâkim bir asistan hekim grubunda ÜYZ'ye yönelik güçlü bir ilgi ve kabul olduğunu, ancak bilgi düzeyi, kullanım yoğunluğu ve çeşitliliği açısından hâlâ gelişmeye açık alanlar bulunduğunu göstermektedir.

Araştırmanın örneklemini, çoğunlukla 30'lu yaşların başında, uzmanlık eğitiminin ilk yıllarında, yoğun klinik ve akademik yük altında çalışan asistan hekimler oluşturmaktadır. Katılımcıların hemen hepsinin akıllı telefon; büyük çoğunluğunun ise bilgisayar ve/veya tablet kullanması ve günlük dijital cihaz kullanım sürelerinin yüksek olması, bu grubun dijital sağlık ve ÜYZ uygulamalarına hızla uyum sağlayabilecek bir profile sahip olduğunu düşündürmektedir.

Bulgular, asistan hekimler arasında ÜYZ kullanım oranlarının çok yüksek olduğunu göstermiştir. Katılımcıların büyük çoğunluğu en az bir ÜYZ aracı kullanmakta ve %90'ın üzerinde bir oran, ÜYZ'yi mesleki amaçla da kullandığını bildirmektedir. Ancak haftalık kullanım süreleri incelendiğinde, ÜYZ'nin çoğu hekim için henüz günlük iş akışının "merkezinde" değil, daha çok belirli işlerde başvurulan destekleyici bir araç konumunda olduğu görülmektedir.

ÜYZ araçları içinde ChatGPT'nin hem ücretsiz hem de ücretli sürümler açısından belirgin biçimde öne çıktığı, diğer metin tabanlı araçların (örneğin Gemini, DeepSeek) daha sınırlı; görsel, ses veya video üretimi yapan araçların ise oldukça düşük oranda kullanıldığı saptanmıştır. Bu durum, asistan hekimlerin ÜYZ araçlarında çoğunlukla tek bir metin tabanlı büyük dil modeli etrafında şekillendiğini ve kullanımın özellikle metin üretme, özetleme, çeviri ve akademik yazı destek süreçlerinde yoğunlaştığını göstermektedir. Aynı zamanda, tek bir ticari platforma bu düzeyde bağımlı olmanın, uzun vadede maliyet ve veri güvenliği gibi açılardan kurumsal ve bireysel düzeyde dikkatli olunması gerektiği söylenebilir.

Çalışmada, ücretli ÜYZ aboneliği olan asistan hekim oranının, ücretsiz kullanıma göre daha düşük kaldığı bulunmuştur. Bu tablo, ÜYZ'ye ilgi ve kabul yüksek olsa da, ücretli sürümlere geçiş kararında maliyet, ek fayda algısı ya da ücretsiz sürümlerin birçok ihtiyacı karşılayabilmesi gibi etkenlerin rol aldığı söylenebilir.

Asistan hekimlerin önemli bir kısmı yapay zekâ ile ilgili bilgi düzeyini "orta" olarak tanımlaması ve genel olarak orta düzeyde gelişmeleri takip ettiği bulunmuştur. Ayrıca, Üretken Yapay Zekâ Kullanım ve Yeterlik Ölçeği (ÜYZKYÖ) ile elde edilen puanlar, genel yeterlik ve YZ destekli öğrenme motivasyonunun örneklemde orta–yüksek aralıkta olduğunu, belirgin bir olumsuz tutum veya direnç bulunmadığını ortaya koymuştur. Bu sonuç, uygun eğitim ve rehberlik sağlandığında asistan hekimlerin ÜYZ araçlarını mesleki süreçlerine daha güvenli ve etkili biçimde entegre etmeye hazır olduğunu düşündürmektedir.

Sosyodemografik ve mesleki değişkenler ile ÜYZ kullanımı/yeterlik düzeyleri arasındaki ilişkiler incelendiğinde, yaş, cinsiyet, medeni durum, çocuk sahibi olma, uzmanlık alanı ve haftalık çalışma süresi gibi değişkenlerin ÜYZ kullanımını büyük ölçüde belirlemediği görülmektedir. Yaş arttıkça kullanım yeterliğinin çok hafif azalması; erkeklerde ve çocuğu olmayanlarda ölçek puanlarının istatistiksel olarak biraz daha yüksek olması ve temel bilimlerde çalışanlarda ÜYZKYÖ puanlarının klinik branşlara göre daha yüksek bulunması gibi farklar saptansa da, medyan puanların birbirine yakın olması bu farklılıkların varlığına ilişkin yorumların sınırlı tutulmasını gerektirmektedir. Genel olarak, ÜYZ'ye yönelik yeterlik ve motivasyonun çoğu sosyodemografik özellikten bağımsız, daha çok bireysel ilgi, dijital okuryazarlık ve eğitim/kurum kültürü gibi faktörlerle ilişkili olduğu söylenebilir.

Kullanım alanları açısından bakıldığında, ÜYZ'nin en sık tıbbi araştırma ve literatür taraması, çeviri ve sunum/eğitim materyali hazırlama gibi metin ve bilgi işleme odaklı işlerde kullanıldığı; tanı, tedavi planlaması, istatistik, tıbbi görüntüleme ve simülasyon gibi doğrudan klinik karar ve ileri teknik bilgi gerektiren alanlarda kullanım oranlarının daha düşük ama kayda değer düzeyde olduğu görülmüştür. Meslek dışı kullanımda da eğitim/öğrenme, eğlence ve sohbet amaçları öne çıkmıştır. Bu tablo, ÜYZ'nin hem profesyonel hem kişisel yaşamda asistan hekimler için hızla "gündelik" bir araç hâline geldiğini göstermektedir.

Tutum düzeyinde ise, asistan hekimlerin çok büyük çoğunluğunun ÜYZ'nin tıpta destekleyici amaçla kullanımının yaygınlaşmasını istediği ve bu yaygınlaşmanın kendilerinde endişe yaratmadığını belirttiği bulunmuştur. Buna karşın, daha küçük bir grup, ÜYZ'nin yaygınlaşmasının kendilerinde kaygı oluşturduğunu ifade etmiştir. ÜYZ'nin yaygınlaşmasını istemeyenlerde endişe oranının belirgin biçimde yüksek olması, "yararlı fakat riskli bir teknoloji" algısının aynı anda var olabildiğini ve hâlen etik, hukuki ve mesleki kimlik boyutlarında soru işaretlerinin sürdüğünü düşündürmektedir.

Tez sürecine özel bulgular ise, asistan hekimlerin önemli bir kısmının henüz tezine başlamadığını veya erken aşamada olduğunu; tez sürecinde ÜYZ kullanımının ise özellikle literatür taraması, konu belirleme ve tez yazımı gibi zihinsel ve metin tabanlı yükü yüksek alanlarda yoğunlaştığını göstermiştir. Mevcut durumda tezle ilgili hiçbir aşamada ÜYZ kullanmayan anlamlı bir grup olsa da, büyük çoğunluk gelecekte tez çalışmalarında ÜYZ kullanmayı düşündüğünü belirtmiştir. Bu durum, ÜYZ entegrasyonuna yönelik güçlü bir potansiyel kabul bulunduğuna işaret etmektedir.

Bu sonuçlar doğrultusunda, asistan hekimlerin ÜYZ kullanımını güçlendirmeye yönelik olarak şu önerilerde bulunulmuştur:

-Asistan hekimlere yönelik uzmanlık eğitimi programlarına, ÜYZ'nin temel kavramlarını, kullanım alanlarını, sınırlılıklarını ve olası risklerini içeren eğitimler eklenmelidir.

-Kurum düzeyinde, özellikle sık kullanılan ÜYZ araçları için etik ilkelere, veri güvenliğine, hasta mahremiyetine ve akademik dürüstlüğe vurgu yapan yazılı kullanım rehberleri hazırlanmalı ve tüm asistanlar tarafından ulaşılabilir hâle getirilmelidir.

-ÜYZ'nin klinik karar destek, tanı, tedavi planlaması ve istatistiksel analiz gibi daha ileri alanlara güvenli entegrasyonu için, aile hekimliği ve diğer branşlarda pilot uygulamalar ve kademeli geçiş modelleri planlanmalıdır.

-Tek bir ticari platforma bağımlılığı azaltmak için, mümkün olduğunda kurumsal lisanslı, güvenli ve alternatif ÜYZ çözümleri de değerlendirilmelidir.

## KOCAELİ ÜNİVERSİTESİ TIP FAKÜLTESİ'NDE ÇALIŞMAKTA OLAN ASİSTAN HEKİMLERİN ÜRETKEN YAPAY ZEKÂ ARAÇLARINI KULLANIM VE YETERLİK DÜZEYLERİNİN DEĞERLENDİRİLMESİ


### TÜRKÇE ÖZET

**Giriş ve amaç:** Kocaeli Üniversitesi Tıp Fakültesi'nde görev yapan asistan hekimlerin üretken yapay zekâ (ÜYZ) araçlarını hangi amaçlarla ve ne düzeyde kullandıkları, ÜYZ'ye ilişkin yeterlik ve tutumlarının değerlendirilmesi amaçlanmıştır.

**Gereç ve yöntem:** Tanımlayıcı ve kesitsel nitelikteki araştırma Haziran 2025-Eylül 2025 tarihleri arasında çalışmaya katılmayı kabul eden 419 asistan hekim ile yürütülmüştür. Veri toplamada sosyodemografik ve mesleki özellikler ile ÜYZ kullanım durumunu ve alanlarını sorgulayan sorular ve Üretken Yapay Zekâ Kullanım ve Yeterlik Ölçeği içeren anket formu kullanılmıştır. İkili gruplarda Mann-Whitney U, ikiden fazla gruplarda Krusskal-Wallis testleri yapılmıştır. Niceliksel değişkenler ile ölçek ve alt boyutlarının karşılaştırılması Spearman korelasyon testi ile yapılmıştır. Tüm analizlerde $p<0,05$ anlamlı kabul edilmiştir.

**Bulgular :** Katılımcıların yaş ortalaması 29,74±3,66 yıl olup %59,2'si kadın, %40,8'i erkektir. Asistan hekimlerin %84,7'si en az bir kez ÜYZ aracı kullandığını bildirmiş; ÜYZ'yi hem mesleki hem kişisel alanlarda yaygın biçimde kullandıkları görülmüştür. Ölçekten elde edilen puanlar, asistan hekimlerin ÜYZ kullanım ve yeterlik düzeylerinin genel olarak orta–yüksek düzeyde olduğunu göstermiştir.

**Sonuç :** Elde edilen bulgular, asistan hekimlerin üretken yapay zekâyı büyük ölçüde benimsediğini, buna rağmen özellikle etik ve veri güvenliğine ilişkin kaygıların sürdüğünü ve ÜYZ okuryazarlığını güçlendirmeye yönelik hedeflenmiş eğitimlere ihtiyaç olduğunu ortaya koymaktadır.



**Anahtar kelimeler :** Üretken yapay zekâ, yapay zekâ, asistan hekim, yeterlik

## ASSESSMENT OF GENERATIVE ARTIFICIAL INTELLIGENCE TOOL USE AND COMPETENCE LEVELS AMONG RESIDENT PHYSICIANS WORKING AT KOCAELİ UNIVERSITY FACULTY OF MEDICINE


## ABSTRACT

**Introduction :** This study aimed to evaluate the purposes and extent to which resident physicians working at Kocaeli University Faculty of Medicine use generative artificial intelligence (GenAI) tools, as well as their competences and attitudes regarding these tools.

**Materials and Methods:** This descriptive, cross-sectional study was conducted between June and September 2025 with 419 resident physicians who agreed to participate. Data were collected using a structured questionnaire including items on sociodemographic and occupational characteristics, GenAI use and fields of use, and the Generative Artificial Intelligence Use and Competence Scale. For group comparisons, the Mann–Whitney U test was used for two groups and the Kruskal–Wallis test for more than two groups. Correlations between quantitative variables and scale and subscale scores were examined using Spearman correlation analysis. A p value <0.05 was considered statistically significant in all analyses.

**Results:** The mean age of the participants was 29.74±3.66 years; 59.2% were female and 40.8% were male. Of the resident physicians, 84.7% reported using a GenAI tool at least once and were found to use these tools widely in both professional and personal contexts. Scale scores indicated that their overall levels of GenAI use and competence were in the moderate-to-high range.

**Conclusion:** The findings of this study show that resident physicians largely embrace generative artificial intelligence, yet concerns persist particularly regarding ethical issues and data security, highlighting the need for targeted training programs to strengthen GenAI literacy and safe use.



**Keywords:** generative artificial intelligence, artificial intelligence, resident physician, competence

## EKLER

### EK-1: ÇALIŞMADA KULLANILAN ANKET FORMU

Değerli katılımcı;

Sizi Kocaeli Üniversitesi Aile Hekimliği Anabilim Dalı Öğretim Üyesi Prof. Dr. Tuncay Müge ALVUR tarafından yürütülen, ‘‘Asistan Hekimlerin Üretken Yapay Zekâ Araçlarını Kullanım ve Yeterlik Düzeylerinin Değerlendirilmesi’‘ başlıklı çalışmaya katılmaya davet ediyoruz.

Katılımınız için çok teşekkür ederiz.

Bu çalışmanın amacı Kocaeli Üniversitesi’nde eğitim gören araştırma görevlisi hekimlerin Üretken Yapay Zekâ Araçları hakkında bilgi sahibi olup olmadıkları ve ölçek aracılığıyla kullanım ve yeterlilik düzeylerinin değerlendirilmesidir.

Veri toplama formu; sosyodemografik özellikler, yapay zekâ ile ilgili literatür taranarak oluşturulan sorular ve izin alınarak kullanılan ‘‘ÜRETKEN YAPAY ZEKÂ KULLANIM VE YETERLİK (ÜYZKYÖ) ÖLÇEĞİ’‘ sorularından oluşmaktadır. Soruları tamamlamak yaklaşık 5 dakika sürecektir.

Kimlik bilgilerinizin kullanılmayacağı bu çalışmadan elde edilen veriler sadece bilimsel amaçla kullanılacaktır. Bireysel anket sonuçlarına sadece araştırmacılar ulaşacaktır.

Araştırmaya katılım tamamen gönüllülük esasına dayanmaktadır. Çalışmaya katılmayı reddedebileceğiniz gibi herhangi bir sebep göstermeksizin istediğiniz anda çalışmadan ayrılabilirsiniz.

Bu araştırmaya katılmanızdan dolayı sizden herhangi bir ücret talep edilmeyecek olup, katılmanızdan dolayı da size herhangi bir ödeme yapılmayacaktır.

Araştırmadan elde edilen sonuçları talep etmeniz durumunda herhangi bir ücret talep etmeksizin sizlere bildireceğiz. Aşağıdaki onay kutucuğunu işaretlediğinizde, gönüllü olarak araştırmaya katıldığınızı onaylamış olacaksınız. Verdiğiniz cevaplarla çalışmaya katkılarınızdan dolayı teşekkür ederiz. Araştırma ile ilgili soru ve katkılarınız için e-posta adresleri:

Ankete katılmayı onaylıyor musunuz?

☐ Onaylıyorum

1. Yaşınız: …….

2. Cinsiyet:

○ Kadın
○ Erkek
○ Belirtmek istemiyorum

3. Medeni durumunuz:

○ Evli
○ Bekar
○ Belirtmek istemiyorum

4. Çocuğunuz var mı?

○ Var (……)
○ Yok

5. Kronik bir hastalığınız var mı? Varsa lütfen belirtiniz:

○ Var …..……
○ Yok

6. Kaç yıldır aktif olarak hekimlik yapmaktasınız?

……

7. Tıp fakültesi mezuniyet yılınız nedir?

……

8. Asistanlıkta kaçıncı yılınız?

……

9. Eğitim gördüğünüz tıpta uzmanlık alanı nedir?

……

10. Haftada ortalama kaç saatinizi işte geçirirsiniz?

○ 40 saatten az
○ 40-50 saat
○ 50-60 saat
○ 60-70 saat
○ 70 saat ve üstü

11. Hangi bilişim araçlarını kullanıyorsunuz? (Birden fazla seçenek işaretleyebilirsiniz)

☐ Akıllı telefon
☐ Tablet
☐ Bilgisayar
☐ Akıllı saat
☐ Oyun konsolu
☐ Diğer: ……

12. Gün içerisinde bilişim araçları ile ne kadar vakit geçiriyorsunuz?

○ 1 saatten az
○ 1-3 saat
○ 3-5 saat
○ 5-7 saat
○ 7 saat ve üzeri

13. Yapay zekâ alanındaki gelişmeleri takip eder misiniz?

○ Her zaman
○ Sıklıkla
○ Bazen
○ Nadiren
○ Hiçbir zaman

14. Yapay zekâ teknolojileri ile ilgili bilgi düzeyinizi nasıl değerlendirirsiniz?

○ Çok iyi
○ İyi
○ Orta
○ Kötü
○ Çok kötü

15. Üretken yapay zekâ araçlarını (ChatGPT vs.) kullanıyor musunuz? (Cevabınız ‘‘HAYIR‘‘ ise 25. soruya geçebilirsiniz)

○ Evet
○ Hayır

16. Hangi üretken yapay zekâ araçlarını kullanıyorsunuz? (Birden fazla seçenek işaretlenebilir)

☐ ChatGPT (OpenAI)
☐ Google Gemini (Bard)
☐ DeepSeek
☐ Midjourney
☐ DALL·E (OpenAI)
☐ ElevenLabs
☐ Descript
☐ Jasper AI
☐ Writesonic
☐ Runway ML
☐ Claude (Anthropic)
☐ Replica
☐ Ocaya
☐ Diğer: ……

17. Üretken yapay zekâ uygulamalarını kullanım süreniz 1 haftada ortalama ne kadardır?

○ 1 saatten az
○ 1-3 saat arası
○ 3-5 saat arası
○ 5-7 saat arası
○ 7 saat ve fazlası

18. Ücretli üretken yapay zekâ programlarını kullanıyor musunuz? (Cevabınız ‘‘HAYIR’‘ ise 21. soruya geçebilirsiniz)

○ Evet
○ Hayır

19. Kullanıyorsanız hangi programları kullanıyorsunuz? (Birden fazla seçenek işaretlenebilir)

☐ ChatGPT Plus (OpenAI)
☐ Midjourney
☐ Jasper AI
☐ Ocaya
☐ Writesonic
☐ Descript (AI Audio & Video Editing)
☐ ElevenLabs
☐ Runway ML
☐ Diğer: ……

20. Eğer ücretli üretken yapay zekâ programlarını kullanıyorsanız haftada kaç saat kullanıyorsunuz?

○ 1 saatten az
○ 1-3 saat arası
○ 3-5 saat arası
○ 5-7 saat arası
○ 7 saat ve fazlası

21. Üretken yapay zekâ araçlarını mesleğinizle ilgili konularda kullanıyor musunuz? (Cevabınız ‘‘HAYIR’‘ ise 23. soruya geçebilirsiniz)

○ Evet
○ Hayır

22. Kullanıyorsanız hangi konularda kullanıyorsunuz? (Birden fazla seçenek işaretlenebilir)

☐ Hastalık Teşhisi ve Tanı
☐ Yapay Zekâ Destekli Çeviri
☐ Tedavi Planlaması ve Kişiselleştirilmiş Sağlık
☐ Eğitim materyali oluşturulmasında (sunum vs.)
☐ Tıbbi Görüntüleme ve Radyoloji
☐ Tıbbi Araştırma (Literatür tarama vs.)
☐ İstatistiksel hesaplamalar
☐ Simülasyon ve Sanal Hastalar
☐ Diğer: ……

23. Üretken yapay zekâ araçlarını mesleğiniz dışındaki konularda kullanıyor musunuz? (Cevabınız ‘‘HAYIR’‘ ise 25. soruya geçebilirsiniz)

○ Evet
○ Hayır

24. Kullanıyorsanız hangi konularda kullanıyorsunuz? (Birden fazla seçenek işaretlenebilir)

☐ İçerik Üretimi ve Yaratıcılık
☐ Görsel Tasarım ve Grafik Oluşturma
☐ Video ve Fotoğraf Düzenleme
☐ Eğitim ve Öğrenme Yardımcıları
☐ Sosyal Medya İçerik Planlaması
☐ Konuşma ve sohbet etmek
☐ Eğlence amaçlı
☐ Yaratıcı Metinler Yazma
☐ Diğer: ……

25. Tıp alanında üretken yapay zekâ araçlarının destekleyici amaçla kullanımının yaygınlaşmasını ister misiniz?

○ Evet
○ Hayır

26. Tıp alanında üretken yapay zekâ araçlarının destekleyici amaçla kullanımının yaygınlaşması sizde endişeye yol açar mı?

○ Evet
○ Hayır

27. Tez ile ilgili çalışmalara başladınız mı? (Cevabınız ‘‘HAYIR’‘ ise 30. soruya geçebilirsiniz)

○ Evet
○ Hayır

28. Şu an hangi aşamadasınız?

○ Tez konusunu belirleme
○ Etik kurul onayı
○ Literatür tarama/hipotez oluşturma
○ Araştırma yöntemi belirleme/örneklem hesaplama
○ Veri toplama (anket, vs.)
○ Veri analizi/istatistik
○ Tez yazma
○ Tez savunması ve sınavı

29. Tez hazırlarken herhangi bir üretken yapay zekâ aracından yardım aldıysanız hangi aşamalarda yardım aldınız? (Birden fazla seçeneği işaretleyebilirsiniz.)

☐ Tez konusunu belirleme
☐ Etik kurul onayı
☐ Literatür tarama/hipotez oluşturma
☐ Araştırma yöntemi belirleme/örneklem hesaplama
☐ Veri toplama (anket, vs.)
☐ Veri analizi/istatistik
☐ Tez yazma
☐ Tez savunması ve sınavı

30. Tez ile ilgili çalışmalarda üretken yapay zekâ araçlarını kullanmayı düşünür müsünüz?

○ Evet
○ Hayır

| No | ÜRETKEN YAPAY ZEKÂ KULLANIM VE YETERLİK (ÜYZKYÖ) ÖLÇEĞİ (TÜRKÇE) | Hiç yansıtmıyor | Az yansıtıyor | Orta düzeyde yansıtıyor | Çok yansıtıyor | Tamamen yansıtıyor |
|---|---|---|---|---|---|---|
| **Faktör 1:** Yapay Zekâ Kullanım Yeterliği | | | | | | |
| 1 | Yapay zekâ destekli öğrenme araçlarını etkili bir şekilde kullanabilirim | 1 | 2 | 3 | 4 | 5 |
| 2 | Yapay zekâ araçlarını kullanarak öğrenme sürecimdeki zorluklarla başa çıkmada sorunum yoktur | 1 | 2 | 3 | 4 | 5 |
| 3 | Yapay zekâ araçlarını kullanarak öğrenme sürecimi özelleştirebilirim / kişiselleştirebilirim | 1 | 2 | 3 | 4 | 5 |
| 4 | Yapay zekâ destekli öğrenme araçlarını kullanarak öğrenme sürecimi düzenleyebilirim | 1 | 2 | 3 | 4 | 5 |
| 5 | Yapay zekâ tabanlı öğrenme uygulamalarının kullanımının zamanımı daha etkin kullanmama yardımcı olduğunu düşünüyorum | 1 | 2 | 3 | 4 | 5 |
| 6 | Yapay zekâ destekli öğrenme sürecinin öğrenme kaynaklarına erişimimi artırdığını düşünüyorum | 1 | 2 | 3 | 4 | 5 |
| 7 | Yapay zekâ destekli öğrenme sürecinin özgürlüğümü kısıtladığını düşünüyorum (-) | 1 | 2 | 3 | 4 | 5 |
| 8 | Yapay zekâ tabanlı öğrenme materyallerini verimli bir şekilde yönetebilirim | 1 | 2 | 3 | 4 | 5 |
| 9 | Yapay zekâ tarafından önerilen öğrenme içeriklerinin doğruluğunu yeterli buluyorum | 1 | 2 | 3 | 4 | 5 |
| 10 | Yapay zekâ araçlarının algoritmasını anlayabilirim. | 1 | 2 | 3 | 4 | 5 |
| **Faktör 2:** Yapay Zekâ Destekli Öğrenme Motivasyonu | | | | | | |
| 11 | Yapay zekâ tabanlı öğrenme araçlarını kullanarak karmaşık konuları anlayabilirim | 1 | 2 | 3 | 4 | 5 |
| 12 | Yapay zekâ destekli kişiselleştirilmiş öğrenme deneyimlerini etkili buluyorum | 1 | 2 | 3 | 4 | 5 |
| 13 | Yapay zekâ destekli öğrenme sürecinin öğrenme hızımı artırdığını düşünüyorum | 1 | 2 | 3 | 4 | 5 |
| 14 | Yapay zekâ kullanarak öğrenme sürecimdeki güncel gelişmeleri takip edebilirim | 1 | 2 | 3 | 4 | 5 |
| 15 | Yapay zekâ tabanlı öğrenme uygulamalarının kullanımının öğrenme sürecimdeki stresimi azalttığını düşünüyorum | 1 | 2 | 3 | 4 | 5 |
| 16 | Yapay zekâ kullanımının öğrenme sürecimdeki öğrenme engellerini azalttığını düşünüyorum | 1 | 2 | 3 | 4 | 5 |
| 17 | Yapay zekâ tabanlı öğrenme uygulamalarının kullanımının öğrenme sürecimdeki motivasyonumu azalttığını düşünüyorum (-) | 1 | 2 | 3 | 4 | 5 |
| 18 | Yapay zekâ tabanlı öğrenme uygulamalarının kullanımının sosyal etkileşimlerimi azalttığını düşünüyorum (-) | 1 | 2 | 3 | 4 | 5 |
| 19 | Yapay zekâ tarafından sağlanan öğrenme içeriklerini değerlendirme ve seçme yeterliğine sahibim | 1 | 2 | 3 | 4 | 5 |

## EK-2: KOCAELİ ÜNİVERSİTESİ TIP FAKÜLTESİ ETİK KURUL BAŞKANLIĞI'NDAN ALINAN YAZI

**T.C.**
**KOCAELİ ÜNİVERSİTESİ REKTÖRLÜĞÜ**
**Tıp Fakültesi Dekanlığı**
**Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu**

Sayı : E-80418770-020-779499
Konu : 2025/228

Sayın Prof.Dr. Tuncay Müge ALVUR

**GOKAEK-2025/10/12** **Prof. Dr. Tuncay Müge Alvur** sorumluluğunda yürütülmesi planlanan **2025/228** proje numaralı Kocaeli Üniversitesi Tıp Fakültesi'nde Çalışmakta olan Asistan Hekimlerin Üretken Yapay Zekâ Araçlarını Kullanım ve Yeterlik Düzeylerinin Değerlendirilmesi başlıklı proje değerlendirilmiş, projenin yürütülmesi uygun bulunmuştur.

Dekanlıktan izin alınması koşuluyla

**KARAR: KABUL, PROJENİN YÜRÜTÜLMESİ UYGUNDUR.**

Projenizin yürütülmesi uygun bulunmuştur, çoklu imza formu ekte sunulmaktadır. Araştırmaya Etik Kurul onay tarihinden sonra en geç 90 gün içinde başlamanız, (i) Başlayamadığınızda veya protokolde bildirdiğiniz hususlarda herhangi bir değişiklik yaptığınızda Değişiklik Bilgi Formu ile, (ii) Araştırmanızı onay aldığınız şekilde tamamladığınızda Sonuç Raporu ile Etik Kurul'a başvurmanız gerekmektedir.

**Prof.Dr. Bülent KARA**
**Kurul Başkanı**

Belge Doğrulama Kodu :BSMM54CR72 Belge Doğrulama Adresi :https://turkiye.gov.tr/kocaeli-universitesi-ebys
Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu Kocaeli Üniversitesi Tıp Fakültesi 41380 Umuttepe / KOCAELİ
Tel:90 262 303 70 04 Faks:90 262 303 70 03
E-Posta :tipdek@kocaeli.edu.tr Elektronik Ağ :http://tip.kocaeli.edu.tr/
Kep Adresi: kocaeliuniversitesi@hs01.kep.tr
Bilgi için: Yasemin Karaarslan
Memur
Telefon No: 303 70 15

## KAYNAKLAR


1. Morales-Arevalo JC, Rodríguez C. A systematic review of the benefits and challenges of data analytics in organizational decision making. Int J Adv Comput Sci Appl. 2025;16(2):200-209.

2. Blease CR, Locher C, Gaab J, Hägglund M, Mandl KD. Generative artificial intelligence in primary care: an online survey of UK general practitioners. BMJ Health Care Inform. 2024;31(1):e101102.

3. Reddy S. Generative AI in healthcare: an implementation science informed translational path on application, integration and governance. Implement Sci. 2024;19(1):27.

4. Sallam M. ChatGPT utility in healthcare education, research, and practice: systematic review on the promising perspectives and valid concerns. Healthcare (Basel). 2023;11(6):887.

5. Waller J, O'Connor A, Rafaat E ve ark. Applications and challenges of artificial intelligence in diagnostic and interventional radiology. Pol J Radiol. 2022;87:e113-e117.

6. Jariyapan P, Pora W, Kasamsumran N, Lekawanvijit S. Digital pathology and artificial intelligence in diagnostic pathology. Malays J Pathol. 2025;47(1):3-11.

7. Xi L, Li C, Anari MS, Rezaee K. Integrating wearable health devices with AI and edge computing for personalized rehabilitation. J Cloud Comput. 2025;14(1):64.

8. Wu C, Xu H, Bai D, Chen X, Gao J, Jiang X. Public perceptions on the application of artificial intelligence in healthcare: a qualitative meta-synthesis. BMJ Open. 2023;13(1):e066322.

9. Can H, Yorgancıoğlu F, Koç EM. Yapay zekâ aile hekimliği hakkında ne düşünüyor? Sağlık Bilimlerinde Yapay Zekâ Derg. 2024;4(1):1-10.

10. Gencer K, Gencer G. Tıp fakültesi öğrencilerinin tıbbi yapay zekâ hazır bulunuşluluğunun incelenmesi. Kocatepe Tıp Derg. 2024;25(2):143-149.

11. Gordon M, Daniel M, Ajiboye A ve ark. A scoping review of artificial intelligence in medical education: BEME Guide No. 84. Med Teach. 2024;46:446-470.

12. Challen R, Denny J, Pitt M, Gompels L, Edwards T, Tsaneva-Atanasova K. Artificial intelligence, bias and clinical safety. BMJ Qual Saf. 2019;28:231-237.

13. Kueper JK, Terry A, Bahniwal R ve ark. Connecting artificial intelligence and primary care challenges: findings from a multi-stakeholder collaborative consultation. BMJ Health Care Inform. 2022;29:e100493.

14. Barak-Corren Y, Wolf R, Rozenblum R ve ark. Harnessing the power of generative AI for clinical summaries: perspectives from emergency physicians. Ann Emerg Med. 2024;84:128-138.

15. Ergen M. What is artificial intelligence? Technical considerations and future perception. Anatol J Cardiol. 2019;22:5-7.

16. Bundy A, Chater N, Muggleton S. Introduction to “cognitive artificial intelligence”. Philos Trans R Soc A Math Phys Eng Sci. 2023;381:20220051.

17. Mao R, Liu Q, Li X, Cambria E, Hussain A. Bridging minds and machines: toward an integration of AI and cognitive science. arXiv. 2025;arXiv:2508.20674.

18. Peyré G. The mathematics of artificial intelligence. arXiv. 2025;arXiv:2501.10465.

19. Mukhamediev RI, Popova Y, Kuchin Y ve ark. Review of artificial intelligence and machine learning technologies: classification, restrictions, opportunities and challenges. Mathematics. 2022;10:2552.

20. An Q, Rahman S, Zhou J, Kang JJ. A comprehensive review on machine learning in healthcare industry: classification, restrictions, opportunities and challenges. Sensors (Basel). 2023;23:4178.

21. Zubair M, Din I, Sarwar N, Elov B, Makhmudov S, Trabelsi Z. Revolutionizing sepsis diagnosis using machine learning and deep learning models: a systematic literature review. In Review. 2025;[preprint].

22. Huang SC, Pareek A, Seyyedi S, Banerjee I, Lungren MP. Fusion of medical imaging and electronic health records using deep learning: a systematic review and implementation guidelines. NPJ Digit Med. 2020;3:136.

23. Roy S, Meena T, Lim SJ. Demystifying supervised learning in healthcare 4.0: a new reality of transforming diagnostic medicine. Diagnostics (Basel). 2022;12:2549.

24. Roy P, Shiva SG. Unsupervised learning: techniques, applications, and testing methodologies. Cureus J Comput Sci. 2025;[epub ahead of print].

25. Al-Hamadani MNA, Fadhel MA, Alzubaidi L, Balazs H. Reinforcement learning algorithms and applications in healthcare and robotics: a comprehensive and systematic review. Sensors (Basel). 2024;24:2461.

26. Jayaraman P, Desman J, Sabounchi M, Nadkarni GN, Sakhuja A. A primer on reinforcement learning in medicine for clinicians. NPJ Digit Med. 2024;7:337.

27. Zhang H, Guo W, Zhang S, Lu H, Zhao X. Unsupervised deep anomaly detection for medical images using an improved adversarial autoencoder. J Digit Imaging. 2022;35:153-161.

28. Takahashi S, Sakaguchi Y, Kouno N ve ark. Comparison of vision transformers and convolutional neural networks in medical image analysis: a systematic review. J Med Syst. 2024;48:84.

29. Miotto R, Wang F, Wang S, Jiang X, Dudley JT. Deep learning for healthcare: review, opportunities and challenges. Brief Bioinform. 2017;19:1236-1246.

30. Mienye ID, Swart TG. A comprehensive review of deep learning: architectures, recent advances, and applications. Information. 2024;15:755.

31. Thakur GK, Thakur A, Kulkarni S, Khan N, Khan S. Deep learning approaches for medical image analysis and diagnosis. Cureus. 2024;16:e59507.

32. Chowdhury GG. Natural language processing. Annu Rev Inf Sci Technol. 2003;37:51-89.

33. Pais S, Cordeiro J, Jamil ML. NLP-based platform as a service: a brief review. J Big Data. 2022;9:54.

34. Cambria E, White B. Jumping NLP curves: a review of natural language processing research. IEEE Comput Intell Mag. 2014;9:48-57.

35. Bender EM, Lascarides A. Linguistic Fundamentals for Natural Language Processing II: 100 Essentials from Semantics and Pragmatics, 1. basım. San Rafael: Morgan & Claypool. 2020:1-250.

36. Taha K, Yoo PD, Yeun C, Homouz D, Taha A. A comprehensive survey of text classification techniques and their research applications: observational and experimental insights. Comput Sci Rev. 2024;54:100664.

37. Pavan Kalyan N, Kandra A, Nethranand PS, Shruthi K. A comprehensive literature review on automated text summarization and evaluation using NLP approaches. Int Adv Res J Sci Eng Technol. 2024;11:258-266.

38. Jurafsky D, Martin JH. Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition, 3. basım. Upper Saddle River, NJ: Pearson. 2023:1-1024.

39. Gendy W, Patel D. Advancements in computer vision: a comprehensive survey of image processing and interdisciplinary applications. Acad J Sci Technol. 2024;13:28-34.

40. Dhabliya D, Ugli ISM, Murali MJ, Abbas AHR, Gulbahor U. Computer vision: advances in image and video analysis. E3S Web Conf. 2023;399:04045.

41. Kaur P, Singh G, Kaur P. A review of denoising medical images using machine learning approaches. Curr Med Imaging Rev. 2018;14:675-685.

42. Agrawal H, Desai K. Canny edge detection: a comprehensive review. Int J Tech Res Sci. 2024;9:27-35.

43. Gao Y, Jiang Y, Peng Y, Yuan F, Zhang X, Wang J. Medical image segmentation: a comprehensive review of deep learning-based methods. Tomography. 2025;11:52.

44. Morgan AA, Abdi J, Syed MAQ, Kohen GE, Barlow P, Vizcaychipi MP. Robots in healthcare: a scoping review. Curr Robot Rep. 2022;3:271-280.

45. Rojas Burbano JC, Ruiz NI, Rojas Burbano GA, Guacho Inca JS, Arragan Lezama CA, González MS. Robot-assisted surgery: current applications and future trends in general surgery. Cureus. 2025;17:e82318.

46. Wah JNK. The rise of robotics and AI-assisted surgery in modern healthcare. J Robot Surg. 2025;19:311.

47. Banyai AD, Brișan C. Robotics in physical rehabilitation: systematic review. Healthcare (Basel). 2024;12:1720.

48. Wu YN, Gao R, Han T, Zhu SC. A tale of three probabilistic families: discriminative, descriptive, and generative models. Q Appl Math. 2019;77:423-465.

49. Ng AY, Jordan MI. On discriminative vs. generative classifiers: a comparison of logistic regression and naive Bayes. Dietterich TG, Becker S, Ghahramani Z, ed. Advances

in Neural Information Processing Systems 14. 1. basım. Cambridge: MIT Press. 2002:841-848.

50. Shalev-Shwartz S, Ben-David S. Understanding Machine Learning: From Theory to Algorithms. 1. basım. Cambridge: Cambridge University Press. 2014.

51. Ahsan MM, Luna SA, Siddique Z. Machine-learning-based disease diagnosis: a comprehensive review. Healthcare (Basel). 2022;10:541.

52. Burges CJC. A tutorial on support vector machines for pattern recognition. Data Min Knowl Discov. 1998;2:121-167.

53. Schober P, Vetter TR. Logistic regression in medical research. Anesth Analg. 2021;132:365-366.

54. LeCun Y, Bengio Y, Hinton G. Deep learning. Nature. 2015;521:436-444.

55. Quinlan JR. Induction of decision trees. Mach Learn. 1986;1:81-106.

56. Salman HA, Kalakech A, Steiti A. Random forest algorithm overview. Babylonian J Mach Learn. 2024;2024:69-79.

57. Şener B. Tıbbi görüntülemede derin üretken modeller: bir literatür taraması. Politek Derg. 2025;28:413-433.

58. Türk M. The future role of generative artificial intelligence (AI) in medicine. J Clin Pract Res. 2024;10:211-213.

59. Regenwetter L, Nobari AH, Ahmed F. Deep generative models in engineering design: a review. J Mech Des. 2022;144:071704.

60. Bond-Taylor S, Leach A, Long Y, Willcocks CG. Deep generative modelling: a comparative review of VAEs, GANs, normalizing flows, energy-based and autoregressive models. IEEE Trans Pattern Anal Mach Intell. 2022;44:7327-7347.

61. Bommasani R, Hudson DA, Adeli E ve ark. On the opportunities and risks of foundation models. arXiv. 2022;arXiv:2108.07258.

62. Rouzrokh P, Khosravi B, Faghani S ve ark. A current review of generative AI in medicine: core concepts, applications, and current limitations. Curr Rev Musculoskelet Med. 2025;18:246-266.

63. Tortora L. Beyond discrimination: generative AI applications and ethical challenges in forensic psychiatry. Front Psychiatry. 2024;15:1346059.

64. He R, Cao J, Tan T. Generative artificial intelligence: a historical perspective. Natl Sci Rev. 2025;12:nwaf050.

65. Maity S, Saikia MJ. Large language models in healthcare and medical applications: a review. Bioengineering (Basel). 2025;12:631.

66. Bandi A, Adapa PVSR, Kuchi YEVPK. The power of generative AI: a review of requirements, models, input–output formats, evaluation metrics, and challenges. Future Internet. 2023;15:260.

67. Çelik G, Talu MF. Çekişmeli üretken ağ modellerinin görüntü üretme performanslarının incelenmesi. Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Derg. 2020;22:181-192.

68. Yılmaz B. Generative adversarial network for load data generation: Türkiye energy market case. Math Model Numer Simul Appl. 2023;3:141-158.

69. Ahmad W, Ali H, Shah Z, Azmat S. A new generative adversarial network for medical images super resolution. Sci Rep. 2022;12:9533.

70. Ali H, Biswas MdR, Mohsen F ve ark. The role of generative adversarial networks in brain MRI: a scoping review. Insights Imaging. 2022;13:98.

71. Barışkan MA, Orman Z, Şamlı R. Common generative adversarial network types and practical applications. Eur J Sci Technol. 2020;(EJOSAT Special Issue 2020):585-590.

72. Kingma DP, Welling M. Auto-encoding variational Bayes. arXiv. 2013;arXiv:1312.6114.

73. Teli A. Uncover this tech term: variational autoencoders. Korean J Radiol. 2025;26(6):616-619.

74. Tarı Ö, Arpacı N. İlaç tasarımında yapay zekâ uygulamaları. Ank Univ Eczacilik Fak Derg. 2024;48(1):327-365.

75. Kim K, Hong GS, Kim N. Primer on generative artificial intelligence and large language models in medical imaging. J Korean Soc Radiol. 2024;85(5):848-860.

76. Hung ALY, Zhao K, Zheng H ve ark. Med-cDiff: conditional medical image generation with diffusion models. Bioengineering (Basel). 2023;10(11):1258.

77. Thirunavukarasu AJ, Ting DSJ, Elangovan K, Gutierrez L, Tan TF, Ting DSW. Large language models in medicine. Nat Med. 2023;29(8):1930-1940.

78. Meng X, Yan X, Zhang K ve ark. The application of large language models in medicine: a scoping review. iScience. 2024;27(5):109713.

79. Wong IN, Monteiro O, Baptista-Hon DT ve ark. Leveraging foundation and large language models in medical artificial intelligence. Chin Med J (Engl). 2024;137(21):2529-2539.

80. McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. Bull Math Biophys. 1943;5(4):115-133.

81. Turing AM. Computing machinery and intelligence. Mind. 1950;59(236):433-460.

82. McCarthy J, Minsky ML, Rochester N, Shannon CE. A proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955. AI Mag. 2006;27(4):12-14.

83. Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain. Psychol Rev. 1958;65(6):386-408.

84. Rumelhart DE, Hinton GE, Williams RJ. Learning representations by back-propagating errors. Nature. 1986;323(6088):533-536.

85. Hochreiter S, Schmidhuber J. Long short-term memory. Neural Comput. 1997;9(8):1735-1780.

86. LeCun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. Proc IEEE. 1998;86(11):2278-2324.

87. Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. In: Pereira F, Burges CJC, Bottou L, Weinberger KQ, ed. Advances in Neural Information Processing Systems 25. New York, NY: Curran Associates, Inc. 2012:1097-1105.

88. Mikolov T, Chen K, Corrado G, Dean J. Efficient estimation of word representations in vector space. arXiv. 2013;arXiv:1301.3781.

89. Lopez R, Gayoso A, Yosef N. Enhancing scientific discoveries in molecular biology with deep generative models. Mol Syst Biol. 2020;16(9):e9198.

90. Goodfellow IJ, Pouget-Abadie J, Mirza M ve ark. Generative adversarial networks. In: Ghahramani Z, Welling M, Cortes C, Lawrence ND, Weinberger KQ, ed. Advances in Neural Information Processing Systems 27. New York, NY: Curran Associates, Inc. 2014:2672-2680.

91. Vaswani A, Shazeer N, Parmar N ve ark. Attention is all you need. Adv Neural Inf Process Syst. 2017;30:5998-6008.

92. Devlin J, Chang MW, Lee K, Toutanova K. BERT: pre-training of deep bidirectional transformers for language understanding. In: Burstein J, Doran C, Solorio T, ed. Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers). Minneapolis, Minnesota: Association for Computational Linguistics. 2019:4171-4186.

93. Ho J, Jain A, Abbeel P. Denoising diffusion probabilistic models. Adv Neural Inf Process Syst. 2020;33:6840-6851.

94. Rombach R, Blattmann A, Lorenz D, Esser P, Ommer B. High-resolution image synthesis with latent diffusion models. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR 2022). New Orleans, LA: IEEE Computer Society. 2022:10684-10695.

95. Ramesh A, Pavlov M, Goh G ve ark. Zero-shot text-to-image generation. In: Meila M, Zhang T, ed. Proceedings of the 38th International Conference on Machine Learning. Volume 139, Proceedings of Machine Learning Research. PMLR. 2021:8821-8831.

96. Buchanan BG, Shortliffe EH, ed. Rule-Based Expert Systems: The MYCIN Experiments of the Stanford Heuristic Programming Project. Reading, MA: Addison-Wesley. 1984.

97. Miller RA, Pople HE, Myers JD. INTERNIST-I, an experimental computer-based diagnostic consultant for general internal medicine. N Engl J Med. 1982;307:468-476.

98. Koshino K, Werner RA, Pomper MG ve ark. Narrative review of generative adversarial networks in medical and molecular imaging. Ann Transl Med. 2021;9:821.

99. Asgariandehkordi H, Goudarzi S, Basarab A, Rivaz H. Deep ultrasound denoising using diffusion probabilistic models. In: 2023 IEEE International Ultrasonics Symposium (IUS). Montreal, Quebec, Canada: IEEE. 2023:1-4.

100. Suram VCK. AI in healthcare: enhancing diagnostics, treatment, and patient care. World J Adv Res Rev. 2022;13(2):574-583.

101. Hirosawa T, Shimizu T. A narrative review of artificial intelligence in medical diagnostics. Comput Mater Contin. 2025;83(3):3919-3944.

102. Khalid SA, Khaliq T, Rehman YN, Anwar Z, Mirani W. Comparative performance of artificial intelligence and radiologists in detecting lung nodules and breast lesions on CT and MRI: a systematic review. Cureus. 2025;17(11):e95943.

103. Debellotte O, Dookie RL, Rinkoo F ve ark. Artificial intelligence and early detection of breast, lung, and colon cancer: a narrative review. Cureus. 2025;17(2):e79199.

104. Liu W, Wu Y, Zheng Z, Bittle M, Yu W, Kharrazi H. Enhancing diagnostic accuracy of lung nodules in chest computed tomography using artificial intelligence: retrospective analysis. J Med Internet Res. 2025;27:e64649.

105. Chang HY, Jung CK, Woo JI ve ark. Artificial intelligence in pathology. J Pathol Transl Med. 2019;53(1):1-12.

106. McGenity C, Clarke EL, Jennings C ve ark. Artificial intelligence in digital pathology: a systematic review and meta-analysis of diagnostic test accuracy. NPJ Digit Med. 2024;7(1):114.

107. Behara K, Bhero E, Agee JT. AI in dermatology: a comprehensive review into skin cancer detection. PeerJ Comput Sci. 2024;10:e2530.

108. Oladele O. AI-powered medical imaging: a comprehensive review of applications, benefits, and challenges. ResearchGate. 2024.

109. Aldughayfiq B, Ashfaq F, Jhanjhi NZ, Humayun M. A deep learning approach for atrial fibrillation classification using multi-feature time series data from ECG and PPG. Diagnostics (Basel). 2023;13(14):2442.

110. Popat A, Yadav S, Obholz J, Hwang EA, Rehman AU, Sharma P. The efficacy of artificial intelligence in the detection and management of atrial fibrillation. Cureus. 2025;17(1):e77135.

111. Sheng B, Chen X, Li T ve ark. An overview of artificial intelligence in diabetic retinopathy and other ocular diseases. Front Public Health. 2022;10:971943.

112. Picozzi P, Nocco U, Labate C ve ark. Advances in robotic surgery: a review of new surgical platforms. Electronics (Basel). 2024;13:4675.

113. Elkohail A, Soffar A, Khalifa AM ve ark. AI-enhanced surgical decision-making in orthopedics: from preoperative planning to intraoperative guidance and real-time adaptation. Cureus. 2025;17:e92762.

114. Bertolino L, Ranzini MBM, Favaro A, Bardi E, Ronzoni FL, Bonanzinga T. Use of artificial intelligence on imaging and preoperatory planning of the knee joint: a scoping review. Medicina (Kaunas). 2025;61:737.

115. Long Y, Cao J, Deguet A, Taylor RH, Dou Q. Integrating artificial intelligence and augmented reality in robotic surgery: an initial dVRK study using a surgical education scenario. In: 2022 International Symposium on Medical Robotics, ISMR 2022. Atlanta: IEEE. 2022:1-8.

116. Abbas GH, Speksnijder C, Ramnarain D ve ark. AI-driven rehabilitation robotics: advancements in and impacts on patient recovery. Cureus. 2025;17:e94273.

117. Davenport T, Kalakota R. The potential for artificial intelligence in healthcare. Future Healthc J. 2019;6:94-98.

118. Chen Z, Liang N, Zhang H ve ark. Harnessing the power of clinical decision support systems: challenges and opportunities. Open Heart. 2023;10:e002432.

119. Nuffield Council on Bioethics. Artificial Intelligence (AI) in Healthcare and Research. London: Nuffield Council on Bioethics. 2018.

120. Varela-Rey I, Bandín-Vilar E, Toja-Camba FJ ve ark. Artificial intelligence and machine learning applications to pharmacokinetic modeling and dose prediction of antibiotics: a scoping review. Antibiotics (Basel). 2024;13:1203.

121. Kim H, Kim E, Lee I, Bae B, Park M, Nam H. Artificial intelligence in drug discovery: a comprehensive review of data-driven and machine learning approaches. Biotechnol Bioprocess Eng. 2020;25:895-930.

122. Du Y, Yang P, Liu Y, Deng C, Li X. Artificial intelligence in chronic disease self-management: current applications and future directions. Front Public Health. 2025;13:1689911.

123. Tsvetanov F. Integrating AI technologies into remote monitoring patient systems. Eng. Proc. 2024;70:54.

124. Riadi D, Trihandini I, Sari D, Wijaya F. COVID-19'da yeniden hastaneye yatış riskini azaltmada uzaktan hasta izlemenin etkinliği: bir meta-analiz. Kesmas. 2025;20:10-20.

125. Rajkomar A, Dean J, Kohane I. Machine learning in medicine. N Engl J Med. 2019;380:1347-1358.

126. Jafleh EA, Alnaqbi FA, Almaeeni HA, Faqeeh S, Alzaabi MA, Al Zaman K. The role of wearable devices in chronic disease monitoring and patient care: a comprehensive review. Cureus. 2024;16:e68921.

127. Alkhameeas AA, Madani YA, Aldailej SA ve ark. The impact of nurse staffing on patient outcomes: a comprehensive review. Int J Innov Res Eng Multidiscip Phys Sci. 2024;12:1-6.

128. Akbaşlı İT, Birbilen AZ, Teksam O. Artificial intelligence-driven forecasting and shift optimization for pediatric emergency department crowding. JAMIA Open. 2025;8:ooae138.

129. Kumar R, Singh A, Ahmed Kassar AS ve ark. Impact of an artificial intelligence-driven operational management system on operational efficiency in health care organization in Saudi Arabia: a mediating role of staff attitude. Front Public Health. 2025;13:1558644.

130. Sendekie AK, Limenh LW, Abate BB ve ark. Artificial intelligence in community pharmacy practice: pharmacists' perceptions, willingness to utilize, and barriers to implementation. Explor Res Clin Soc Pharm. 2024;16:100542.

131. Huang T, Li LT, Bernstam EV, Jiang X. Confidence-based laboratory test reduction recommendation algorithm. BMC Med Inform Decis Mak. 2023;23:93.

132. De Mattei L, Morato MQ, Sidhu V ve ark. Are artificial intelligence virtual simulated patients (AI-VSP) a valid teaching modality for health professional students? Clin Simul Nurs. 2024;92:101536.

133. Elendu C, Amaechi DC, Okatta AU ve ark. The impact of simulation-based training in medical education: a review. Medicine (Baltimore). 2024;103:e38813.

134. Mao RQ, Lan L, Kay J ve ark. Immersive virtual reality for surgical training: a systematic review. J Surg Res. 2021;268:40-58.

135. Basnawi A, Koshak A. Application of artificial intelligence in advanced training and education of emergency medicine doctors: a narrative review. Emerg Care Med. 2024;1:247-259.

136. Başer Kolcu Mİ, Kolcu G. Artificial intelligence applications in medical education – Tıp eğitiminde yapay zekâ uygulamaları. Int J Interdiscip Interact Health Sci. 2024;3:28-37.

137. Mir MM, Mir GM, Raina NT ve ark. Application of artificial intelligence in medical education: current scenario and future perspectives. J Adv Med Educ Prof. 2023;11:133-140.

138. Riley SC, Morton J, Ray DC, Swann DG, Davidson DJ. An integrated model for developing research skills in an undergraduate medical curriculum: appraisal of an approach using student selected components. Perspect Med Educ. 2013;2:230-247.

139. Bolaños F, Salatino A, Osborne F, Motta E. Artificial intelligence for literature reviews: opportunities and challenges. Artif Intell Rev. 2024;57:259.

140. Khalifa M, Albadawy M. Using artificial intelligence in academic writing and research: an essential productivity tool. Comput Methods Programs Biomed Update. 2024;5:100145.

141. Kim W, Jeon SY, Byun G, Yoo H, Choi JH. A systematic review of deep learning-based denoising for low-dose computed tomography from a perceptual quality perspective. Biomed Eng Lett. 2024;14:1153-1173.

142. Akrami H, Joshi AA, Li J, Aydore S, Leahy RM. Brain lesion detection using a robust variational autoencoder and transfer learning. In: 2020 IEEE 17th International Symposium on Biomedical Imaging (ISBI). Iowa City: IEEE. 2020:786-790.

143. Janumpally R, Nanua S, Ngo A, Youens K. Generative artificial intelligence in graduate medical education. Front Med (Lausanne). 2025;11:1525604.

144. Xu X, Chen Y, Miao J. Opportunities, challenges, and future directions of large language models, including ChatGPT in medical education: a systematic scoping review. J Educ Eval Health Prof. 2024;21:6.

145. Chauhan A, Khaliq F, Nayak KR. Assessing quality of scenario-based multiple-choice questions in physiology: faculty-generated vs. ChatGPT-generated questions among Phase I medical students. Int J Artif Intell Educ. 2025;35:2315-2344.

146. Zeng X, Wang F, Luo Y ve ark. Deep generative molecular design reshapes drug discovery. Cell Rep Med. 2022;3:100794.

147. Marshall I, Kuiper J, Banner E, Wallace BC. Automating biomedical evidence synthesis: RobotReviewer. In: Bansal M, Ji H, ed. Proceedings of ACL 2017, System Demonstrations. Vancouver: Association for Computational Linguistics. 2017:7-12.

148. Kuo SM, Tai SK, Lin HY, Chen RC. Automated clinical trial data analysis and report generation by integrating retrieval-augmented generation (RAG) and large language model (LLM) technologies. AI. 2025;6:188.

149. Wornow M, Xu Y, Thapa R ve ark. The shaky foundations of large language models and foundation models for electronic health records. NPJ Digit Med. 2023;6:135.

150. Murdoch B. Privacy and artificial intelligence: challenges for protecting health information in a new era. BMC Med Ethics. 2021;22:122.

151. Ho CH. Secondary use of health data for medical AI: a cross-regional examination of Taiwan and the EU. Asian Bioeth Rev. 2024;16(3):407-422.

152. Yadav N, Pandey S, Gupta A, Dudani P, Gupta S, Rangarajan K. Data privacy in healthcare: in the era of artificial intelligence. Indian Dermatol Online J. 2023;14(6):788-792.

153. Hurley ME, Lang BH, Kostick-Quenet KM, Smith JN, Blumenthal-Barby J. Patient consent and the right to notice and explanation of AI systems used in health care. Am J Bioeth. 2025;25(3):102-114.

154. Ashwin M, Jha S, Prasad G, Kumar S. Fake it till you make it? AI hallucinations and ethical dilemmas in anesthesia research and practice. J Anaesthesiol Clin Pharmacol. 2025;41(3):381-383.

155. Koçak B, Ponsiglione A, Stanzione A ve ark. Bias in artificial intelligence for medical imaging: fundamentals, detection, avoidance, mitigation, challenges, ethics, and prospects. Diagn Interv Radiol. 2025;31(2):75-88.

156. Nagendran M, Chen Y, Lovejoy CA ve ark. Artificial intelligence versus clinicians: systematic review of design, reporting standards, and claims of deep learning studies. BMJ. 2020;368:m689.

157. Asgari E, Montaña-Brown N, Dubois M ve ark. A framework to assess clinical safety and hallucination rates of LLMs for medical text summarisation. NPJ Digit Med. 2025;8(1):274.

158. Habli I, Lawton T, Porter Z. Artificial intelligence in health care: accountability and safety. Bull World Health Organ. 2020;98(4):251-256.

159. Bleher H, Braun M. Diffused responsibility: attributions of responsibility in the use of AI-driven clinical decision support systems. AI Ethics. 2022;2(4):747-761.

160. Goddard K, Roudsari A, Wyatt JC. Automation bias: a systematic review of frequency, effect mediators, and mitigators. J Am Med Inform Assoc. 2012;19(1):121-127.

161. Benjamens S, Dhunnoo P, Meskó B. The state of artificial intelligence-based FDA-approved medical devices and algorithms: an online database. NPJ Digit Med. 2020;3:118.

162. Shaw J, Ali J, Atuire CA ve ark. Research ethics and artificial intelligence for global health: perspectives from the global forum on bioethics in research. BMC Med Ethics. 2024;25:46.

163. Jiang F, Jiang Y, Zhi H ve ark. Artificial intelligence in healthcare: past, present and future. Stroke Vasc Neurol. 2017;2:230-243.

164. Croxford E, Gao Y, First E ve ark. Evaluating clinical AI summaries with large language models as judges. NPJ Digit Med. 2025;8:640.

165. World Health Organization (WHO). Ethics and Governance of Artificial Intelligence for Health: WHO Guidance, 1. basım. Geneva: World Health Organization. 2021.

166. Teo ZL, Jin L, Liu N ve ark. Federated machine learning in healthcare: a systematic review on clinical applications and technical architecture. Cell Rep Med. 2024;5:101419.

167. Arslankara VB, Usta E. Generative artificial intelligence as a lifelong learning self efficacy: usage and competence scale. J Teach Educ Lifelong Learn. 2024;6:288-302.

168. Aksu M. Öğrencilerin yapay zekâya ilişkin bilgi, tutum ve bakış açılarının analizi. J Acad Soc Sci Stud. 2025;18:467-484.

169. Syeda LH, Batool Z, Hayder Z, Ali S. Medical undergraduate students' awareness and perspectives on artificial intelligence: a developing nation's context. BMC Med Educ. 2025;25:1060.

170. Karaferis D, Balaska D, Karaferi ME, Pollalis Y. Assessment of knowledge and attitudes of healthcare personnel towards artificial intelligence technologies in Greece: a survey study. Hygiene (Basel). 2025;5:44.

171. Tran C, Hryciw BN, Moore SW, Chaput A, Seely AJE. Perceptions and use of generative artificial intelligence in medical students: a multicenter survey. J Med Educ Curric Dev. 2025;12:23821205251391969.

172. Ghanem OA, Hagag AM, Kormod ME ve ark. Medical students' knowledge, attitudes, and practices toward generative artificial intelligence in Egypt 2024: a cross-sectional study. BMC Med Educ. 2025;25:790.

173. Fußhöller A, Lechner F, Schlicker N ve ark. Perceptions, usage, and educational impact of ChatGPT among medical students in Germany: cross-sectional mixed methods survey. JMIR Form Res. 2025;9:e81484.

174. Zhang JS, Yoon C, Williams DKA, Pinkas A. Exploring the usage of ChatGPT among medical students in the United States. J Med Educ Curric Dev. 2024;11:23821205241264695.

175. Kaban YE, Aygün D, Til A. Tıp ve diş hekimliği fakültesi öğrencilerinin yapay zekâya yönelik genel tutumu ve yapay zekâ okuryazarlık seviyelerinin belirlenmesi. Tıp Eğitimi Dünyası. 2025;24(73):19-25.

176. Norris SA, Kron T, Masterson M, Badawy MK. An Australasian survey on the use of ChatGPT and other large language models in medical physics. Phys Eng Sci Med. 2025;48:1145-1153.

177. Ganjavi C, Eppler M, O'Brien D ve ark. ChatGPT and large language models (LLMs) awareness and use: a prospective cross-sectional survey of U.S. medical students. PLOS Digit Health. 2024;3:e0000596.

178. Alammari D, Alamari E, Alamri R, Alharbi R, Felimban J, Aljohani J. Assessing medical students' attitudes, performance, and usage of ChatGPT in Jeddah, Saudi Arabia. Front Artif Intell. 2025;8:1577911.

179. Chang LC, Hung LL, Liu TW, Huang CH, Lin HL, Liao LL. Relationships between ChatGPT use with self-directed learning and critical thinking among school and university nurses in Taiwan. BMC Nurs. 2025;24:1426.

180. Ahmed WMM, Abdalmotalib MM, Elbadawi MH ve ark. Shaping the future of medical education: a cross-sectional study on ChatGPT attitude and usage among medical students in Sudan. PLOS ONE. 2025;20(5):e0324698.

181. Kandemir F, Azizoğlu F. Hemşirelerin yapay zekâya yönelik genel tutumlarının incelenmesi. Yoğun Bakım Hemşireliği Derg. 2024;28(2):113-125.

182. Pedro AR, Dias MB, Laranjo L, Cunha AS, Cordeiro JV. Artificial intelligence in medicine: a comprehensive survey of medical doctors' perspectives in Portugal. PLOS ONE. 2023;18(9):e0290613.

183. Jendly M, Santschi V, Tancredi S, Chiolero A. Primary care physician eHealth profile and care coordination: a cross-sectional study. Swiss Med Wkly. 2024;154(10):3851.

184. Zhang J, Luo B, Liu X, He Y, Zuo Y. Explore the use of complementary and alternative medicine among Chinese gynaecological patients with cancer undergoing chemotherapy: a qualitative phenomenological study. BMJ Open. 2023;13(12):e074313.

185. Ajalo E, Mukunya D, Nantale R ve ark. Widespread use of ChatGPT and other artificial intelligence tools among medical students in Uganda: a cross-sectional study. PLOS ONE. 2025;20(1):e0313776.

186. Verghese BG, Iyer C, Borse T, Cooper S, White J, Sheehy R. Modern artificial intelligence and large language models in graduate medical education: a scoping review of attitudes, applications & practice. BMC Med Educ. 2025;25(1):730.

187. Hu N, Jiang XQ, Wang YD ve ark. Status and perceptions of ChatGPT utilization among medical students: a survey-based study. BMC Med Educ. 2025;25(1):831.

188. Kharko A, Garcia Sanchez C, Hagström J ve ark. General practitioners' opinions of generative artificial intelligence in the UK: an online survey. Digit Health. 2025;11:20552076251360863.

189. Başer A, Altuntaş SB, Kolcu G, Özceylan G. Artificial intelligence anxiety of family physicians in Turkey. Prog Nutr. 2021;23(S2):e2021275.

190. Moallem E, Ghavami V, Moghri J, Marvi A, Najafi MS, Tabatabaee SS. Medical students' attitudes towards artificial intelligence and educational needs: a cross-sectional study. J Health Adm. 2025;28(1):40-55.

191. Malik AR, Pratiwi Y, Andajani K ve ark. Exploring artificial intelligence in academic essay: higher education students' perspective. Int J Educ Res Open. 2023;5:100296.

192. Aydın Ş, Güntepe ET. Lisansüstü öğrencilerin perspektifinden üretken yapay zekâ kullanımına yönelik bir değerlendirme. 18. Uluslararası Bilgisayar ve Öğretim Teknolojileri Sempozyumu (ICITS 2025), 18-19 Eylül 2025, Ankara, Türkiye. Erişim adresi: https://webupload.gazi.edu.tr/upload/1232/2025/10/30/94284d6f-f394-4dd8-a232-9b20e50d42c3-icits-2025-ozetler-v2.pdf

193. Arslankara VB, Usta E. Öğretmenlerin üretken yapay zekâ kullanım ve yeterlikleri ile dijital iyi oluş hallerinin incelenmesi. Uluslararası Eğitim Yönetimi Forumu (EYFOR-16), 30 Nisan-4 Mayıs 2025, Antalya, Türkiye. Erişim adresi: https://www.eyuder.org/