


Eczacılık için Yapay Zekâ Araç Seti

Eczacılar için giriş ve
kaynak rehberi

2025



FIP Development Goals



Bütün hakları Uluslararası Eczacılık Federasyonu'na (FIP) aittir.

Uluslararası Eczacılık Federasyonu (FIP)
Andries Bickerweg 5
2517 JP Lahey
Hollanda
www.fip.org

Tüm hakları saklıdır. Bu yayının hiçbir bölümü kaynak gösterilmeden herhangi bir erişim sisteminde saklanamaz veya elektronik, mekanik, kayıt veya başka bir şekilde kopyalanamaz. FIP, bu raporda yer alan herhangi bir veri ve bilginin kullanımından kaynaklanan zararlardan sorumlu tutulamaz. Bu raporda sunulan veri ve bilgilerin doğruluğunu sağlamak için tüm önlemler alınmıştır. Belge, Türk Eczacıları Birliği tarafından İngilizce'den çevrilmiştir. Orijinal ile çevirinin ayrışması durumunda metnin orijinal hali dikkate alınmalıdır.

Editör:

Dr. Whitley Yi, FIP Teknoloji Danışma Grubu Yapay Zeka Çalışma Grubu Başkanı

Yardımcı editörler:

Dr. Ardalan Mirzaei, FIP Sağlık ve İlaç Bilgi Bölümü Asya Pasifik Temsilcisi
Brent Sin Hidge, FIP Teknoloji Danışma Grubu Yapay Zekâ Çalışma Grubu
Dr. Mariana Guia, FIP Teknoloji Danışma Grubu Yapay Zekâ Çalışma Grubu
Dr. Paul Voigt, FIP Teknoloji Danışma Grubu Yapay Zekâ Çalışma Grubu

Önerilen alıntı biçimi:

Uluslararası Eczacılık Federasyonu (FIP). Eczacılık İçin Yapay Zeka Araç Seti - Eczacılar için giriş ve kaynak rehberi. Lahey: Uluslararası Eczacılık Federasyonu; 2025

İçindekiler

Türkçe çeviriye önsöz	3
Teşekkürler	4
1 Yönetici özeti	5
2 Önsöz.....	6
2.1 Bu araç setinin yazılma amacı	6
2.2 Yapay Zekâ ve FIP gelişim hedefleri.....	7
3 Arka plan	8
3.1 Yapay zekânın temelleri	8
3.1.1 Yapay zekânın öğrenme biçimleri.....	9
3.1.2 Yapay zekâ araç türleri	10
3.2 Yapay zekâ performansının değerlendirilmesi.....	11
3.2.1 Performans neden ölçülür?	11
3.2.2 Nasıl şeffaf ve hesap verebilir olunur ve güven inşa edilir?	11
3.3 Sınıflandırma modellerinde kullanılan performans ölçütleri	14
4 Etik olarak göz önünde bulundurulması gereken hususlar	16
4.1 Güvenilebilir bir yapay zekâ yaratmak	16
4.2 Yapay zekânın sağlık hizmetinde kullanılması durumunda göz önünde bulundurulması gereken etik hususlar	17
4.2.1 Etik hususlar	17
4.2.2 Sağlık hizmetlerinde yapay zekânın etik bir şekilde kullanılması için etki azaltma stratejisi.....	18
5 ISO düzenlemeleri ve uyumluluk.....	21
5.1 Genel yapay zekâ mevzuatı.....	21
5.2 Verilerin korunması ve sağlık hizmetinde özel hayatın gizliliği	21
5.2.1 İnsan merkezli yapay zekâ.....	22
5.2.2 Algoritmaların yeniden üretilebilirliği ve klinik olarak doğrulanması	22
5.2.3 Birlikte çalışabilirlik standartları.....	23
5.2.4 Siber güvenlik önlemleri	23
5.2.5 Erişilebilirlik ve kapsayıcılık.....	23
5.2.6 Gelecekte göz önünde bulundurulması gereken hususlar	23
6 Uygulama süreçlerinde sık görülen engeller	24
6.1 Algoritmik taraflılık.....	24
6.2 Model sapması.....	25
6.3 Ezberleme.....	25
6.3.1 Akılda tutulması gereken diğer engeller:.....	26
6.4 Artıları ve eksileri belirleyerek doğru aracı seçme.....	26
6.4.1 Modeller arasındaki artı ve eksilerin tartılması.....	27
7 Uygulama kontrol listesi.....	33
8 Yapay zekâ yetkinliğinin eğitimi ve geliştirilmesi	34
8.1 Eczacıların yapay zekâ hakkında bilmesi gerekenler nelerdir?	34
8.2 Yapay zekâ bilgi ve becerileri.....	35
9 Kaynakça	36
Ek - Bu araç setinde kullanılan terimler sözlüğü	39

Türkçe Baskı Bilgisi

ISBN: 978-975-8037-96-4

Türk Eczacıları Birliği Yayın Editörü:

Dr. Öğr. Üyesi Cansu Göncüoğlu
Selçuk Üniversitesi Eczacılık Fakültesi
Eczacılık Meslek Bilimleri Bölümü
Klinik Eczacılık Ana Bilim Dalı

Çeviren:

Murat Beşik, Dr. Ecz. Betül Topçu İnce

Grafik Tasarım: FIP

Baskı: Fersa Matbaacılık Paz. San. ve Tic. Ltd. Şti.
Ostim 1207 cadde, No.5/C-D, Yenimahalle / Ankara
Matbaa Sertifika No: 50262

Türke eviriye

Önsöz

Hızla deėiřen ve dijitalleşen dünyada, yapay zekâ teknolojileri saėlık ve eczacılık alanında da dönüřtürücü bir güç olarak öne çıkmaya başladı. Bu teknolojinin çerçevesi, hangi yasal kurallara dayanarak kullanılması gerektiėi ve etik sınırları dünya genelinde henüz bir tartışma konusu. Ancak yapay zekâ uygulamalarına ilişkin mesleki bir yaklaşım geliřtirmek de kaçınılmaz.

Bu hızlı teknolojik dönüşüm sürecinde, veri gizliliėi, etik kaygılar ve nihayetinde eczacılık mesleėinin geleceėi, üzerinde ok ciddi düşünülmesi gereken konular olarak önümüze geliyor. İnsan odaklı yaklaşımı sürdürerek, yapay zekânın mesleki çerçevemize uygun desteklerini kullanmamız dönüşüme uyum açısından önem taşıyor.

Uluslararası Eczacılık Federasyonu'nun (FIP) hazırladıėı ve Türk Eczacıları Birliėinin Türke evirisini yaptıėı "Eczacılık İin Yapay Zekâ Ara Kiti", eczacıların bu yeniliki teknolojileri mesleki uygulamalarına hangi yöntemleri kullanarak entegre edebilecekleriyle ilgili bir rehber niteliėi taşıyor. Kılavuz, hasta odaklı tedavi süreçlerinde yapay zekâ teknolojilerinden faydalanmanın, bunu yaparken de eczacılık pratiėini daha güvenli ve yeniliki hale getirmenin yollarını gösteriyor.

FIP'nin bu deėerli alışmasının meslektaşlarımızın yapay zekâ teknolojilerini her yönüyle, mesleki etik ilkelerden ödün vermeden deėerlendirmelerine katkı vereceėine inanıyoruz.

Ecz. Arman ÜNEY
Türk Eczacıları Birliėi Başkanı

Teşekkürler

FIP, bu araç setini geliştiren tüm yazarlara minnettarlığını ve takdirlerini sunmaktadır:

- Whitley Yi, PharmD, BCPS, FIP Teknoloji Danışma Grubu Yapay Zekâ Çalışma Grubu Başkanı, FIP Teknoloji Danışma Grubu Üyesi, Eczacılık ve Üye Hizmetleri Direktörü, Colorado Üniversitesi Skaggs Eczacılık ve Farmasötik Bilimler Fakültesi Öğretim Görevlisi, ABD
- Brent Sin Hidge, BPharm (NMU), FIP Teknoloji Danışma Grubu Yapay Zekâ Çalışma Grubu; Güney Afrika Eczacılar Birliği Ulusal Yürütme Komitesi üyesi; Güney Afrika Hastane ve Kurumsal Eczacılar Birliği Western Cape Başkanı; Hastane Eczacısı, Netcare Blaauwberg Hastanesi, Güney Afrika
- Bruno Macedo, FIP Teknoloji Danışma Grubu Yapay Zekâ Çalışma Grubu, MedFacts CEO'su ve Kurucusu, Program Yöneticisi, Calouste Gulbenkian Vakfı, Portekiz
- Claudia Rijcken, FIP Teknoloji Danışma Grubu Yapay Zekâ Çalışma Grubu, FIP Teknoloji Danışma Grubu Üyesi, CSO ve Pharmi Kurucusu, Utrecht Üniversitesi Eczacılık Fakültesi Öğretim Görevlisi, Hollanda
- Florencia Ojeda, Sistem Mühendisi, Yapay Zekâ Yüksek Lisansı, FIP Teknoloji Danışma Grubu Yapay Zekâ Çalışma Grubu Üyesi, Uruguay
- Joanna Klopotoska, FIP Teknoloji Danışma Grubu Yapay Zekâ Çalışma Grubu, Yardımcı Doçent ve Baş Araştırmacı, Amsterdam UMC Akademik Tıp Merkezi, Hollanda
- Mariana Guia, PharmD; FIP Teknoloji Danışma Grubu Yapay Zekâ Çalışma Grubu; Sağlık Çözümleri Uzmanı, Portekiz Ulusal Eczaneler Birliği, Portekiz
- Markus Manner, FIP Teknoloji Danışma Grubu Yapay Zekâ Çalışma Grubu, Geliştirme Müdürü, Suomen Apteekkariliitto, Finlandiya Eczaneler Birliği, Finlandiya
- Martin Kondža, MPharm, PhD, FIP Teknoloji Danışma Grubu Yapay Zekâ Çalışma Grubu, Yardımcı Doçent, Mostar Üniversitesi, Bosna Hersek / Bosna Hersek Federasyonu Eczacı Odası, Bosna Hersek
- Mauro Tschanz, FIP Teknoloji Danışma Grubu Yapay Zekâ Çalışma Grubu, İsviçre Eczacılık Birliği (PharmaSuisse) Dijitalleşme Uzmanı, İsviçre
- Mohd Syamir Mohamad Shukeri, B.Pharm., M. Comm. Sağlık, R.Ph. MMPS, FIP Teknoloji Danışma Grubu Yapay Zekâ Çalışma Grubu, Malezya Eczacılar Birliği, Malezya
- Paul Voigt, BPharm, MSc, DBiotech, ADHSML, FIP Teknoloji Danışma Grubu Yapay Zekâ Çalışma Grubu, Güney Afrika Eczacılık Derneği, Envanter Operasyonları Müdürü, Mediclinic, Güney Afrika
- Régis Vaillancourt, B.Pharm., PharmD, FFIP, FOPQ, FCSHP, FIP Teknoloji Danışma Grubu Yapay Zekâ Çalışma Grubu, Eczacılık İşleri Başkan Yardımcısı BCE Pharma A.Ş., Kanada
- Sangeetha Ramdave, FIP Teknoloji Danışma Grubu Yapay Zekâ Çalışma Grubu, Misafir Akademisyen, Monash Üniversitesi, Avustralya

FIP, FIP Teknoloji Forumu Başkanı Lars-Åke Söderlund'a ve tüm FIP Teknoloji Forumu üyelerine destekleri, katkıları ve geri bildirimleri için şükranlarını sunar.

1 Yönetici özeti

“Eczacılık İçin Yapay Zekâ Araç Kiti”, eczacıların yapay zekâ teknolojilerini uygulamalarına entegre etmelerine yardımcı olmak için tasarlanmış bir kaynaktır. Uluslararası Eczacılık Federasyonu (FIP) tarafından geliştirilen bu araç kiti, hızla gelişen yapay zekâ alanı ile eczacıların pratik ihtiyaçları arasındaki boşluğu doldurmayı amaçlamaktadır.

Yapay zekânın eczacılıktaki önemi ve kullanım amacı: Yapay zekâ, büyük miktarlardaki tıbbi verilerin analiz edilmesine olanak tanıyarak, klinik karar alma sürecine yardımcı olarak, hasta tedavilerini kişiye özel hale getirerek, hastalık salgınlarını tahmin ederek ve operasyonel iş akışlarını optimize ederek sağlık hizmetlerinde devrim yaratmaktadır. FIP Kalkınma Hedefi 20 (Dijital Sağlık) ile yakından uyumlu şekilde yapay zekâ; dijital yetkinliğe sahip eczane iş gücü oluşturulmasına yardımcı olarak klinik bakım, hastalık taraması, sağlık sistemleri yönetimi ve ilaç araştırmalarını iyileştirir. Bununla birlikte eczacılar, veri gizliliği, siber güvenlik tehditleri, muhtemel algoritma yanlılığı ve etik kaygılar gibi kritik sorunlarla karşı karşıyadır.

FIP’in bağlılığı ve girişimleri: FIP, yapay zekâ teknolojilerinin etkin kullanımı konusunda eczacılara rehberlik etmeye ve onları desteklemeye kararlıdır. FIP 2023 yılında, yapay zekâ ile ilgili ihtiyaçları belirlemek ve sektörler arası iş birliğini güçlendirmek için bir yapay zekâ çalışma grubu kurmuştur. Bu grup, bilgi boşluklarını kapatmayı ve eczacılar ve eczacılık alanındaki bilim insanları arasında yapay zekâ teknolojilerinin anlaşılması ve yaygınlaştırılmasını amaçlamaktadır.

Bu araç setinin oluşturulma amacı: Bu araç seti eczacılar için üst düzey bir kılavuz sunarak yapay zekâ uygulama hususlarına, pratik uygulamalara ve ilham verici yeniliklere genel bir bakış sağlamaktadır. Eleştirel düşünme veya mesleki muhakemelerini zayıflatmadan daha güvenli, daha etkili ve kişiselleştirilmiş hasta bakımı sunmaları için eczacıları güçlendirmeyi amaçlamaktadır.

Yapay zekâ ve FIP Gelişim Hedefleri: Araç seti, FIP Kalkınma Hedefleri’nin hayata geçirilmesini desteklemekte ve eğitim ve sürekli mesleki gelişim (SMG), dijital okuryazarlık ve eczacılık uygulamalarında inovasyon konularına odaklanarak BM Sürdürülebilir Kalkınma Hedefleri ile uyum sağlamaktadır. Spesifik hedefler arasında dijital yetkinlik, yapay zekâ eğitiminin mesleki eğitime entegre edilmesi ve dijital sağlık işgücü politikaları konusunda stratejik rehberlik sağlanması için eğitim kaynaklarının geliştirilmesi yer almaktadır.

Karşılaşılabilecek zorluklar ve göz önünde bulundurulması gereken hususlar: Yapay zekânın eczacılığa etkili bir şekilde entegre edilmesi, eczacıların yapay zekânın becerilerini ve sınırlamalarını anlamasını ve belirli zorluklara göre uyarlanmış uygun araçları seçmesini gerektirmektedir. Veri kalitesinin sağlanması, mevzuata uygunluk, etik çerçeveler ve altyapı yatırımı göz önünde bulundurulması gereken temel hususlardan bazılarıdır. Ayrıca, mevcut sağlık eşitsizliklerinin ve adaletsizliklerin daha da derinleşmesini önlemek için adil erişimin gözetilmesi hayati önem taşımaktadır.

Sonuç: Bu araç seti eczacıların yapay zekânın karmaşıklığı içinde yollarını bulmalarını, potansiyelinden yararlanmalarını ve sınırlamalarını açıkça anlamalarını sağlayan kapsamlı bir kaynak olarak hizmet etmeyi amaçlamaktadır. FIP, inovasyonu, iş birliğini ve proaktif yaklaşımı teşvik ederek yapay zekânın eczacılık uygulamalarındaki rolünü geliştirmeyi ve nihai olarak hasta bakımında ve küresel sağlık sonuçlarında iyileştirmeler sağlamayı amaçlamaktadır.

2 Önsöz

2.1 Bu araç setinin yazılma amacı

Yapay zekâ öğrenme, muhakeme, problem çözme ve örüntü tanıma gibi tipik olarak insan zekâsı gerektiren görevleri yerine getirebilen sistemler oluşturmaya adanmış bir bilgisayar bilimi dalıdır. Yapay zekâ uygulamaları büyük hacimli tıbbi verileri analiz etmek, klinik karar verme sürecine yardımcı olmak, tedavi planlarını kişiselleştirmek, hastalık salgınlarını tahmin etmek ve sağlık hizmetleri ortamlarındaki operasyonel iş akışlarını optimize etmek için giderek daha fazla kullanılmaktadır.

Dijital sağlık FIP için bir önceliktir ve eczacılara sağlık hizmeti sunumunu, eczacılık uygulamalarını ve farmasötik araştırmaları desteklemek için dijital gelişmelerin en iyi nasıl kullanılacağı konusunda rehberlik eder. Yapay zekâ dijital sağlığın klinik bakım, hastalık taraması ve takibi, sağlık sistemleri yönetimini optimize etme ve ileri düzey farmasötik araştırma ve geliştirmeyi kolaylaştırmada verimliliği artırmak için büyük bir potansiyele sahip olan alanıdır. Dahası yapay zekâ hastaların sağlık hizmeti ihtiyaçlarını aktif olarak yönetmelerini sağlayarak küresel olarak sağlık hizmetine erişimde eşitliği yaygınlaştırma potansiyeline sahiptir. Bununla birlikte, eczacılık sektörüne giren çok sayıda yapay zekâ dijital aracına rağmen, yapay zekâ kendi zorluklarını barındırmakta ve veri gizliliği endişeleri, güvenlik riskleri, kodlanmış yanlılıklar ve siber güvenlik tehditleri hususlarında riskler oluşturmaktadır.

FIP, optimum sağlık sonuçlarına ulaşmak için yapay zekânın etkin bir şekilde kullanılması konusunda küresel olarak eczacılarla iş birliği yapma, onlara rehberlik etme ve onları eğitme sorumluluğunu kabul etmektedir. FIP, eczacıların bu teknolojileri güvenle benimseyebilecekleri bir ortamı desteklemeye kararlıdır. 2023 yılında bu hedefleri göz önünde bulundurarak FIP, FIP Teknoloji Danışma Grubu'nun bir alt grubu olarak, FIP takipçilerinin yapay zekâ ile ilgili ihtiyaçlarını haritalamak, pratik kaynaklar oluşturmak ve rehberlik sağlamakla görevli bir yapay zekâ çalışma grubu kurmuştur.

Yapay Zekâ Çalışma Grubu tarafından geliştirilen bu araç seti, hızla gelişen yapay zekâ alanı ile eczacıların pratik ve günlük ihtiyaçları arasındaki boşluğu doldurmayı amaçlamaktadır. Yapay zekânın uygulanması için dikkate alınması gereken hususlara genel bir bakış sağlayarak eczacıların yapay zekâ uygulamalarının karmaşıklıklarında yönlerini bulabilmeleri için üst düzey bir rehber görevi görmektedir. FIP, pratik uygulamalardan örnekler sergilemeyi, kendi kitlesinde yeniliğe ilham vermeyi, eczacıların gelişen yapay zekâ ortamında yönlerini bulmaları ve yapay zekânın kısıtlılıklarını anlarken faydalarından yararlanacak donanımda olmalarını sağlamayı amaçlamaktadır.

Sonuç olarak bu araç seti, eczacılar ve ekiplerinin yapay zekâyı, uzmanlıklarını tamamlayacak şekilde güvenle uygulamalarına entegre etmelerini ve eczacıların eleştirel düşünme ile mesleki yargı becerilerini korurken daha güvenli, etkili, verimli ve kişiselleştirilmiş hasta bakımı sunmalarını sağlamayı amaçlamaktadır.

2.2 Yapay Zekâ ve FIP gelişim hedefleri

Eylül 2020'de yayımlanan FIP Gelişim Hedefleri eczacılık mesleğinin dönüşümünü küresel olarak 2030 yılına kadar yönlendirmeyi amaçlamaktadır (daha fazla bilgi için <https://developmentgoals.fip.org/> adresini ziyaret edin). FIP Kalkınma Hedefleri, daha geniş bir küresel girişim olan BM Sürdürülebilir Kalkınma Hedefleri ile uyumlu şekilde, eczacılık uygulamalarını, eğitimi ve farmasötik bilimleri geliştirmeye özellikle odaklanmaktadır. 'Tek FIP' Gelişim Hedefleri, eczacılık mesleği için dönüştürücü bir çerçevede ortak noktaların ve sektörler arası iş birliğinin belirlenmesine olanak tanımaktadır.

Dijital Sağlık ile ilgili FIP Kalkınma Hedefi (Kalkınma Hedefi 20) üç unsur etrafında yapılandırılmıştır: eğitim ve işgücü, uygulama ve bilim.

Eğitim ve işgücü: 'Eczane iş gücünde dijital dönüşümü mümkün kılan unsurlar ve dijital okuryazarlığa sahip bir eczane iş gücünün gelişimini kolaylaştıracak etkili süreçler.'

Yapay zekâ bağlamında, bu araç seti aşağıdaki Gelişim Hedefi mekanizmalarını desteklemeyi amaçlamaktadır:

- Dijital okuryazarlığa sahip bir işgücü için kurslar ve eğitimler geliştirmek (FIP Gelişim Hedefleri 1 & 2).
- Dijital sağlık ve okuryazarlık yetkinliklerinin FIP ileri düzey ve uzmanlık çerçevelerine dahil edilmesi (FIP Gelişim Hedefleri 4 & 5).
- Dijital sağlık okuryazarlığını güçlendirmek için multidisipliner öğrenme araçları sağlamak (FIP Gelişim Hedefi 8).
- Eczacıların ve eczacılık alanındaki bilim insanlarının eğitim ve öğretiminde yapay zekânın kullanımını ve yorumlanmasını desteklemek. Teknolojideki gelişmelerle birlikte güncel uygulamaları temin etmek için sürekli eğitim ve gelişim fırsatları yaratmak (FIP Gelişim Hedefi 9).
- İstihdam da dahil olmak üzere, yapay zekânın dijital sağlık işgücü geliştirme politikalarına dahil edilmesi konusunda rehberlik sağlamak (FIP Gelişim Hedefi 13).

Uygulama: 'Dijital okuryazarlık, teknoloji ve dijital olanakların kullanımı, erişim ve eşitliği genişletmek için duyarlı dijital hizmetlerin yapılandırılması yoluyla kaliteli dijital sağlık ve farmasötik bakım hizmetleri geliştirmek ve sunmak için mevcut sistemler ve yapılar'.

Yapay zekâ bağlamında bu araç seti aşağıdaki Gelişim Hedefi mekanizmalarını desteklemeyi amaçlamaktadır:

- En ileri düzeyde hizmet sunumunu ve klinik karar alma süreçlerini destekleyen dijital sağlık araçları ve yapay zekâ odaklı teknolojiler hakkında bilgi sağlamak (FIP Gelişim Hedefi 20).
- Mülkiyet, etik, mahremiyet, operasyonel etkiler ve bilgi kalitesi hususlarında dijital okuryazarlık ve yönetimi irdelemek. Sağlık verileri yönetimini ve hasta sonuçları için hesap verebilirliği destekleyecek ve geliştirecek politikalar için rehberlik sağlamak (FIP Gelişim Hedefi 20).
- Farmasötik bakıma eşit erişimi artıran yapay zekâ odaklı dijital sağlık girişimlerini yaygınlaştırmak (FIP Gelişim Hedefi 20).

Bilim: 'Sağlık hizmetlerinde dijital teknolojinin uygulanması ve yenilikçi tıbbi ürünlerin geliştirilmesi.'

Yapay zekâ bağlamında bu araç seti aşağıdaki Gelişim Hedefi mekanizmalarını desteklemeyi amaçlamaktadır:

- Bir veri bilimi çözümü olarak yapay zekâ entegrasyonunu kolaylaştırarak, eczacıların yenilikçi sağlık teknolojileri aracılığıyla gelişmiş hasta bakımı sunmalarını sağlamak (FIP Gelişim Hedefi 20).

3 Arka plan

Bu yapay zekâ araç setinin gerekliliğini ortaya koyan temel sorun, yapay zekanın endüstri, hastane ve toplum eczanesi ortamlarında günlük eczacılık uygulamalarına, eczacıların iş süreçlerini optimize etmek, hasta bakımını iyileştirmek, multidisipliner etkileşimi teşvik etmek ve eczacılara yapay zekâ araçlarının verimli kullanımı konusunda eğitim vermek amacıyla entegrasyonudur.

Makine öğrenimi ve yapay zekâ teknolojilerinin entegrasyonu, eczacılar da dahil olmak üzere sağlık çalışanlarının rollerini ve sorumluluklarını yeniden şekillendirmektedir. Yapay zekâ, ilaç yönetimi (hem lojistik hem de farmasötik bağlamda), hasta danışmanlığı, ilaç etkileşimi kontrolleri, kişiselleştirilmiş tıp, farmasötik araştırma ve çok daha fazlası gibi geniş bir görev yelpazesinde eczacıların becerilerini artırma potansiyeline sahiptir.

Üretken yapay zekâdaki son gelişmeler yapay zekânın benimsenmesini daha da hızlandırmış, düşünceli ve sorumlu bir yaklaşım ihtiyacını ortaya çıkarmıştır. Üretken yapay zekâ, farmasötik bakım için önemli bir umut vaat ederken diğer yandan etkili ve etik entegrasyon için ele alınması gereken önemli sınırlamalar ve zorlukları da beraberinde getirmektedir.

Yapay zekâ sistemleri tarafından kullanılan ve üretilen verilerin kalitesi ve bütünlüğü önemli bir endişe kaynağıdır. Yapay zekâ çıktıları yalnızca öğrendikleri veriler kadar güvenilir olduğundan eğitim veri kümelerindeki yanlışlıklar, önyargılar veya tutarsızlıklar yanlış sonuçlara veya tahminlere yol açabilir. Bu, özellikle hasta güvenliği ve ilaçların etkinliğinin söz konusu olduğu farmasötik bakımda kritik öneme sahiptir.

Üretken yapay zekâ sistemlerinin yanlış, anlamsız veya uydurma çıktılar ürettiği “yapay zekâ halüsinasyonu” bir diğer kritik konudur. Bu durum, farmasötik bakım gibi kritik uygulamalarda önemli zorluklara yol açmaktadır.¹ Örneğin yapay zekâ eğitim verilerindeki sınırlamalar, örüntü tanıma hataları veya çıkarım hatalarından kaynaklanan, kulağa makul gelen ancak yanlış tıbbi tavsiyeler veya tedavi önerileri üretebilir. Bu halüsinasyonların ele alınması, eğitim veri kalitesinin iyileştirilmesini, doğrulama adımlarının uygulanmasını ve doğruluk ve güvenilirliği korumak için insan denetiminin sağlanmasını içerir. Farmasötik bakım sağlayıcıları yapay zekâ araçlarını sisteme giderek daha fazla entegre ettikçe yapay zekâ halüsinasyonlarını anlamak ve azaltmak, güvenli ve etkili hasta bakımı sağlamak için çok önemlidir.

Teknik önlemlere ve insan denetimine ek olarak, hukuki hususlar da yapay zekânın başarılı bir şekilde entegrasyonunda merkezi bir rol oynamaktadır. Farmasötik bakım kapsamlı şekilde düzenlenmiş hukuki temele sahiptir ve yapay zekâ uygulamaları da ilaç geliştirme, klinik deneyler ve hasta mahremiyeti ile ilgili karmaşık yasal şartları sağlamalıdır. Hem yerel hem de uluslararası düzeyde bu düzenlemelere uyum sağlamak, hasta güvenliğini ve uygulanmakta olan yeni teknolojilere güveni sağlamak için gereklidir.

Ayrıca, farmasötik bakımda yapay zekânın uygulanması altyapı, eğitim ve yönetim açısından önemli yatırımlar gerektirmektedir. Sağlık hizmeti sağlayıcıları ve kuruluşları, bu gelişmiş teknolojileri etkin bir şekilde kullanabilmek için güçlü bilgi işletim sistemlerine ve personel eğitimine yatırım yapmaya hazır olmalıdır.

Etik hususlar da kritik bir rol oynamaktadır. Yapay zekâ kullanımı hasta gizliliği ve güvenliği, rıza ve tedavi önerilerinde yanlılıktan kaçınma ile ilgili etik standartlarla uyumlu olmalıdır. Yapay zekâ sistemlerinin şeffaf olmasını ve işleyişlerinin düzenleyici kurumlar ve sağlık uzmanları tarafından anlaşılabilir olmasını sağlamak, kabul edilmeleri ve güvenilirlikleri için çok önemlidir.

Son olarak, yapay zekâ bakımın kişiselleştirilmesini ve verimliliğini artırabilirken, dikkatli bir şekilde yönetilmezse mevcut sağlık eşitsizliklerini derinleştirme riski barındırmaktadır. Sağlık eşitsizliklerinin daha da derinleşmesinin önüne geçmek için farmasötik bakımda yapay zekâ teknolojisinin faydalarına eşit erişimin sağlanması gereklidir.

Bu araç seti bu konuları daha ayrıntılı olarak ele alacak ve eczacılık uygulamalarında yapay zekâ araçlarından yararlanmanın yollarını araştırırken göz önünde bulundurulması gereken hususların bir listesini sunacaktır.

3.1 Yapay zekânın temelleri

Yapay zekâ modelleri iki geniş sınıflandırmaya ayrılır: öngörücü ve üretken. Öngörücü modeller verilerdeki kalıpları öğrenir ve bu kalıpları daha önce hiç görmediği yeni verilere -muhtemel sonuçları tahmin etmek için- uygular. Öngörücü yapay zekâ, tablet tanıma, ilaç tasarımı, kanser teşhisi ve nüfus

sağlığı analizi dahil olmak üzere eczacılıkta ve genel olarak sağlık hizmetlerinde çeşitli kullanım alanları bulmuştur. Bazı öngörücü model türleri şunları içerir:

1. Sınıflandırma ve etiketleme
2. Risk tahmini ve öngörü
3. Öneri

Üretken modeller yeni veriler üretmek için verilerdeki kalıpları öğrenir. Üretken yapay zekâda çıktılar, metinden elektronik tablolara, görüntülerden videolara kadar değişebilir. ChatGPT üretken yapay zekânın popüler bir örneğidir. Üretken yapay zekâ önemli bir potansiyele sahip ve halihazırda birçok sektörde kullanılıyor olsa da etik ve sorumlu bir şekilde kullanılmasını sağlamak için ele alınması gereken önemli sınırlamalar ve riskleri de beraberinde getirmektedir.

3.1.1 Yapay zekânın öğrenme biçimleri

Hem öngörücü hem de üretken modeller makine öğrenimi tarafından yönlendirilir. Sinir ağlarını kullanan makine öğrenimi modelleri 'derin öğrenme' olarak kabul edilir. Derin öğrenme modelleri doğası gereği "kara kutu" olarak işlev görür, bu da modelin sonuçlara ulaşma şeklinin yapay zekânın kendisi veya insan kullanıcısı tarafından açıklanamayacağı anlamına gelmektedir. Bu durum düzenleyici kurumlar için kavramsal engeller oluşturabilir.

Belirli bir model veya araç tarafından uygulanan öğrenme yöntemi, o aracın işlevselliğini ve faydasını etkileyecektir. Tüm öğrenme stilleri her kullanım amacı için uygun değildir. Bu öğrenme yöntemleri şunlardır:

1. Denetimli
2. Denetimsiz
3. Pekiştirmeli

Denetimli öğrenme, modelin önceden etiketlenmiş veriler üzerinden eğitilmesini içerir. Etiketlenmiş veriler makineye sunulan verilerin bir tanımının yapıldığı, örneğin "KEDİ" olarak etiketlenmiş bir kedi görüntüsünün sağlandığı anlamına gelir. Bu, makinenin sonuçları tahmin ederken veya etiketlenmemiş yeni veri girdilerine dayalı olarak yeni veriler üretirken kullandığı bir kaynak kütüphanesi oluşturur. Denetimli öğrenme sağlık alanında bir hastalığın varlığını tahmin etmek, risk skorları oluşturmak veya bir hastalığın prognozunu öngörmek amacıyla modeller geliştirmek için kullanılmıştır.² Denetimli öğrenmeyi kullanan bir öngörücü yapay zekâ motoru ilaç keşfine de uygulanmış ve uygulama Halicin olarak bilinen yeni, geniş spektrumlu bir antibiyotik keşfiyle sonuçlanmıştır.³

Yeterli sayıda etiketli veriye sahip olmak sağlık hizmetlerinde denetimli öğrenmeyle ilgili sık görülen bir zorluktur. Etiketli veri kümeleri oluşturmak zaman almaktadır. Tıbbi görüntüleme (yani röntgen veya manyetik rezonans görüntülemeleri) gibi çıktıları etiketlemek genellikle daha kolaydır. Ancak, kronik bir hastalığın şiddetlenmesi gibi tıbbi bir olayı veya sonucu etiketlemek alan uzmanlığı ve belirleyici kararlar vermeyi gerektirdiğinden daha zordur. Herkes verileri aynı şekilde yorumlamayabilir ve bu da modelin nihai çıktısını etkiler. Gizlilik ve güvenlik konuları da etiketli veri kümelerinin oluşturulması ve paylaşılmasında bir diğer sorundur.

Denetimsiz öğrenme, bir modelin etiketlenmemiş veriler üzerinden eğitilmesini içermektedir. Derin öğrenme makinenin verilerdeki örüntüleri, ilişkileri veya benzerlikleri tanımlaması için kullanılır. Genellikle bu örüntüler aynı verileri inceleyen insanlar tarafından tanımlanamaz. Her hasta için mevcut olan birçok değişken veya veri noktasındaki benzerliklere dayanarak, hastaları farklı fenotip gruplarına ayıran bir küme analizi yapmak bu duruma örnek gösterilebilir. Bununla birlikte, bu öğrenme yöntemini öngörücü bir model oluşturmak için kullanırken dikkatli olunmalıdır; denetimsiz öğrenme modelleri, kabul edilebilir çıktının ne olacağı konusunda eğitilmedikleri için saçma veya yanlış çıktılara eğilimli olabilirler.


Metinler, kimyasal yapılar, DNA dizileri, resimler ve videolar dahil olmak üzere kalıpları tanımlama ve bunları kullanarak tahminler yürütmeye denetimli ve denetimsiz öğrenme çok güçlüdür. Ancak, bir dizi olayın veya kararın sırasının sonuç için önemli olduğu dinamik ortamlarda tahmin gücü azalmaktadır. Bu tür amaçlar için pekiştirmeli öğrenme daha uygulanabilir bir seçenek olabilmektedir.

Pekiştirmeli öğrenme, modeli doğru kararlar verdiği için “ödüllendirir”. Model, ödülün gecikmesi olasılığını artıran bir sonraki eylemi veya eylemler serisini tahmin etmeyi öğrenir.⁴ Ödül sürecinin modele programlanması gerekir, böylece model verdiği her karardan sonra ya olumlu ya da olumsuz bir ödül alır. Bu yöntem, modelin kararların doğru yönde alınıp alınmadığını bilmesini sağlar. Go ve satranç oyunlarını oynamak için AlphaZero olarak bilinen bir yapay zekâ modeli kullanılarak iki önemli deney gerçekleştirilmiştir.⁵ Model, pekiştirmeli öğrenmeyi kullanarak hangi hamle serisinin oyunu kazanmanın ödülüyle sonuçlanma olasılığının en yüksek olduğunu öğrenmiştir. Model, satranç oyunu tarihinde insanların aklına hiç gelmemiş yeni stratejiler geliştirmiştir. Bu yazının yazıldığı sırada hiçbir insan AlphaZero’yu yenememiştir. Pekiştirmeli öğrenme kavramı, hastaneden taburculuk süresine kadar meydana gelebilecek mortaliteyi veya hedef A1C değerine ulaşma amacıyla yapılan ilaç düzenlemesi gibi uzak gelecekteki bir ödül için birden fazla kararın verildiği tıp alanına uygulanabilir.

3.1.2 Yapay zekâ araç türleri

Yapay zekâ geniş bir teknoloji kategorisidir; ancak tüm yapay zekâ araçları veya uygulamaları üç ana bileşene ayrılabilir: Şekil 1’de belirtildiği gibi girdi, algoritma/model ve çıktı.

Şekil 1: Yapay zekâ model bileşenleri



Bu bileşenlerin her birini anlamak, yapay zekâ teknolojisinin farklı durumlarda nasıl kullanılabileceğini anlamak açısından önemlidir. Tablo 1, modelin kullandığı girdi verilerine bağlı olarak mevcut farklı yapay zekâ araçlarını özetlemektedir.

Tablo 1: Girdiye dayalı yapay zekâ araç türleri

Model girdisi	Yapay zekâ araç tanımı
Görüntü	Bunlar, görüntüleri girdi verileri olarak kullanan modellerdir. Buna göğüs röntgenleri veya bilgisayarlı tomografi gibi tıbbi görüntülerin incelenmesine yönelik teşhis araçları da dahildir. Etiketlenmemiş hapları ve tabletleri %85 doğrulukla tanımlayabilen bir hap tanımlama modeli bu modele örnek olarak gösterilebilir. ⁶
Metin	Girdi olarak metin kullanan modeller, doğal konuşma veya metinle etkileşime girebilmektedir. Bu bir sohbet robotu (ChatGPT gibi) şeklinde olabileceği gibi bir belge sınıflandırma modeli de olabilir.
Ses	Bu tür modeller ham sesi girdi olarak alır. Örnekler arasında dikte programları, akıllı hoparlörler veya cihazlar ya da mobil cihazlardaki akıllı asistanlar yer almaktadır. Ayrıca, teşhis koymak veya hastanın stres seviyesini ölçmek için ses işaretlerini kullanan yapay zekâ destekli klinik uygulamalar da vardır.
Tablosal	Tablosal veriler, bir elektronik tabloda düzenlenebilecek veya saklanabilecek her türlü veriyi içerir. Bu tür verileri kullanan modeller risk tahmin algoritmalarını içerir.
Çok modlu	Çok modlu bir model, modelin birden fazla girdi türünü kabul edebileceğini gösterir. Örneğin bir sohbet robotu metne de, yüklenen bir görüntüye de yanıt verebilir.

3.2 Yapay zekâ performansının değerlendirilmesi

Makine öğrenimi modellerinin performansının değerlendirilmesi, bu modellerin teknik dayanıklılığının ve doğruluğunun test edilmesinin yanı sıra şeffaflığın ve hesap verebilirliğin sağlanması ve kullanıcılar arasında güven oluşturulması için de çok önemlidir.

Performans ölçütleri bir modelin çeşitli senaryolarda ne kadar iyi performans gösterdiğini anlamada, güçlü ve zayıf yönlerini belirlemede ve model iyileştirmeleri ve uygulamaları hakkında bilinçli kararlar vermede geliştiricilere ve paydaşlara yol gösteren temel araçlar olarak kullanılmaktadır.

Bir sonraki bölümde yapay zekâ modellerini değerlendirmek ve şeffaflık ve anlaşılabilirlik hakkında yorum yapabilmenin önünü açmak amacıyla kullanılan yaygın metodolojiler ve araçlar özetlenmektedir.

3.2.1 Performans neden ölçülür?

Yapay zekâ modellerinin performansının ölçülmesi yalnızca teknik bir gereklilik değil, aynı zamanda şeffaflık, güven ve hesap verebilirliğin sağlanması için temel bir uygulamadır. Şeffaflık, modellerin nasıl çalıştığı ve performansları hakkında açık ve erişilebilir bilgi sunmayı içerir. Bu sayede kullanıcılar, karar destek sistemi olarak kullanacakları yapay zekânın içgörülerini anlayabilir ve güvenebilirler. Hesap verebilirlik, geliştiricilerin ve kuruluşların modellerinin performansından, etik sonuçlarından ve hastalar üzerindeki muhtemel etkisinden sorumlu olmalarını sağlar. Model kartları bunu başarmaya yardımcı olabilecek önemli bir araçtır.

3.2.2 Nasıl şeffaf ve hesap verebilir olunur ve güven inşa edilir?

Model kartları, bir makine öğrenimi modeli hakkında temel ayrıntıları içeren kapsamlı ve yapılandırılmış kılavuzlar olarak işlev görür.⁷ Modelin özellikleri, performansı, kısıtlılıkları ve kullanım amaçları hakkında bilgi vermek için standart bir çerçeve sağlar ve farklı modeller arasında karşılaştırmalı bir analiz yapılmasına olanak tanır. Google Research, makine öğreniminde şeffaflığı artırmak için Model Kartı Araç Kitini (MKAT) geliştirmiştir. MKAT, geliştiricilerin bir modelin kökeni, kullanım amacı ve etik hususlar hakkında temel bilgiler sağlayan model kartları oluşturmalarına yardımcı olur. MKAT'yi kullanarak geliştiriciler modellerini kolayca belgeleyebilir ve sorumlu bir şekilde kullanılmalarını sağlayabilir.⁸ Bir model kartına bakmak, bir modelin belirli bir görev veya kullanım için uygun olup olmadığının belirlenmesine yardımcı olmalıdır. Tipik bir model kartı, Tablo 2'de açıklandığı gibi çeşitli bileşenler içerebilir.

Tablo 2: Model kartının bileşenleri

Bileşen	Detay
Tanım	Varsa, üretim zamanı ve model versiyonu da dahil olmak üzere modelin kısa açıklaması ve özgün kimliği.
Amaç, kullanıcılar ve bağlam	Modelin amacının aşağıdaki sorularla net ifadesi: modelin hangi amaçla geliştirildiği; modelin hangi amaçlar için uygun olmadığı; modelden yararlanabilecek potansiyel kullanıcılar; modelin uygulanması veya uygulanmaması gereken bağlamlar; ve farklı amaçlar, kullanıcılar ve bağlamlar için genelleştirmenin muhtemel sınırlamaları.
Nasıl kullanılır	Kullanıcıların modeli etkili bir şekilde uygulayabilmelerini sağlamak için basit bir dille yazılmış anlaşılabilir kılavuzlar. Mümkünse, kullanıcının anlamasını kolaylaştırmak için akış tabloları ve şemalar da sağlanmalıdır.
Performans ölçütleri	Ölçütler model türüne ve amacına göre (ör. üretim, tahmin, sınıflandırma, vs.) değişir. Performans ölçütlerine kullanıldığı bağlamda ne anlama geldiklerine dair bir yorumun eklenmesi önemlidir. Özellikle modelin sonuçları hakkındaki belirsizliklerin olduğu durumlarda kullanıcının anlamasını kolaylaştırmak için mümkün mertebe örnekler verilmelidir. Uygulanabilir durumlarda modelin farklı nüfus alt gruplarındaki performansı, muhtemel yanlılıklar hakkında bilgi sağlamak için listelenmelidir.
Eğitim verileri	Eğitim verilerinde şeffaflık esastır. Kaynak, kalite, uygulanan ön işleme adımları ve fazla veya eksik temsil edilebilecek belirli gruplar veya alt gruplar da buna dahildir. Veri setinin anlaşılması, kullanıcıların modelin uygulanabilirliğini ve muhtemel önyargıları ölçmesine yardımcı olur

Etik	Yapay zekâda etik hususlar çok önemlidir. Bu, önyargı, adalet ve gizliliğin ele alınmasını içerir. Modellerin önyargıları sürdürmemesini ve kullanıcı verilerinin sorumlu bir şekilde ele alınmasını sağlamak, etik standartların korunmasında kritik öneme sahiptir.
Belirsizlik	Her modelin sınırlamaları ve belirsizlikleri vardır. Bunların belgelenmesi, kullanıcı beklentilerinin yönetilmesine yardımcı olur ve onları potansiyel riskler ve modelin düşük performans gösterebileceği alanlar hakkında bilgilendirir.
Yazar, kod, lisans ve mülkiyet	Kodun yazarının, kullanılabilirliğinin, lisans koşullarının ve mülkiyet haklarının açıkça belirtilmesi şeffaflığı artırır ve toplumun katkıları ile iyileştirmelerini teşvik eder.
İletişim ve kaynaklar	İletişim bilgilerinin ve ek kaynakların sağlanması, kullanıcıların modeli anlamasını ve etkili bir şekilde kullanmasını destekler. Ayrıca geri bildirim ve iyileştirme için kanallar açar.

Bir modelin ne kadar iyi performans gösterdiğinin değerlendirilmesinde kullanılan belirli ölçütleri daha iyi anlamak için Tablo 3 verilmiştir. Tablo 3, bir model kartında görülebilecek veya model geliştiricileri tarafından sağlanabilecek ölçütlere genel bir bakış sunmaktadır.

Tablo 3: Model ölçütleri, kullanımları ve örnekleri

Model türü	Performans değerlendirme ölçütleri	Tanım	Örnek
ÖNGÖRÜCÜ YAPAY ZEKÂ			
Sınıflandırma	Doğruluk Kesinlik Geri çağırma F1 Puanı Duyarlılık Özgüllük ROC-AUC Karışıklık Matrisi <i>Bu ölçütlerin tanımları için bir sonraki bölüme bakınız.</i>	Girdileri etiketleyerek veya kategorize ederek sınıflandıran modelleri değerlendirir. Ölçütler tahminlerin doğruluğunu değerlendirir.	Örnek: Bir model, hasta kayıtlarını reçete yenileme veya randevu planlama talepleri gibi kategorilere ayırır. Performans ölçütlerinin uygulanması: Yüksek düzeyde doğruluk ve hassasiyet, hataları en aza indirerek doğru kategorilendirmenin bir göstergesi olur. Yüksek düzeyde geri çağırma, önemli kategorilerin gözden kaçırılmamasını sağlar. Karışıklık Matrisi (bkz. Tablo 4) ile birlikte yüksek Alıcı İşletim Karakteristik Eğrisi Altındaki Alan (ROC-AUC), kategoriler arasında etkili bir ayırım yapıldığını göstermektedir.
Regresyon	Ortalama Karesel Hata (OKH) R^2 Ortalama Mutlak Hata (OMH) Ortalama Karesel Hatanın Kökü (OKHK)	Sürekli değerleri (verileri) tahmin eden modelleri değerlendirir. Ölçütler tahmin edilen ve gerçek değerler arasındaki sapmayı ölçer.	Örnek: Bireyselleştirilmiş tıp için doz tahmin modeli. Performans matrislerinin uygulanması: OKH ve OKHK değerlerinin düşük olması, tahmini ve gerçek dozlar arasında yakın bir uyum olduğunu gösterir ve gerekenden düşük veya yüksek doz hesaplama riskini azaltır. Yüksek R^2 , modelin hasta özellikleri ile gerekli doz arasındaki ilişkiyi etkili bir şekilde yakaladığını göstermektedir.

Zaman dizileri	Ortalama Mutlak Yüzde Hata (OMYH) Ortalama Karesel Hatanın Kökü (OKHK)	Geçmiş verilere dayanarak gelecekteki değer tahminlerinde doğruluk ve hatayı değerlendirir.	Örnek: Gelecekteki ilaç talebini tahmin eden bir öngörü modeli. Performans ölçütlerinin uygulanması: Düşük OMYH ve OKHK değerleri, doğru tahminlere işaret ederek optimum envanter seviyelerinin korunmasına yardımcı olur.
ÜRETKEN YAPAY ZEKÂ			
Üretim	Büyük dil modelleri (Large Language Models, LLM): Karmaşıklık (Perplexity, PPL) ⁹ İki Dilli Değerlendirme Çalışması (Bilingual Evaluation Understudy, BLEU) ^{10, 11} Genel Dil Anlama Değerlendirmesi (General Language Understanding Evaluation, GLUE) ¹² Gisting Değerlendirmesi için Geri Çağırma Odaklı Araştırma (Recall-Oriented Understudy for Gisting Evaluation, ROUGE) ¹³	Üretilmiş içerik ve referans içerik arasındaki benzerliği ölçer.	Örnek: Hastaların bireysel ihtiyaçlarına göre uyarlanmış ilaç danışmanlığı senaryoları oluşturan bir model. Performans ölçütlerinin uygulanması: Yüksek BLEU puanı, senaryoların klinik eczacılar tarafından hazırlanan yüksek kaliteli referanslarla yakından eşleştiğini gösterir ve hastaların doğru ve anlaşılır tavsiyeler almasını sağlar.

3.3 Sınıflandırma modellerinde kullanılan performans ölçütleri

Bütün performans ölçütlerinin kapsamlı bir incelemesini sunmak bu araç setinin kapsamı dışındadır. Bu nedenle bu bölüm, en sık karşılaşılabilecek performans ölçütlerinden bazıları hakkında ayrıntılı bilgi vermektedir. Kesinlik, geri çağırma, F1 puanı, özgüllük ve duyarlılık, bir modelin sınıflandırma yoluyla tahmin etme etkinliğini değerlendirmek için sıklıkla kullanılan ölçütlerdir.¹⁴ ROC-AUC eğrisi ve Karışıklık Matrisi, bir modelin tahmin yaparken farklı sınıfları ayırt etme kapasitesini anlamak için yararlı araçlardır. Aşağıdaki içerik bu matrislerin teorik temellerini açıklamaktadır.

- **Kesinlik**, pozitif öngörü değeri olarak da bilinir, model tarafından yapılan pozitif tahminlerin doğruluğunu ölçer. Özellikle yanlış pozitiflerin maliyetinin yüksek olduğu senaryolarda kullanışlıdır. Kesinlik şu soruyu yanıtlar: “Pozitif olarak tahmin edilen tüm örneklerden kaç tanesi gerçekten pozitifdir?”

Kesinlik formülü şu şekilde verilir:

$$\text{Kesinlik} = \frac{DP}{DP + YP}$$

DP (Doğru Pozitifler) pozitif olarak doğru tahmin edilen örneklerdir.

YP (Yanlış Pozitifler) yanlışlıkla pozitif olarak tahmin edilen örneklerdir.

- **Geri çağırma**, aynı zamanda duyarlılık veya doğru pozitif oranı olarak da bilinir, modelin ilgili tüm örnekleri belirleme becerisini ölçer. Pozitif bir örneği kaçırmamanın maliyetli olduğu durumlarda çok önemlidir. Geri çağırma şu soruyu yanıtlar: “Tüm doğru pozitif örneklerden kaç tanesini model doğru bir şekilde tanımladı?”

Geri çağırma formülü şöyledir:

$$\text{Duyarlılık (Geri çağırma)} = \frac{DP}{DP + YN}$$

DP (Doğru Pozitifler) pozitif olarak doğru tahmin edilen örneklerdir.

YN (Yanlış Negatifler) yanlışlıkla negatif olarak tahmin edilen örneklerdir.

- **F1 Puanı** kesinlik ve geri çağırmanın ortalamasıdır ve iki ölçüt arasında bir denge sağlar. Özellikle eşit olmayan bir sınıf dağılımı olduğunda (yani sınıflardan biri nadir olduğunda) veya hem yanlış pozitiflerin hem de yanlış negatiflerin en aza indirilmesi gerektiğinde kullanışlıdır.

F1 puanı formülü şudur:

$$\text{F1 Puanı} = 2 \times \frac{\text{Kesinlik} \times \text{Geri Çağırma}}{\text{Kesinlik} + \text{Geri Çağırma}}$$

- **Özgüllük**, gerçek negatif oranı olarak da bilinir, modelin negatif örnekleri doğru tanımlama becerisini ölçer. Yanlış negatiflerin maliyetinin yüksek olduğu durumlarda önemlidir. Özgüllük şu soruyu yanıtlar: “Tüm gerçek negatif örneklerden kaç tanesini model doğru şekilde tanımladı?”

Özgüllük formülü şudur:

$$\text{Özgüllük} = \frac{DN}{DN + YP}$$

- **ROC AUC Eğrisi** bir sınıflandırıcının performansının grafiksel bir gösterimidir. Alıcı İşletim Karakteristiği (Receiver Operating Characteristic, ROC) eğrisi, çeşitli eşik ayarlarında doğru pozitif oranını (duyarlılık) yanlış pozitif oranına (1-özgüllük) karşı çizer. Eğri Altındaki Alan (Area Under the Curve, AUC), modelin tüm eşiklerdeki performansının toplu bir ölçüsünü sağlar. AUC değeri 1 olan bir model mükemmeldir, AUC değeri 0,5 olan bir model ise ayırt etme kabiliyetinin olmadığına işaret eder.
- **Karışıklık Matrisi** gerçek değerlerin bilindiği bir dizi test verisi üzerinde bir sınıflandırma modelinin performansını tanımlamak için kullanılan bir tablodur. Bir algoritmanın performansının görselleştirilmesini sağlar. Matris $N \times N$ 'dir, burada N sınıf sayısıdır. Sınıflandırıcı tarafından yapılan hata türleri hakkında bilgi sağlar.

Tablo 4'teki karışıklık matrisi aşağıdaki yapıya sahiptir:

Tablo 4: Karışıklık matrisi

	Tahmini pozitif	Tahmini negatif
Gerçek pozitif	Doğru pozitif (DP)	Yanlış negatif (YN)
Gerçek negatif	Yanlış pozitif (YP)	Doğru negatif (DN)

Yapay zekâ modellerinin performansını yapılandırılmış ve şeffaf yöntemlerle değerlendirmek, güven ve hesap verebilirliği güçlendirmek için çok önemlidir. Şeffaflığa, etik hususlara öncelik vererek ve son kullanıcıları değerlendirme sürecine dahil ederek, yapay zekâ geliştiricileri yalnızca teknik olarak sağlam değil, aynı zamanda güvenilir ve kullanıcı ihtiyaçlarıyla uyumlu modeller oluşturabilir.

4 Etik olarak göz önünde bulundurulması gereken hususlar

4.1 Güvenilebilir bir yapay zekâ yaratmak

Makine öğrenimi ve yapay zekâ alanındaki son gelişmeler, sağlık hizmetleri de dahil olmak üzere birçok sektörü dönüştürmüştür. Bu teknolojiler muazzam potansiyel faydalar sunarken aynı zamanda sorumlu ve adil kullanımı sağlamak için ele alınması gereken etik ikilemler de ortaya çıkarmaktadır. Avrupa Birliği tarafından 2019 yılında görevlendirilen Yapay Zekâ Üst Düzey Uzman Grubu'nun (HLEG on AI) "Güvenilir Yapay Zekâ için Etik Kılavuzları", yapay zekânın etik ve güvenilir bir şekilde geliştirilmesini ve uygulanmasını sağlamak için kapsamlı bir rehberlik sunmaktadır.¹⁵ Kılavuzlara göre güvenilir bir yapay zekâ aşağıdaki özelliklere haiz olmalıdır:

1. **Hukuka uygun** – yürürlükteki bütün kanun ve düzenlemelere uygun olmalıdır;
2. **Etik** – ahlaki ilke ve değerlere uygun olmalıdır; ve
3. **Dayanıklı** – teknik bir perspektiften bakarken aynı zamanda sosyal çevresini de dikkate almalıdır.

Kılavuzlar, yapay zekâ sistemlerinin güvenilir olarak kabul edilmesi için karşılaması gereken yedi temel şartı ana hatlarıyla belirtmektedir (bkz. Tablo 5).

Tablo 5: Güvenilir yapay zekânın yedi temel şartı

Temel şart	Detaylar
1. İnsan temsilciliği ve gözetimi	Yapay zekâ sistemleri, insan özerkliğini ve karar verme sürecini desteklemeli ve yapay zekâ sonuçlarından nihai olarak insanlar sorumlu olmalıdır.
2. Teknik dayanıklılık ve güvenlik	İstenmeyen zararlardan kaçınmak için yapay zekâ sistemleri her zaman emniyetli, güvenilir ve dayanıklı olmalıdır
3. Özel hayatın gizliliği ve veri yönetimi	Yapay zekâ sistemleri özel hayatın gizliliğine saygı göstermeli, kişisel verilerin korunmasını ve veri koruma düzenlemelerine uyulmasını temin etmelidir.
4. Şeffaflık	Yapay zekâ sistemleri tarafından gerçekleştirilen süreçler ve alınan kararlar, kullanıcılar tarafından açıklanabilir, anlaşılabilir ve erişilebilir olmalıdır.
5. Çeşitlilik, ayrımcılık yapmama ve hakkaniyet	Yapay zekâ sistemleri kapsayıcı ve adil olmalı, çeşitli özelliklere dayalı önyargı ve ayrımcılıktan kaçınmalıdır.
6. Toplumsal ve çevresel refah	Yapay zekânın geliştirilmesi ve yaygınlaştırılması, sürdürülebilirliği ve toplumsal refahı teşvik ederek topluma ve çevreye fayda sağlamalıdır.
7. Hesap verebilirlik	Yapay zekâ sistemlerine dahil olan paydaşlar (geliştiriciler, dağıtıcılar, vb.) yapay zekâ ile ilgili kararları ve eylemlerinde hesap verebilir olmalıdır.

4.2 Yapay zekânın sağlık hizmetinde kullanılması durumunda göz önünde bulundurulması gereken etik hususlar

Sağlık hizmetlerinde makine öğrenimi ve yapay zekâ kullanımının etik sonuçları karmaşık ve çok boyutludur. Bu teknolojiler hasta güvenliğini artırmak gibi dönüştürücü bir potansiyel sunarken, klinik karar verme sürecini etkileyerek hasta bakımında önyargı gibi etik sorunları da beraberinde getirmektedir.¹⁶

Algoritmaların olasılıksal olduğunu ve asla yanılmaz olmadığını vurgulayan “kesin olmayan kanıtlar” önemli bir etik kaygıdır.¹⁷ Örneğin, bir akıllı saat kalp hızı ölçümlerindeki yanlışlıklar nedeniyle doğru olmayan bir düzensiz kalp atışı teşhisi sunabilir. Bu tür hatalar, algoritmaların bireysel hasta özellikleri yerine genel nüfus normlarına göre -belirli cilt tonları gibi- kalibre edildiğinde ortaya çıkabilir. Bu durum, yapay zekâ geliştirmedeki önyargıların hasta bakımında eşitsizliklere nasıl yol açabileceğini göstermektedir.

Ayrıca, sağlık hizmetlerinde sorumlu yapay zekâ kullanımı, özellikle eczacılık uygulamalarında hasta güvenliği, mahremiyet, şeffaflık, adalet, bilgilendirilmiş onam ve iş gücü etkilerini de ele almalıdır.¹⁸ Yapay zekânın etik entegrasyonu, tıp etiğinin dört temel ilkesinin¹⁹ dikkatle değerlendirilmesini gerektirir:

- Özerklik – hastanın kendi kaderini tayin hakkı;
- Yararlılık - ‘iyilik yapma’ sorumluluğu;
- Zarar vermeme - ‘zarar vermeme’ sorumluluğu; ve
- Adalet – herkese eşit ve adil davranmak.

Bu ahlaki zorlukları proaktif bir şekilde ele alarak, etik standartları koruyarak ve hasta refahını sağlayarak sağlık hizmetlerinde yapay zekânın faydalarını en üst düzeye çıkarabiliriz.

Etik yapay zekâyı tanımlamanın zorluğu: Yapay zekânın etik ilkelere bağlı kalması gerektiğine dair yaygın kabullere rağmen, “etik yapay zekâ”nın pratik tanımına ilişkin tartışmalar devam etmektedir. Belirli etik gereksinimler, teknik standartlar ve uygulama için en iyi uygulamalar konusundaki belirsizlikler de buna dahildir. Dünya Sağlık Örgütü (DSÖ), sağlık hizmetlerinde yapay zekâ kullanımında özerkliğin korunması; insan refahının yaygınlaştırılması; şeffaflık, açıklanabilirlik ve anlaşılabilirliğin sağlanması; sorumluluk ve hesap verebilirliğin teşvik edilmesi; kapsayıcılık ve eşitliğin sağlanması ve duyarlı gelişimin teşvik edilmesi gibi temel etik ilkeleri belirlemiştir.²⁰ Benzer şekilde, yapay zekâ etik kılavuzlarının küresel görünümüne ilişkin bir derleme, birbiri ile yakınsak beş etik ilke belirlemiştir: şeffaflık, adalet ve hakkaniyet, kötü niyetli olmama, sorumluluk ve mahremiyet.²¹ Aşağıdaki bölüm, bu etik ilkeleri dikkate alarak sağlık hizmetlerinde yapay zekânın sorumlu bir şekilde uygulanması için dikkate alınması gereken temel etik konuları detaylandırmaktadır.

4.2.1 Etik hususlar

4.2.1.1 Özel hayatın gizliliği ve güvenlik

- Makine öğrenimi ve yapay zekânın kullanımı, büyük hacimlerde hassas hasta verilerinin işlenmesini gerektirmekte, bu da gizlilik ihlalleri ve veri güvenliği ile ilgili endişeleri artırmaktadır.
- Hasta gizliliğini korumak için verilerin anonimleştirilmesi ve şifrelenmesine yönelik yöntemler sağlam olmalıdır.
- Araştırmacılar ve son kullanıcılar, kullanılan verilerle ilişkili gizlilik ve mahremiyet risklerini dikkate almalıdır.
- Gizlilik ve güvenlik önlemleri, hem makineye aktarılan eğitim verilerini hem de makine öğrenimi bulgularından elde edilen çıktıları ele almalıdır.

4.2.1.2 Şeffaflık

- Makine öğrenimi modelleri karmaşık ve yorumlanması zor olabilir. Araştırmacılar ve yapay zekâ geliştiricileri, modellerinin şeffaflığını ve açıklanabilirliğini göz önünde bulundurmalıdır.²²
- Makine öğrenimi ve yapay zekâ algoritmaları genellikle “kara kutular” olarak çalışır ve algoritmaların karar verme süreçlerini anlamayı zorlaştırır.
- Makine öğreniminin şeffaf olmasını sağlamak, altta yatan süreçlerin tekrarlanabilirliğini ve daha iyi anlaşılmasını sağlar.
- Algoritmik çıktılarda şeffaflığın sağlanması ve algoritmik hatalar veya yanlışlıklar için hesap verebilirliğin tesis edilmesi kritik etik hususlardır.²²

4.2.1.3 Hesap verebilirlik

- Hesap verebilirlik makine öğrenimi süreci boyunca çok önemlidir. Modeller yalnızca amaçları doğrultusunda kullanılmalı ve paydaşlar sorumluluklarının farkında olmalıdır.
- Araştırmacılar, yapay zekâ geliştiricileri ve klinisyenler gibi son kullanıcılar, istenmeyen sonuçları veya makine öğrenimi çıktılarının kötüye kullanımını önlemek için hesap verebilirliği sağlamalıdır.

4.2.1.4 Yanlılık ve hakkaniyet

- Yanlı veri kümeleri kullanılarak eğitilen makine öğrenimi modelleri, sağlık hizmetlerinde mevcut yanlışlıkları devam ettirerek veya güçlendirerek adaletsiz uygulamalara yol açabilir.
- Yanlılık, model mimarisinin kendisi ve eğitim sürecinde alınan kararlar yoluyla da ortaya çıkabilir.²³
- Etik makine öğrenimi uygulamaları, sağlık hizmeti sunumunda adaleti ve eşitliği sağlamak için veri ve algoritmalarındaki yanlılığı belirleme ve azaltma stratejileri gerektirir.

4.2.1.5 Bilgilendirilmiş onam

- Hastalar, yapay zekâ destekli tanı veya tedavi önerilerinin etkilerini tam olarak anlayamayabilir.²⁴
- Yapay zekâ destekli müdahaleler için bilgilendirilmiş onamın sağlanması, hastaların yapay zekânın sağlık hizmetinde karar verme sürecindeki rolü ve kısıtlılıkları konusunda eğitilmesini de içermektedir.

4.2.1.6 Sağlık uzmanları üzerindeki etkisi

- Makine öğrenimi ve yapay zekâ teknolojileri sağlık çalışanlarının rollerini ve sorumluluklarını değiştirerek potansiyel olarak işgücünün yerinden edilmesine veya vasıfsızlaşmasına yol açabilir.
- Etik kılavuzlar, mesleki uygulamalarda ve görev tanımlarında teknoloji kaynaklı değişikliklerin etik sonuçlarını ele almalıdır.

4.2.2 Sağlık hizmetlerinde yapay zekânın etik bir şekilde kullanılması için etki azaltma stratejisi

Sağlık hizmetlerinde yapay zekâ kullanımına ilişkin etik sorunları etkili bir şekilde ele almak için, sağlık ve teknoloji sektörlerinden paydaşlar işbirliği yaparak kapsamlı kılavuzlar ve düzenlemeler geliştirmelidir. Tablo 6, etik karar verme sürecini iyileştirmeye ve eczacıları ve diğer paydaşları aktif olarak sürece dahil etmeye odaklanarak, yapay zekânın etik entegrasyonu için temel risk azaltma stratejileri ve eylemlerini özetlemektedir.

Tablo 6: Yapay zekânın etik bir şekilde kullanılmasına yönelik stratejiler

Strateji	Eylem	
Açık etik kılavuzların oluşturulması	Önyargı, şeffaflık, hasta mahremiyeti ve çevresel hususlar gibi temel konuları ele alarak, sağlık hizmetlerinde yapay zekâ teknolojilerinin geliştirilmesi ve uygulanmasını yöneten etik kılavuzlar geliştirmek ve bunları yaymak.	
Eğitim programlarına etiğin entegre edilmesi	- Yapay zekâ da dahil olmak üzere dijital sağlık alanında uzmanlaşmış sağlık çalışanları için etik eğitiminin eğitim müfredatına dahil edilmesi ²⁴ - Yapay zekânın hem klinik uygulamalarda hem de bilimde etik kullanımına odaklanan sürekli mesleki gelişim fırsatları sağlamak.	
Güçlü denetim ve doğrulama mekanizmalarının uygulanması	- Yanlılıkları tespit etmek ve ele almak ve hakkaniyeti sağlamak için yapay zekâ algoritmalarının düzenli olarak denetlenmesi ve doğrulanması amacıyla mekanizmalar geliştirmek. - Yapay zekâ sistemlerinin bağımsız değerlendirmelerini sağlamak için üçüncü taraf denetçileri görevlendirmek.	
Hastalar ve toplumla iletişim	- Yapay zekânın sağlık hizmetlerinde karar verme süreçlerindeki rolü ve etkisi hakkındaki tartışmalara hastaları ve toplumu aktif olarak dahil etmek. - Verilerinin nasıl kullanıldığı konusunda hastalara şeffaf olmak ve açık rıza almak.	
Güçlendirilmiş bir etik karar verme çerçevesinin kullanılması	Kapsamlı paydaş katılımı	Yapay zekâ ve makine öğrenimi geliştiricileri, sağlık bakımı ile ilgili karar vericiler, araştırma etik kurulları, düzenleyici kurumlar ve diğerleri dahil olmak üzere klinik makine öğrenimi teknolojilerinin adil ve sorumlu kullanımını yaygınlaştırmaya kendini adanmış çeşitli paydaşları sürece dahil etmek.
	Etik normların entegrasyonu	Yapay zekâ ve makine öğrenimi araçlarının etik tasarımını biyomedikal etik, klinik araştırma etiği ve sosyal adalet ilkelerini kapsayacak şekilde sağlık hizmetleri ortamındaki yerleşik normlarla uyumlu hale getirmek.
	Yapay zekâ ve makine öğrenimi yaşam döngüsü boyunca bütünsel etik rehberlik	Sağlık hizmetlerinde yapay zekâ ve makine öğrenimi entegrasyonunun her aşamasında etik hususları vurgulayarak, bu ilkelerin makine öğrenimi uygulamalarında adaleti teşvik etme üzerindeki etkilerini yansıtmak.

Son kullanıcı olarak eczacıların güçlendirilmesi	Model şeffaflığının değerlendirilmesi	- Eczacıları yapay zekâ önerilerini yorumlama ve altta yatan karar verme süreçlerini anlama konusunda eğitmek.²⁵ - Yapay zekâ sistemlerinin tasarımlarını, eğitim verilerini ve karar gerekçelerini detaylandıran kapsamlı belgelere sahip olduğunu teyit etmek (bkz. Model Performansının Değerlendirilmesi bölümü).
	Yanlılığın belirlenmesi ve azaltılması	- Yanlılık emareleri için yapay zekâ çıktılarının düzenli olarak kontrol edilmesi ve herhangi bir tutarsızlığın ilgili makamlara veya geliştiricilere bildirilmesi. - Yanlılığı bildirmek için geri bildirim mekanizmalarını kullanmak ve modelin adaletini iyileştirmek için geliştiricilerle iş birliği yapmak.
	Adalet ve eşitliğin sağlanması	- Yapay zekânın savunmasız nüfusları orantısız bir şekilde etkilememesini temin ederek, tüm hasta demografilerinde eşitlikçi yapay zekâ kullanımı için savunuculuk faaliyetleri yürütmek.²³ - Hasta bakım kalitesini artırdıklarından emin olmak için özellikle karmaşık vakalarda yapay zekâ önerilerini teyit etmek.
	Devamlı eğitim ve öğretim	- Yapay zekâ gelişmeleri ve etik hususlar konusunda güncel kalmak için sürekli mesleki gelişime katılmak. - Yapay zekânın günlük eczacılık uygulamaları üzerindeki etik sonuçları üzerine kafa yormak ve bu hususları hasta bakımına entegre etmek. - Kullanılan modelden kaynaklanan kasıtsız zararları önleme sorumluluğuna sahip son kullanıcılar arasında bir hesap verebilirlik kültürü oluşturmak.
	Hasta ve toplum katılımı	- Yapay zekânın bakımlarındaki rolü hakkında hastalarla açık şekilde iletişim kurmak ve yapay zekâ odaklı önerilerin arkasındaki mantığı açıklamak. - Halkın endişelerini ele alan ve yapay zekâ teknolojilerine olan güveni artıran sosyal diyalogu yaygınlaştırmak.
	Proaktif risk yönetimi	- Yapay zekâ hataları, halüsinasyonlar veya istenmeyen sonuçlar gibi potansiyel etik ikilemleri öngörmek ve ele almak için stratejiler geliştirmek. - En iyi uygulamaları paylaşmak ve eczacılıkta yapay zekâ kullanımını geliştirmek için diğer sağlık çalışanlarıyla iş birliği yapmak.

Eczacılar, Tablo 6'da belirtilen etki azaltma stratejilerini uygulayarak yapay zekânın sağlık hizmetlerinde etik ve sorumlu bir şekilde kullanılmasını sağlamada önemli bir rol oynayabilirler. Doğru araçlar ve bilgi ile donatılan eczacılar risklerin azaltılmasına ve hasta bakımında yapay zekâdan en üst düzeyde yararlanılmasına yardımcı olabilir, daha şeffaf, adil ve hasta merkezli bir yaklaşıma katkıda bulunabilir ve yapay zekâ uygulamalarında güven ve hesap verebilirliği güçlendirebilirler.

5 ISO düzenlemeleri ve uyumluluk

Yapay zekâ teknolojisini eczacılık uygulamalarına entegre ederken, eczacıları hasta veri gizliliği, kalite ve algoritma tekrarlanabilirliği ve bilgi işlem güvenliği gibi önemli alanlarda uyumu sağlamak için çeşitli kritik alanlarda etkili bir şekilde yönlendirmek esastır. Eczacılık uygulamalarında kullanılan yapay zekâ sistemleri, ülkeye veya bölgeye göre değişen belirli sağlık ve bilişim teknolojileri ile ilgili hukuki düzenlemelere uygun olmalıdır.

5.1 Genel yapay zekâ mevzuatı

Yapay zekâ düzenlemeleri, her bölgenin inovasyonu denetimle dengeleme konusundaki kendine has yaklaşımının bir sonucu olarak farklı küresel bölgelerde önemli farklılıklar gösterir. Bölgeler genelinde, yapay zekânın inovasyonu engellemeden etik ve sorumlu bir şekilde kullanılmasını sağlayan çerçeveler oluşturma yönünde açık bir eğilim vardır. Avrupa, güçlü düzenleyici çerçevelere vurgu yaparken, Amerika merkezi olmayan ve sektöre özgü bir yaklaşımla karakterizedir. Asya-Pasifik bölgesinde karma bir strateji görülmektedir. Tablo 7, her bölgedeki düzenleme manzarasını ayrıntılı olarak açıklamaktadır.

Tablo 7: Bölgesel yapay zekâ düzenlemeleri

Bölge	Düzenleme
Avrupa	Avrupa Birliği (AB), yapay zekâ uygulamalarını risk seviyelerine göre sınıflandıran ve biyometrik gözetim ve bilinçaltı manipülasyonu gibi yüksek riskli kullanımlar için katı şartlar getiren kapsamlı “Yapay Zekâ Yasası” ile bu hususta proaktif bir tutum sergilemektedir. Bu mevzuat, yapay zekâ kullanımında şeffaflık, hesap verebilirlik ve hakkaniyeti vurgulayarak, yapay zekâyı Avrupa’nın insan gözetimi ve özel hayatın gizliliği değerleriyle uyumlu hale getirmeyi amaçlamaktadır. Birleşik Krallık’ın stratejisi, yapay zekâ gelişimini teşvik etmek ve inovasyonu desteklemek için aşırı kısıtlayıcı düzenlemelerden kaçınmayı vurgularken güvenlik ve şeffaflık ilkelerine odaklanmaktadır. ²⁶
Amerika	ABD’de henüz birleşik bir yapay zekâ mevzuatı bulunmamaktadır. Bunun yerine yapay zekâ uygulamalarını yönetmek için çeşitli yönergeler ve çerçeveler kullanılmakta ve genellikle sektöre özgü önlemlere odaklanılmaktadır. Kanada, güvenliği ve sorumlu yapay zekâ uygulamalarını teşvik eden Yapay Zekâ ve Veri Yasası’nı (AI and Data Act, AIDA) çıkarmış, Brezilya ise yüksek riskli yapay zekâ sistemlerini düzenlemek ve yapay zekâ kullanımında şeffaflık ve hesap verebilirliği sağlamak için kapsamlı yapay zekâ mevzuatını aktif olarak geliştirmektedir.
Asya-Pasifik	Çin, algoritmik öneriler ve derin sentez teknolojileri için özel yasalarla yapay zekâ düzenlemesinde önemli adımlar atarak yapay zekâ yenilikleri üzerinde kontrolü korurken içerik bütünlüğünü ve hakkaniyeti sağlamayı amaçlamaktadır. Japonya, kapsamlı bir ulusal mevzuattan ziyade bağlayıcı olmayan yönergelere ve sektöre özgü kurallara daha fazla güvenmektedir ve inovasyonu desteklemek için esnek bir yaklaşımı teşvik etmektedir. Hindistan ve diğer Asya ülkeleri şu anda yaklaşımlarını formüle etmektedir ve yakında daha kesin düzenlemelere doğru bir geçiş sinyali vermektedir.
Afrika	Çeşitli ülkeler, yapay zekâ teknolojisinin faydalarını yönetmek ve kullanmak için ulusal stratejiler ve politikalar geliştirmenin farklı aşamalarında. Mevzuat ve yönergeler hala çeşitli veri koruma yasalarına büyük ölçüde bağımlıdır. Güney Afrika, Mauritius, Mısır ve Kenya gibi ülkeler, yapay zekânın hem fırsatlarını hem de etik zorluklarını ele alan yapay zekâ yönergelerini taslak haline getirmek ve uygulamak için öncü çabalarda bulunmaktadır. Bu girişimler genellikle AB’nin Yapay Zekâ Yasası gibi küresel standartları yerel bağlamlara uyarlamayı, etik değerleri ve toplumsal normları korurken inovasyonu teşvik etme fikrinden yanadır. Afrika Birliği de bir rol oynamakta ve daha birleşik bir kıta stratejisine doğru ilerlemeyi önermektedir. Bununla birlikte, teknolojik altyapının sınırlı olması ve yerel yapay zekâ uzmanlığına ihtiyaç duyulması bu hususta karşılaşılan önemli engellerdir. Bu bölgesel farklılıklar, küresel olarak güvenli ve faydalı bir yapay zekânın gelişimini teşvik ederken, küresel standartların yerel ihtiyaçları karşılayabilmesini sağlayarak yapay zekâ yönetimini uyumlu hale getirmek için uluslararası iş birliği ve diyalogun önemini vurgulamaktadır.

5.2 Verilerin korunması ve sağlık hizmetinde özel hayatın gizliliği

Hasta verilerinin gizliliğini, bütünlüğünü ve erişilebilirliğini korumak çok önemlidir. Yapay zekâ sistemleri büyük miktardaki hassas verileri işler ve bu verilerin yetkisiz erişime, ihlallere ve sızıntılara karşı korunmasını sağlamak temel bir etik ve yasal gerekliliktir. Etkili veri koruma önlemleri, sağlık hizmeti sunumunun temel taşı olan hasta güveninin korunmasına yardımcı olur. Verileri korumadaki başarısızlık mali kayıplara, hasta güveninin zedelenmesine ve belirli yargı bölgelerinde cezai kovuşturma dahil olmak üzere ciddi hukuki cezalara yol açabilir.

ABD’de, HIPAA (Sağlık Sigortası Uyumluluk ve Sorumluluk Yasası), eczanelerin hasta bilgilerini korumak için uyması gereken birincil hukuki çerçevedir.²⁷ Eczaneler, kişisel sağlık bilgilerinin uygunsuz şekilde imha edilmesi nedeniyle CVS Pharmacy ve Rite Aid gibi kuruluşlara uygulanana benzer cezalardan kaçınmak için YZ teknolojileri de dahil olmak üzere hasta verilerini işleyen tüm sistemlerin HIPAA standartlarını karşıladığından emin olmalıdır. ABD’deki eczaneler, HIPAA gerekliliklerini karşılamak için depolanan veriler için sağlam şifreleme ve güvenli iletim protokolleri benimsemelidir.

Avrupa’da, Genel Veri Koruma Tüzüğü (GDPR) kapsamında benzer korumalar sağlanmaktadır.²⁸ GDPR kapsamında, eczacılar hasta verilerinin gizliliğini sıkı erişim kontrolleriyle sağlamalı ve yetkisiz erişimi takip etmelidir. Eczane sahipleri, veri saklama politikalarını düzenli olarak gözden geçirmeli ve personelin hasta gizliliğinin önemini anladığından emin olmalıdır.

Afrika Birliği, üye devletler arasında mevzuatın uyumunu kolaylaştırmak için Siber Güvenlik ve Kişisel Verilerin Korunması Sözleşmesi’ni kabul etmiştir. Bu sözleşme bağlayıcı değildir ancak bir kılavuz görevi görmektedir. Kıta genelinde 55 ülkeden 36’sı veri koruma yasalarını yürürlüğe koymuştur. Güney Afrika, her türlü kişisel bilgi işlenmesinde geçerli olan Kişisel Bilgilerin Korunması Yasası’nı (POPIA) yürürlüğe koymuştur. Yasa, kişisel verilerin yeterli şekilde korunamaması durumunda cezai sonuçlar doğurur. Yasa, veri sahiplerinin ve kullanıcıların haklarını ve sorumluluklarını, gerekli güvenlik önlemlerini ve bilgilerin ülke dışına nasıl gönderilebileceğini belirler ve bu da herhangi bir denizaşırı veri işleme üzerinde etkiye sahiptir. Benzer şekilde Mısır, Kenya, Nijerya ve Zimbabve de kendi Veri Koruma Yasalarını uygulamaya koymuştur.

5.2.1 İnsan merkezli yapay zekâ

Eczacılar, insan merkezli bir yaklaşımı sürdürmeli, yapay zekânın, sağlık hizmetlerinde kritik olan kişisel etkileşimi ve bakımı desteklemesini ancak bunun yerini almamasını sağlamalıdır. Sağlık hizmetlerine erişimde eşitlik bir diğer hayati husustur; eczacılar, yapay zekâ araçlarının belirli popülasyonları diğerlerine göre kayırarak eşitsizlikleri istemeden daha da kötüleştirmemesi konusunda dikkatli olmalıdır. Yapay zekâ gelişmeleri ve etik kurallar konusunda sürekli eğitim verilmesi büyük önem taşımaktadır ve eczacıları bilinçli karar vermeleri ve teknolojinin sorumlu kullanımını savunmaları için güçlendirir. Eczacılar, yenilikçiliği etik dikkat ile dengeleyerek, mesleğin temel değerleri olan güven, gizlilik ve eşitliği korurken hasta bakımını iyileştirmek için yapay zekâdan yararlanabilir.

5.2.2 Algoritmaların yeniden üretilebilirliği ve klinik olarak doğrulanması

Yapay zekâ uygulamalarıyla ilgili düzenlemeler ülkeden ülkeye değişmektedir. Otonom yapay zekâ uygulamaları, çıktıyı doğrulamak veya kontrol etmek için bir insan olmadan çalışan uygulamalardır. Bazı ülkeler otonom yapay zekâ için sağlam klinik doğrulama gerektirir. Yani yapay zekâ uygulamasının amaçlanan kullanımı için güvenli ve etkili olduğu test edilmeli ve kanıtlanmalıdır. Bu tür uygulamalar için düzenlemeler genellikle tıbbi cihaz düzenlemeleri içinde yer alır. Otonom olmayan uygulamalar bu kadar katı bir düzenleme gerektiremeyebilir.

Avrupa’da, Tıbbi Cihaz Yönetmeliği (Medical Device Regulation, MDR), yapay zekâ teknolojisini sağlık hizmetlerine entegre eden eczacılar için hayati öneme sahiptir. Çünkü MDR, yapay zekâ odaklı araçlar da dahil olmak üzere tıbbi cihazların güvenliğini, etkinliğini ve kalitesini temin eden kapsamlı bir çerçeve sağlar.²⁹ MDR kapsamında, tıbbi cihaz olarak sınıflandırılan yapay zekâ teknolojileri, risk yönetimi, klinik değerlendirme ve pazar sonrası gözetim için katı şartları karşılamalıdır. Eczacılar için, hasta bakımında kullanılan yapay zekâ araçlarının güvenilir, emniyetli ve Avrupa standartlarına uygun olduğundan emin olmak için MDR’ye uyum esastır. Bu yönetmelik aynı zamanda şeffaflık ve izlenebilirliği vurgulayarak yapay zekâ sistemlerinin yalnızca etkili değil aynı zamanda açıklanabilir ve hesap verebilir olmasını sağlayarak hasta güvenliğini korumakta ve yapay zekâ destekli sağlık çözümlerine olan güveni artırmaktadır.

ABD’de sağlık hizmetlerindeki yapay zekâ teknolojisi, esas olarak Dijital Sağlık ve Tıbbi Cihaz Olarak Yazılım (Software as a Medical Device, SaMD) çerçeveleri kapsamında Gıda ve İlaç Dairesi (Food and Drug Administration, FDA) tarafından düzenlenmektedir.^{29, 30} FDA, yapay zekâ odaklı araçları amaçlanan kullanımlarına, hastalar için potansiyel risklerine ve tıbbi cihaz kriterlerini karşılayıp karşılamadıklarına göre değerlendirir. Tıbbi cihaz olarak sınıflandırılan yapay zekâ teknolojileri için FDA, güvenliği, etkinliği ve kaliteyi sağlamak amacıyla pazar öncesi onay veya izin dahil olmak üzere titiz bir inceleme sürecini şart koşturmaktadır. Kurum ayrıca piyasaya sürülme sonrası gözetimi ve yapay zekâ sistemlerinin sürekli öğrenme

ve uyarlanma ihtiyacını vurgulayarak, zaman içinde performans standartlarını koruduklarından emin olur. Bu hukuki yaklaşım, inovasyonu hasta güvenliğiyle dengelemeyi ve yapay zekânın sağlık hizmetlerine entegrasyonu için sağlam bir çerçeve sağlamayı amaçlamaktadır. Ancak, yalnızca klinik karar desteği olarak kullanılan yapay zekâ uygulamalarının kullanımdan önce test edilmesi ve güvenli ve etkili olduğu kanıtlanması genellikle gerekli değildir, çünkü güvenlik için son karar verici olan insan faktörü vardır. Bu yapay zekâ uygulamaları, yine de güvenliği teşvik edecek ve riski en aza indirecek şekilde sorumlu bir şekilde kullanılmalı, etkinlik ve güvenliği sağlamak için sorumluluk yükünün klinik son kullanıcıya düştüğü anlaşılmalıdır. Doğrulama gerektiren ve gerektirmeyen yapay zekâ uygulamaları arasında ayırım yapabilmek önemlidir.

Asya'da sağlık hizmetlerinde yapay zekâ teknolojisini düzenlenmesi ülkeler arası farklılık göstermektedir, ancak Japonya, Çin ve Güney Kore gibi birkaç önde gelen ülke, tıbbi bağlamlarda yapay zekâ kullanımını yönetmek için kapsamlı çerçeveler geliştirmektedir. Japonya'da, İlaç ve Tıbbi Cihaz Ajansı (Pharmaceuticals and Medical Devices Agency, PMDA), FDA'nın yaklaşımına benzer şekilde güvenlik, etkinlik ve pazara sonrası izleme konularına odaklanarak tıbbi cihaz olarak nitelendirilen yapay zekâ teknolojilerini denetlemektedir. Çin, Ulusal Tıbbi Ürün Kurumu (National Medical Products Administration, NMPA) aracılığıyla, veri güvenliği ve hasta gizliliğine güçlü bir vurgu yaparak yapay zekâ tıbbi cihazları için titiz testler ve onay gerektiren katı düzenlemeler uygulamıştır. Güney Kore'de Gıda ve İlaç Güvenliği Bakanlığı (Ministry of Food and Drug Safety, MFDS), sağlık hizmetlerinde yapay zekâyı düzenlemekte, onay süreçlerini zorunlu kılmakta ve pazardaki yapay zekâ araçlarının sürekli izlenmesini sağlamaktadır. Genel olarak, Asya'daki düzenleyici çerçeveler hala gelişmekte olsa da, sağlık hizmetlerinde yapay zekânın bölge genelinde güvenli, etkili ve emniyetli olmasını sağlamak için uluslararası standartlara uyum sağlama yönünde açık bir eğilim vardır.

5.2.3 Birlikte çalışabilirlik standartları

Eczane uygulamalarındaki yapay zekâ sistemlerinin Sağlık Seviyesi 7 (Health Level 7, HL7) veya Hızlı Sağlık Hizmetleri Birlikte Çalışabilirlik Kaynağı (Fast Health Interoperability Resource, FHIR) gibi birlikte çalışabilirlik standartlarına uymasını sağlamak, farklı sağlık sistemleri arasında kesintisiz veri alışverişi için çok önemlidir.³¹ Bu uyumluluk, birleşik ve verimli bir sağlık bilgi ortamının korunmasına yardımcı olur.

5.2.4 Siber güvenlik önlemleri

Eczaneler tehditlere karşı korunmak için güçlü siber güvenlik önlemleri uygulamalıdır. Bu önlemler, hasta bilgilerini korumak için şifreleme, güvenli erişim kontrolleri ve düzenli güvenlik denetimlerini içerir. Güvenliği artırmak için iki faktörlü kimlik doğrulama ve sağlam parola politikaları gibi stratejiler önerilir. Sağlık verilerini korumak için ISO27001 ve ISO27799 dikkate alınması gereken temel sertifikalardır.

5.2.5 Erişilebilirlik ve kapsayıcılık

Yapay zekâ araçları engelliler de dahil olmak üzere tüm kullanıcılar için erişilebilir olmalı ve sağlık hizmetlerindeki eşitsizlikleri önlemek için tasarlanmalıdır. Bu, yapay zekâ sistemlerinin çeşitli hasta grupları tarafından kullanılabilmesini ve hiçbir grubun yanlışlıkla dışarıda bırakılmamasını sağlamak için dikkatli tasarım ve yerleştirme uygulamaları gerektirir.

Yapay zekâ, algoritmaların çeşitli ve temsili veri kümeleri üzerinde eğitilmesini sağlayarak kapsayıcılığı vurgulamak üzere tasarlanabilir; bu da önyargıları azaltmaya ve sistemin farklı demografik gruplardaki performansını iyileştirmeye yardımcı olur. Örneğin, sağlık hizmetlerinde yapay zekâ, farklı genetik geçmişleri, sosyoekonomik faktörleri ve cinsiyet farklılıklarını dikkate alacak şekilde geliştirilebilir ve böylece tanı araçlarının ve tedavi önerilerinin tüm popülasyonlar için etkili olması sağlanabilir. Ek olarak, yapay zekâ arayüzleri, sınırlı hareket kabiliyeti veya görme engeli olanlar için ses tanıma gibi özellikler içerecek şekilde engelli bireyler için de erişilebilir olacak şekilde tasarlanabilir. Çok dilli destek ve kültürel açıdan hassas içerik sağlanması, yapay zekânın daha geniş bir kullanıcı yelpazesine hizmet edecek şekilde uyarlanmasının diğer yollarıdır ve bu sayede teknolojinin geçmişleri veya yetenekleri ne olursa olsun herkes için faydalı olması sağlanır.

Eczacılar bu alanları ele alarak, uzmanlıklarını tamamlamak için yapay zekâyı etkin bir şekilde kullanabilir ve daha güvenli, daha etkili ve kişiselleştirilmiş hasta bakımı sağlayabilirler. Her bölgenin kendine özgü düzenleyici gereksinimleri olabilir ve sürekli eğitim ve hukuki güncellemelerin takip edilmesi yoluyla bilgi sahibi olmak, uyumun sürdürülmesi ve eczacılık uygulamalarında yapay zekânın etkili kullanımının sağlanması için önemlidir.

5.2.6 Gelecekte göz önünde bulundurulması gereken hususlar

Farmasötik bakım sağlayıcıları yapay zekâ teknolojisini giderek daha fazla kullandıkça, yapay zekâ düzenlemesinde akılda tutulması gereken gelecek eğilimler arasında, özellikle hasta verileriyle ilgili daha katı veri gizliliği yasaları ve yapay zekâ hesap verebilirliği ve şeffaflığı konusunda daha net yönergelerin oluşturulması yer almaktadır. Düzenleyiciler, yeni ilaçlar için onay sürecine benzer şekilde, sağlık hizmetlerinde yapay zekâ sistemlerinin güvenlik ve etkinliği sağlamak için titiz testler ve doğrulama süreçlerinden geçmesini gerektirebilir. Ayrıca gelecekte, hasta bakımında güveni korumak ve etik standartları sürdürmek için yapay zekâ odaklı kararların sağlık hizmeti sağlayıcıları ve hastalar için açıklanabilir ve yorumlanabilir kalmasını sağlayan daha sağlam çerçeveler için bir itici güç olabilir.

6 Uygulama süreçlerinde sık görülen engeller

Bir yapay zekâ modelinin doğruluğu ve performansı kritik öneme sahip olsa da nihai klinik etkinliği kullanım ortamındaki uygulamalara göre belirlenir. En gelişmiş yapay zekâ modelleri bile uygulamaya etkili bir şekilde entegre edilmezlerse potansiyellerinin gerisinde kalabilir. Yapay zekâ modellerinin uygulanması, etkilerini başarılı şekilde ortaya çıkarmada ele alınması gereken çeşitli engeller ve zorluklar barındırır.

6.1 Algoritmik yanlılık

Yapay zekâda yanlılık, algoritmalar belirli bireylere veya gruplara karşı sistematik ve haksız ayrımcılık ürettiğinde ortaya çıkar. Bu, önyargılı eğitim verilerinden, model tasarım hatalarından, veri ve kavram kaymasından veya uygunsuz kullanımdan kaynaklanabilir. Sağlık hizmetleri ve ilaçlar bağlamında, bu tür yanlılıkların sonuçları ciddi olabilir ve hasta sonuçlarını ve tedavi etkinliğini etkileyebilir.^{32, 33} Neyse ki, Tablo 8'de açıklandığı gibi yanlılığı ele almaya yardımcı stratejiler vardır. Bu stratejiler yanlılığı ortadan kaldırmaya da azaltmaya yardımcı olabilir.

Tablo 8: Algoritmik yanlılığı ele almak için temel stratejiler

Strateji	Detay
Çok çeşitli verilerin toplanması	Eğitim verilerinin çeşitli popülasyonları temsil ettiğinden emin olmak, yanlılığı azaltmaya yardımcı olabilir. Bu, çeşitli demografik, coğrafik ve sosyo-ekonomik çevreden veri toplamayı içerir.
Algoritmik hakkaniyet	Model eğitimi sırasında yanlılığı aktif olarak kontrol eden ve düzelten adalet duyarlı algoritmalar uygulamak, yanlı sonuçları önleyebilir. Çeşitli hakkaniyet modelleri göz önüne alındığında, her biri yanlılığın farklı yönlerini ele alır (ör; demografik eşitlik). Daha fazla bilgi edinmek için, Alan Turing Enstitüsü, algoritmik hakkaniyete ilişkin pratik teknikler ve kapsamlı içgörüler sağlayan yapay zekâda yanlılık ve ayrımcılığı değerlendirme ve azaltma üzerine bir kurs ³⁴ sunmaktadır.
Sürekli izleme	Yapay zekâ sistemlerinin yanlılığını tespit etmek ve ele almak için düzenli denetim esastır. Bu, sistemin çıktılarının adalet açısından sürekli olarak değerlendirildiği geri bildirim döngülerinin kurulmasıyla olur. Hakkaniyetin birden fazla tanımı vardır. Castelnovo ve diğerleri ³⁵ hakkaniyeti aşağıdaki kavramlarla tanımlar: - Bireysel hakkaniyet: Benzer bireyler benzer sonuçlar almalıdır. Bu, cinsiyet gibi hassas nitelikleri dikkate almadan bireylere özelliklerine göre benzer şekilde davranmayı ele alan Farkındalıkla Hakkaniyet ve Farkında Olmamayla Hakkaniyet gibi kavramları içerir. - Grup hakkaniyeti: Farklı gruplara eşit davranmaya odaklanır ve şunları içerir: - Bağımsızlık (demografik eşitlik): Kararlar hassas niteliklerden bağımsız olmalıdır. - Ayrım (eşit olasılıklar): Gruplar arasında eşit hata oranlarının sağlanması. - Yeterlilik (kalibrasyon): Tahminlerin gruplar arasında eşit derecede doğru olmasını sağlama.
Şeffaflık ve açıklanabilirlik	Yapay zekâ sistemlerini şeffaf ve karar alma süreçlerini açıklanabilir hale getirmek, yanlılığı belirlemeye ve düzeltmeye yardımcı olabilir. Paydaşlar, yapay zekâ sistemlerinin belirli kararları nasıl ve neden aldığını anlamalıdır. Derin öğrenme algoritmaları özünde açıklanamaz olsa da bazı araçlar modelin kararları nasıl aldığını tahmin etmeye yardımcı olmak için kullanılabilir.
Kendi güvenlik bariyerlerini kur	Üretken yapay zekâ konusu farklı bir durumdur. Modelin çıktılarında, var olmayan veriler üretilir. Bu modeller gerçeklere dayalı olacak şekilde eğitilmediğinden, bu modellerle ilgili en büyük endişe, modelin yanlış veya hatalı bir yanıt verdiği halüsinasyonlardır. Dahası, bu modeller deterministik değildir; yani tek bir komut verildiğinde, birden çok doğru (ve yanlış) yanıt vardır. Komut mühendisliği bu durumda önemli bir rol oynar.

6.2 Model sapması

Altta yatan veri modellerindeki değişiklikler nedeniyle bir yapay zekâ modelinin performansının zamanla bozulması olarak tanımlanan model sapması kritik bir sorundur.³⁶ Uygun şekilde yönetilmezse, modelin zamanla daha yanlış hale gelmesine yol açabilir. Tablo 9, model sapmasının etkisini en aza indirmek için stratejileri listelemektedir.

Tablo 9: Model sapmasını yönetme stratejileri

Strateji	Detay
Düzenli yeniden eğitim	Modelleri yeni verilerle periyodik olarak yeniden eğitmek, doğru ve ilgili kalmalarını sağlar.
Performans izleme	Model performansını gerçek zamanlı olarak izlemek için sürekli izleme sistemleri kurmak, sapmanın erken tespit edilmesini sağlar. Doğruluk, kesinlik, tekrar çağırma ve F1 puanı gibi ölçütler izlenebilir.
Versiyon kontrolü	Modeller için sürüm kontrolünün sürdürülmesi, değişiklikleri izlemeye ve gerekirse önceki sürümlere geri dönmeye yardımcı olur. Bu ayrıca modelin performansının evrimini anlamaya yardımcı olur.
Anormallik tespiti	Anormallik tespit sistemlerinin uygulanması, paydaşları model davranışındaki beklenmedik değişiklikler konusunda uyarabilir ve zamanında müdahaleleri teşvik edebilir.

6.3 Ezberleme

Ezberleme, bir modelin sinyal yerine eğitim verilerindeki gürültüyü öğrenmesi ve bunun da ilk kez karşılaşılan verilerde zayıf genellemeye yol açmasıyla oluşur.³⁷ Bu, modellerin eğitim aşamasında çok iyi performans göstermesine ancak eğitim veri kümesinin dışındaki herhangi bir veri üzerinde test edildiğinde zayıf performans göstermelerine neden olur. Ezberlemeyi önlemek için Tablo 10'daki stratejiler uygulanabilir.

Tablo 10: Ezberlemeyi azaltma stratejileri

Strateji	Detay
Çapraz doğrulama	Çapraz doğrulama olarak bilinen bazı teknikler ve iyi uygulamalar vardır. Bu yöntem, modeli farklı veri alt kümelerinde eğitip test ederek, modelin farklı veri setleri üzerinde ne kadar iyi çalıştığını değerlendirmek için kullanılır. Bu tekniklerden biri de k-katlı çapraz doğrulamadır.
Düzenleme teknikleri	Bunlar, modelleri çok karmaşık oldukları için cezalandıran, basitliği ve genellemeyi teşvik eden tekniklerdir. Düzenleme yöntemlerine örnek olarak L1 (Lasso) ve L2 (Ridge) verilebilir.
Budama ve erken durdurma	Karar ağaçlarını budamak (bir tür makine öğrenmesi modeli) ve doğrulama verilerindeki performans düşmeye başladığında eğitim sürecini erken durdurmak ezberlemeyi engellemek için etkili yöntemlerdir.
Birleştirme yöntemleri	Birleştirme yöntemleri, genellemeyi iyileştirmek ve ezberleme olasılığını azaltmak için aynı anda birden fazla tekniğin kullanılmasını içerir.

6.3.1 Akılda tutulması gereken diğer engeller

Yanlılığı en aza indirme, sapmayı yönetme ve ezberlemeyi azaltma gibi teknik zorlukların yanı sıra, yapay zekâyı uygulamaya entegre etmenin önünde önemli idari ve insan kaynaklı engeller de vardır. Bunlara karmaşık klinik iş akışlarında aradığını bulma ve eczacıların yeni araçlar ve süreçler konusunda yeterli şekilde eğitilmesi dahildir. Başarılı uygulama ayrıca son kullanıcıların ilgisini çekmeye ve yeni teknolojiyi benimseme isteklerini teşvik etmeye de bağlıdır. Tablo 11, başarılı yapay zekâ entegrasyonunu desteklemek için ele alınması gereken önemli engelleri özetlemektedir.

Tablo 11: Uygulamaya yönelik ek zorluklar

Engeller	Detay
Karmaşık iş akışlarıyla entegrasyon	Yapay zekâyı karmaşık farmasötik ve klinik iş akışlarına entegre etmek çeşitli hususları içermektedir. Bu, yapay zekânın benimsenmesi ve uygulanması için büyük bir zorluktur. ³⁸
Birlikte çalışabilirlik	Yapay zekâ sistemlerinin mevcut bilişim altyapısı ve yazılım sistemleriyle sorunsuz bir şekilde entegre olabilmesini sağlamak hayati önem taşır. Bu entegrasyon, iletişim için standart protokolleri ve uygulama programlama arayüzlerini kullanmayı içerir. Ayrıca, gerekli kaynaklara (hem insan hem de ekonomik) sahip olmak da oldukça önemlidir.
Kullanıcı eğitimi ve desteği	Son kullanıcılara kapsamlı eğitim ve destek sağlamak, sorunsuz bir şekilde benimsenmesini sağlamak için gereklidir. Kullanıcı dostu arayüzler oluşturmak ve sürekli teknik destek sunmak da buna dahildir.
İş akışı özelleştirme	Yapay zekâ çözümleri, onu kullanan eczanenin, ilaç şirketinin, kuruluşun veya bireylerin özel ihtiyaçlarına ve süreçlerine uyacak şekilde uyarlanmalıdır. Özelleştirme, yapay zekâ araçlarının mevcut iş akışlarını bozmak yerine onları tamamlamasını sağlar.
Ölçeklenebilirlik	Yapay zekâ sistemleri, kullanan kuruluşun büyümesiyle ölçeklenecek şekilde tasarlanmalıdır. Bu, artan veri hacimleri, ek işlevler ve genişletilmiş kullanıcı tabanları için planlama gerektirir.
İşbirliği ve iletişim	Yapay zekâ uzmanları, eczacılar ve diğer paydaşlar arasında iş birliğinin teşvik edilmesi hayati önem taşımaktadır. Açık iletişim kanalları, yapay zekâ çözümlerinin gerçek dünyadaki zorlukları etkili bir şekilde ele almasını sağlamaya yardımcı olur. Her iki dünyayı bütünleştirmek için hem teknik uzmanlığa hem de sektörel bilgi birikimine ihtiyaç vardır. Bir şirkete yapay zekâyı entegre etmek, engelleri ve karışıklıkları aşabilen bütün bir kültür tarafından desteklenmelidir.
Yüksek başlangıç maliyetleri	Yapay zekâ çözümlerinin geliştirilmesi ve uygulanması altyapı, kalifiye personel ve teknoloji için önemli yatırımlar gerektirmektedir ve bu da birçok kuruluş için caydırıcı olabilmektedir. ^{32, 38}
Değişim yönetimi	Yapay zekâyı mevcut iş akışlarına entegre etmek, kuruluş içinde kültürel bir değişim gerektirir. Personel ve paydaşlar arasında değişime karşı direnç gösterilmesi, benimseme sürecini engelleyebilir. ^{32, 38}

6.4 Artıları ve eksileri belirleyerek doğru aracı seçme

Doğru aracı seçmek her zaman kolay değildir ve genellikle birden fazla yapay zekâ çözümü etkili olabilir. Kararı yönlendiren her zaman aracın işlevsel yetenekleri olmayabilir. Uygulanacağı teknik ortam, modeli oluşturma, inşa etme veya sürdürme maliyeti, ihtiyaç duyulan şeffaflık düzeyi, düzenlemeler veya veri erişimi gibi faktörler de devreye girebilir.

Doğru aracı seçerken, aracın yetenekleri ve sınırlılıkları ile birlikte uygulama tasarımı da hesaba katılmalıdır. Örneğin, hastalara sağlık bilgisi sağlamak için üretken bir yapay zekâ aracı oluşturmak, aracı doğrudan hastaların kullandığı durumda daha yüksek bir risk taşır. Ancak, model bir hastaya sunulmadan önce onu inceleyen bir klinisyene bilgi sağlıyorsa, risk çok daha düşüktür. İkinci senaryoda kullanılabilecek araç seçeneği çok daha fazladır, çünkü ilk senaryo için ihtiyaç duyulacak tüm güvenlik önlemlerine ilk etapta ihtiyaç duyulmayabilir.

Benzer şekilde, yoğun bakım ortamlarında ilaç dozajı için klinik karar destek aracı oluşturmak farklı hususları içerir. Bir hastanın her gün alması gereken dozu öneren bir model oluşturmak, bir klinisyeni hastanın durumunun değiştiği (veya yakında değişeceğinin tahmin edildiği) konusunda uyararak ve klinisyeni nasıl bir doz ayarlamasının gerektiğini değerlendirmeye yönlendiren bir model oluşturmaktan çok farklıdır. Her iki senaryo da modeli oluşturmak için farklı eğitim verileri gerektirir, çünkü her modelin çıktısı farklı olacaktır. İlk senaryo için, modelin çıktısı önerilen bir dozdur (ör. 5 mg). İkinci senaryo için, model çıktısı bir doz ayarlamasının gerekip gerekmediğini öngörür. İkinci senaryo daha az risk barındırır, çünkü kararı hala bir klinisyen vermektedir ve karar yapay zekâ ile zenginleştirilmiştir. İlk senaryo için pekiştirmeli bir öğrenme modeli daha uygun olabilirken, ikincisi için denetimli bir öğrenme modeli daha uygun olabilir.


6.4.1 Modeller arasındaki artı ve eksilerin tartılması

Derin öğrenme yapay zekâ araçlarını kullanmanın birçok faydası vardır, ancak veriye bağımlı olması ve sınırlı model yorumlanabilirliği gibi akılda tutulması gereken genel sınırlamaları da vardır (bkz. Tablo 12). Daha derine inildiğinde, farklı yapay zekâ modellerinin güçlü ve zayıf yönlerini türlerine, öğrenme stillerine ve girdi verilerine göre tartmak önemlidir. Şekil 2, yaygın olarak kullanılan yapay zekâ modellerini ana hatlarıyla belirtirken, Tablo 13, modellerin nasıl uygulandığına ve nihai kullanım hedefine bağlı olarak her model türü için dikkate alınması gereken artıların ve eksilerin üst düzey bir özetini sağlar.

Tablo 12: Derin öğrenme modellerinin genel artıları ve eksileri

Artılar	Eksiler
Uyarlanabilirlik: Model daha fazla veriye maruz kaldığında performansı artırılabilir.	Veriye bağımlılık: Etkili ve doğru bir şekilde eğitim için büyük miktarda veriye ihtiyaç vardır.
Çok Yönlülük: Görüntü tanımadan doğal dil işlemeye kadar çok çeşitli sorunlara uygulanabilir.	Opaklık: Derin sinir ağları gibi karmaşık modeller “kara kutular” olabilir ve bu da model tarafından kararların nasıl alındığını anlamayı zorlaştırır.

Şekil 2: Derin öğrenme modelleri



Tablo 13: Farklı model türleri için dikkate alınması gereken artıların ve eksilerin üst düzey özeti

Model	Örnekler (her şeyi kapsamamaktadır)	Artılar	Eksiler	Dikkate alınması gereken hususlar
Üretken doğal dil işleme araçları (büyük dil modelleri)	Sohbet robotu Doğal metni işleyen ve bir insanla sohbeti simüle eden bir bilgisayar programı ³⁹ İçerik oluşturma - Bir komut üzerine orijinal metin üretir Belge sınıflandırma - Bir belgeyi konuya veya diğer özelliğe göre etiketler Özetleme - Bir belgenin veya komutun özetini üretir	- Giriş verilerinin yapılandırılmasını gerektirmez - Çok yönlü - Tek bir model birçok farklı amaç için kullanılabilir - Birçok ürün/kaynak kodlama gerektirmez ve kullanımı kolaydır - Genel kullanımlar için birçok model “kutudan çıkar çıkmaz” kullanıma hazırdır (ör. ek eğitim veya ince ayar gerektirmez) - Modeller, harici bir veri kaynağına bağlanabilir	- Doğru olmak için eğitilmemiştir. Halüsinasyonlara yatkındır. - Bağılamsal sınırlamalar: Bağlamı, alaycılığı ve nüanslı dili anlamada zorlanır - Yanlılık: Eğitim verilerinde bulunan yanlılıkları istemeden öğrenebilir ve yayabilir - Alana özgü görevlerde zorluk çekebilir - Model, eğitim süreci tamamlandıktan sonra meydana gelen hiçbir bilgiyi (örneğin, güncel olaylar, yeni ilaçlar, kılavuz güncellemeleri) içermez	- Genellikle, kurum içinde geliştirmek pratik değildir. Genellikle mevcut bir temel model kullanılmaktadır. - Bazı modeller tescilliyeğin diğerleri açık kaynaklıdır - Performans farklı modellerde değişir. Bazıları belirli becerilerde diğerlerinden daha doğrudur (tıbbi bilgi, matematik, muhakeme, ilaç bilgisi vb.). - Bir modelin çeşitli ölçütlere göre nasıl performans gösterdiğini, nasıl eğitildiğini, eğitimin hangi noktada son bulduğunu ve yanlılık kaynaklarını/ riskini gözden geçirmek önemlidir. Ancak, tüm modeller bu verileri paylaşmaz. - Modelin gerçek zamanlı bilgi sağlaması veya belirli bir belge veya dahili bilgi tabanı hakkında soruları yanıtlaması için Retrieval-Augmented Generation (RAG) gibi tekniklerin kullanılmasını gerektirir.

Model	Örnekler (her şeyi kapsamamaktadır)	Artılar	Eksiler	Dikkate alınması gereken hususlar
Üreten olmayan doğal dil işleme araçları	Sınıflandırma: - Bir belgenin konusunu etiketleme Veri çıkarma: - Bir klinik nottan tanı veya ilaç listesini çıkarma Öngörücü: - Hastane klinik notlarını kullanarak bir hastanın palyatif bakıma ihtiyaç duyma riskini tahmin etme	- Geliştiriciler model çıktısı üzerinde daha fazla kontrole sahiptir - Daha az veriyle oluşturulabilir - Çok fazla bilgi işlem gücü gerektirmez (bireysel cihazlarda daha kolay çalıştırılabilir) - Dar kullanım alanları için etkilidir	- Oluşturulması daha uzun sürer; yapay zekâ uzmanlığı gerektirir - Spesifik ve genelleştirilemez. Tek bir kullanım için oluşturulan modeller yeniden eğitilmeden başka amaçlar için kullanılamaz. - Genellikle eğitim için etiketli veri gerektirir ve bu da oluşturması yoğun bir kaynak olabilir	- Kurum içinde oluşturulabilir - Önceden eğitilmiş etkin verilerin kullanılması doğruluğu artırmaya yardımcı olabilir - Temel modele ve sinir ağlarının kullanılıp kullanılmamasına bağlı olarak, bu modeller sinir ağlarını kullanan diğer kara kutu modellerinden daha anlaşılır olabilir
Çok modlu üreten yapay zekâ modelleri	Sohbet robotları: - Metin, resim, ses ve/veya video işleyerek bir insanla sohbeti simüle eden bir bilgisayar programı Yapay zekâ asistanları: - Bir görevi tamamlamak için birbirleriyle ve/veya diğer araçlarla koordine olan çoklu modeller	- Modellerle birden fazla kanal üzerinden etkileşime girilebilir - Modeller, takip sorularına ve ileri geri diyaloga izin verecek şekilde tasarlanabilir (örneğin, bir modelden bir görüntüye bakmasını istedikten sonra, kullanıcı modelin bu görüntü ile ilgili verdiği yanıtlara dayanarak takip soruları sorabilir)	Üreten yapay zekâ için olan sınırlamalar çok modlu modeller için de geçerlidir	- Tüm modeller gerçekten çok modlu değildir. Bazıları birkaç farklı modeli (örn. metin oluşturucu, görüntü oluşturucu, transkripsiyon modeli, vb.) bir araya getirerek çok modlu gibi görünür. - Dikkate alınması gereken hususlar, yukarıdaki üretken doğal dil işleme araçları için olanlara benzerdir

Model	Örnekler (her şeyi kapsamamaktadır)	Artılar	Eksiler	Dikkate alınması gereken hususlar
Denetimli öğrenme modeli - görüntü tanıma	Tanı: Tıbbi görüntülemelerden hastalık özelliklerini teşhis etme ⁴⁰⁻⁴²	Birçok yapay zekâ çözümü, Gıda ve İlaç Dairesi (FDA) gibi düzenleyici kurumlar tarafından belirlendiği üzere yeterli doğruluk, güvenlik ve güvenilirlik göstermiştir ⁴³	- Modeller kara kutulardır ve açıklanamazlar - Genellikle yalnızca eğitildiği verileri ile aynı boyut, tür ve çözünürlükteki görüntülerle kullanılabilir - Belirli bir görüntüleme cihazına bağlı olabilir- cihaz değiştirilirse yeni bir model gerekir	Üçüncü taraf bir satıcıdan tıbbi görüntüleme için derin öğrenme modeli kullanılıyorsa, modelin geçerli ilaç veya cihaz düzenleyici kuruluş tarafından onaylanıp onaylanmadığı kontrol edilmelidir. (örneğin, FDA, ABD; Health Sciences Authority, Singapur; South African Health Products Regulatory Authority (SAHPRA), Güney Afrika; INFARMED, Portekiz; Medicines and Healthcare Products Regulatory Agency (MHRA), Birleşik Krallık) ⁴⁴
Denetimli öğrenme modeli - tablo verileri	Risk tahminleri/öngörülere: - Bir hastanın taburcu olduktan sonra tekrar hastaneye yatırılma olasılığı için bir risk puanı oluşturma ⁴⁵ - İlaç kıtlıklarını tahmin etme ⁴⁶	- Uygulama için birçok araç mevcuttur - Yüksek doğruluk ve performans elde edilebilir - Önemli miktarda sağlık verisi zaten tablo biçiminde mevcuttur - Yerel verilere göre inceleme yapılabilir - Mevcut verileri yeni bir ölçüte veya risk puanına eşlemek için kullanılabilir (örneğin, pedometre verilerini yürüme stabilitesi puanına eşlemek)	- Modeller kara kutulardır ve açıklanamazlar - Geleneksel istatistiksel yöntemlere (örneğin, lojistik regresyon) göre her zaman daha iyi bir performans göstermeyebilir - Daha basit istatistiksel yöntemlere kıyasla performans kazanımlarını görmek için büyük miktarda veri gerektirir - Verilerdeki önceden var olan hataları ve yanlışlıkları devam ettirir - Genelleştirilemez	"Tavsiye" sistemleri için ideal değildir - en iyi eylemi gerçek anlamda tahmin etmez, ancak tarihsel olarak hangi eylemlerin gerçekleştirildiğini tahmin eder (ki bu her zaman doğru olmayabilir). - Ölçeklenmesi zor ve yoğun kaynaklı olabilir. Her yeni kullanım durumu genellikle yeni bir model ve eğitim verisi gerektirir

Model	Örnekler (her şeyi kapsamamaktadır)	Artılar	Eksiler	Dikkate alınması gereken hususlar
Pekiştirmeli öğrenme modeli	Öneri sistemleri: Uzun vadeli bir hedefe ulaşmak için bir dizi eylemi/kararı optimize eder	- Açık bir denetim olmadan öğrenebilirler, bu da onları açıklamalı verilerin eksik veya mevcut olmadığı görevler için uygun hale getirir - Uzak gelecekte var olabilecek bir ödülü en üst düzeye çıkarmak için tasarlanmıştır (örneğin, bir oyunu kazanmak için hangi eylem dizisinin yapılması gerektiği) - Bir hedefe ulaşmak için bir dizi eylem gerektiren problemlerde mükemmeldir	- Ödül fonksiyonu iyi tanımlanmıyorsa bu modeller genellikle beklenmeyen sonuçlara yol açabilir - Kara kutu - Model, sağlık hizmeti ortamında güvenli olmayabilecek diğer eylem yollarını "keşfetmek" için öngörülemeyen kararlar alabilir - Modelin güvenli olmayan önerilerde bulunmasını önlemek için modelde koruma önlemleri uygulamak zordur	"Ödülün" kısa vadeli bir faydadan ziyade uzun vadeli bir sonuç olabileceği bir sağlık hizmeti ortamına iyi uyum sağlar. Örneğin, hastanın taburcu olma şansını artırma amacıyla uzun bir hastane yatışı boyunca birden fazla tedavi kararı verilir (uzun vadeli hedef) - Bu modeller, güvenlik bariyerleri oluşturmak için bilgi tabanlı sistemlerle entegre edilmelidir - Doğru "ödülün" seçildiğinden ve modelin yanlışlıkla yanlış olanı optimize etmediğinden emin olmak için titiz bir doğrulama gereklidir

7 Uygulama kontrol listesi

Yapay zekâ araç setindeki bilgilerin bir özeti olarak, aşağıdaki kontrol listesi, bir yapay zekâ aracı veya çözümünün uygulanmasını takip ederken tartışmaları yönlendirmeye yardımcı olacak bir soru listesi olarak hizmet eder. Kapsamlı bir kılavuz olarak değil, bir başlangıç noktası olarak kullanılmalıdır. Her çalışma ortamının veya ortamın dikkate alınması gereken kendine has gereksinimleri olacaktır.

Kontrol listesi	
Kullanım durumunun tanımlanması	
☐	Yapay zekâ aracı hangi sorunu çözmeyi amaçlıyor?
☐	Sorun, yapay zekâ destekli olmayan bir çözüm veya araçla çözülebilir mi?
☐	Karar vericiler ve son kullanıcılar dahil olmak üzere tüm uygun paydaşlar dahil edildi mi?
☐	Bu araç mevcut iş akışına nasıl uyacak veya iş akışı araca göre nasıl ayarlanacak?
Model seçimi	
☐	Yapay zekâ modeli kurum içinde mi geliştirilecek yoksa üçüncü taraf bir satıcı mı kullanılacak?
☐	Model kurum içinde oluşturuluyorsa, yeterli eğitim verisi var mı?
☐	Üçüncü taraf bir temel model kullanılıyorsa, yerel veya alan-özel verilerle ince ayar (ek eğitim) gerekecek mi?
☐	Üçüncü taraf bir yapay zekâ destekli ürün veya yazılım kullanılıyorsa, düzenleyici bir kurum tarafından güvenli ve etkili olarak değerlendirilmesi ve onaylanması gerekiyor mu (örneğin, tıbbi cihaz olarak FDA onaylı yazılım)? Öyleyse, onaylandı mı?
☐	Mevcut bir model kullanılıyorsa, model ne kadar iyi performans gösteriyor (bkz. Tablo 3)? Diğer modellerle veya mevcut kıyaslama ölçütleriyle nasıl karşılaştırılıyor?
Uyumluluk	
☐	Model korunan sağlık bilgilerine erişebilecek veya bunları kullanabilecek mi?
☐	Modelin kullanılması, verilerin kurum dışında paylaşılmasını gerektirecek mi? Örneğin, model bir Uygulama Programlama Arayüzü kullanmayı mı gerektiriyor yoksa veriler kuruluş dışındaki bir bulut sunucusuyla mı paylaşılıyor? Eğer öyleyse, bu durum, modelin girdisine hangi verilerin dahil edilebileceği konusunda hangi sınırlamaları getiriyor?
☐	Hangi uyumluluk düzenlemelerine uyulmalıdır (Uyumluluk ve ISO regülasyonları bölümüne bakınız)?
☐	Model yerel olarak kullanılabilir mi?
Satıcı seçimi	
☐	Üçüncü taraf bir satıcı kullanılıyorsa, satıcı bir model kartı (Tablo 2'de açıklandığı gibi) veya eğitim verileri ve model performansı hakkında ayrıntılı bilgi (Tablo 3'teki ölçütlere bakın) sağlıyor mu?
☐	Satıcı model performansını ne sıklıkla denetliyor veya modelini ne sıklıkla yeniden eğitiyor?
☐	Satıcı, herhangi bir model güncellemesi yayınlandıktan sonra, güncellenmiş performans ölçümleri sağlıyor mu?
Güvenlik	
☐	Modelin muhtemel arıza modları ana hatlarıyla belirtildi mi? Etki azaltma stratejileri neler olacak?
☐	Model sürekli olarak nasıl denetlenecek?
☐	Modelin muhtemel sapmaya göre ne sıklıkla yeniden doğrulanması gerekiyor?
☐	Modelin eğitim verilerine göre, model belirli alt popülasyonlar için daha az doğruluk içermeye durumu var mı? Bu nasıl azaltılacak?

8 Yapay zekâ yetkinliğinin eğitimi ve geliştirilmesi

8.1 Eczacıların yapay zekâ hakkında bilmesi gerekenler nelerdir?

Hem hastane hem de toplum eczacıları ve ekipleri için, bu teknolojilerin tüm potansiyelinden yararlanmak adına aşağıdaki yetkinlikler esastır:

- **Üretken yapay zekânın yetenek ve sınırlamalarının anlaşılması:** Eczacılar, üretken yapay zekâ araçlarının kapsamları, güvenilirlikleri ve en iyi şekilde çalıştıkları bağlamlar dahil olmak üzere neleri yapıp neleri yapamayacaklarını anlamalıdır. Bu bilgi, karar alma sürecinde yapay zekâyı uygun şekilde güvenilmesini ve hatalara yol açabilecek aşırı güvenin önlenmesini sağlar.
- **Veri okuryazarlığı:** Yapay zekâ araçlarından elde edilen veri çıktılarını yorumlama ve değerlendirme yeteneği çok önemlidir. Eczacıların, doğru hasta bakımı ve ilaç yönetimi için, yapay zekâ tarafından üretilen verileri nasıl okuyacaklarını, analiz edeceklerini ve bunlara dayanarak bilinçli kararlar vereceklerini anlamaları gerekir.
- **Yapay zekâ kullanımının etik ve yasal hususları:** Eczacılık uygulamalarında yapay zekâ kullanımının etik etkilerini ve yasal sınırlarını anlamak çok önemlidir. Bunlara hasta mahremiyeti ile ilgili endişeler, veri güvenliği ve hasta güvenliğini ve düzenlemelere uyumu sağlamak için karar alma süreçlerinde yapay zekânın etik kullanımı dahildir.
- **Eleştirel düşünme ve karar alma:** Yapay zekâ öneriler sunabilse de, nihai karar verme sorumluluğu eczacıya aittir. Her hastanın kendine has bağlamlarını ve ihtiyaçlarını göz önünde bulundurarak yapay zekâ tarafından oluşturulan tavsiyeleri eleştirel bir şekilde değerlendirme yeteneği, etkili eczacılık uygulamaları için esastır.
- **İletişim becerileri:** Eczacılar, yapay zekâ tarafından üretilen bilgileri hastalara ve sağlık ekiplerine etkili bir şekilde iletmelidir. Bu, karmaşık yapay zekâ verilerini anlaşılır tavsiyelere dönüştürmeyi ve yapay zekâ destekli kararların şeffaf ve gerekçeli olmasını sağlar.
- **Sürekli öğrenme ve uyarlanabilirlik:** Yapay zekâ alanı hızla gelişmektedir. Bu nedenle eczacıların sürekli eğitim ve yeni teknolojilere uyum sağlamaları gerekmektedir. Bu sürekli öğrenme, hasta bakımını iyileştirmek için en güncel yapay zekâ araçlarını kullanarak eczacılık uygulamalarının en ileri düzeyde kalmasını sağlar.
- **Multidisiplinler ekipleri için iş birliği becerileri:** Bilişim uzmanları, veri bilimcileri ve diğer sağlık hizmeti sağlayıcıları dahil olmak üzere multidisipliner ekiplerle çalışmak, eczacılık uygulamasında yapay zekâ araçlarını uygulamak ve optimize etmek için çok önemlidir. Etkili iş birliği, yapay zekâ uygulamalarının iyi koordine edilmesini ve sağlık hizmeti sunumunun çeşitli ihtiyaçlarının karşılanmasını sağlar.
- **Hasta merkezli bakım:** Eczacılar, yapay zekâ araçlarının hasta ihtiyaçlarına ve sonuçlarına öncelik verecek şekilde kullanılmasını sağlamalıdır. Bu, ilaç yönetimini ve desteğini kişiselleştirmek ve hastalara sunulan bakımın kalitesini artırmak için yapay zekâyı kullanmayı içerir.
- **İnovasyon ve yaratıcılık:** Son olarak, yapay zekâ ile çalışan tüm ekosistemlerde olduğu gibi, eczacılar yenilikçi bir zihniyet geliştirmeli ve yapay zekâyı eczacılık uygulamalarında kullanmak için yaratıcı yollar aramalıdır. Eczacılık bilimini ileri taşıyacak yapay zekâ tarafından zenginleştirilmiş yeni iş akışlarını, hasta bakım stratejilerini ve yönetim uygulamalarını geliştirmek buna dahildir.

Bu yetkinliklerin her biri, eczacıların ve ekiplerinin üretken yapay zekâ araçlarını uygulamalarına etkili bir şekilde entegre etmeleri için kritik öneme sahiptir. Birlikte, yüksek kaliteli, verimli ve kişiselleştirilmiş hasta bakımının sunulmasını sağlayarak, eczacıların sağlık hizmetlerinde yenilikçiliğin ön saflarında kalmasını sağlarlar.

8.2 Yapay zekâ bilgi ve becerileri

Üretken yapay zekâ araçlarının eczacılık uygulamalarına entegre edilmesi, daha verimli ve etkili sağlık hizmeti sunumuna doğru dönüştürücü bir değişimi temsil etmektedir. Eczacılık uygulamalarında, yapay zekâ sistemleri ilaç yönetimini optimize etmek, reçete doğruluğunu artırmak ve envanter kontrolünü kolaylaştırmak için giderek daha fazla kullanılmaktadır. Örneğin, yapay zekâ destekli reçete doğrulama sistemleri, ilaç siparişlerindeki olası hataları otomatik olarak tespit ederek eczacılar için manuel doğrulama görev yükünü azaltabilir. Bu durum verimliliği ve hasta güvenliğini artırırken, eczacıların ilaç dağıtım süreçlerini denetleme ve klinik bakım sağlama konusundaki geleneksel rolünü de etkiler. Eczacıların, yapay zekâ sistemleriyle birlikte çalışmaya uyum sağlamaları ve yapay zekâ tarafından üretilen verileri yönetme ve yorumlama konusunda yeni beceriler edinmeleri gerekmektedir.

Sağlık hizmetleri ve eczacılık uygulamalarında yapay zekâ ve uygulamaları hakkında daha fazla bilgi edinmek isteyen eczacılar, çeşitli öğrenme ortamlarına sahiptir. Coursera, edX, Udemy gibi kurumlar ve üniversiteler tarafından sunulan çevrimiçi kurslar ve web seminerleri, yapay zekâ, yapay zekâ ilkeleri ve sağlık hizmetlerindeki uygulamaları hakkında temel bilgiler sağlar ve kolayca erişilebilir.

Asya'da Coursera'nın Çin ofisi, en iyi Çin üniversiteleriyle ortaklaşa, Mandarin dilindeki mevcut içerikle sağlık hizmetlerinde yapay zekâyı odaklanan özel kurslar sunmaktadır. NUS-ISS (National University of Singapore, Institute of Systems Science), Singapur ve çevre bölgelerdeki profesyonellere hitap eden, sağlık hizmetlerinde yapay zekâ konusunda uzmanlaşmış programlar sunmaktadır. Güney Kore Eğitim Bakanlığı tarafından desteklenen K-MOOC (Korean Massive Open Online Course, Kore Kitleli Açık Çevrimiçi Kursu), sağlık ve eczacılıktaki uygulamalara odaklanan ve Korece olarak sunulan yapay zekâ ile ilgili kurslar sunmaktadır. Ayrıca, Singapur'daki Nanyang Teknoloji Üniversitesi, Asya genelindeki sağlık profesyonellerini hedefleyerek sağlık hizmetlerinde yapay zekâ uygulamaları konusunda yönetici eğitimi ve çevrimiçi öğrenme modülleri sunmaktadır. Bu platformlar, eczacılara yapay zekâyı uygulamalarına etkili bir şekilde entegre etmeleri için bölgeye özgü içgörü ve beceriler sağlamaktadır.

Amerikan Sağlık Sistemi Eczacıları Derneği (American Society of Health-System Pharmacists, ASHP) ve Uluslararası Eczacılık Federasyonu (FIP) gibi mesleki kuruluşlar, eczacılık uygulamalarında yapay zekâyı odaklanan özel eğitim oturumları, atölyeler ve konferanslar sunmaktadır. Akademik dergiler ve yayınlar genellikle yapay zekâ araştırmaları ve vaka çalışmaları hakkında makaleler yayınlayarak eczacıları en son gelişmeler ve pratik uygulamalar konusunda güncel tutar.

Seminerler ve projeler aracılığıyla veri bilimcileri ve sağlık profesyonelleri de dahil olmak üzere multidisipliner ekiplerle iş birliği yapmak, pratik bilgiler ve gerçek dünya deneyimi sağlayabilir. Ayrıca hem çevrimiçi hem de profesyonel ağlar içinde yapay zekâ odaklı forumlara ve tartışma gruplarına katılım, sürekli öğrenme ve bilgi paylaşımını teşvik eder.

Bu çeşitli eğitim kaynakları, hasta bakımını iyileştirmek ve sağlık hizmeti sunumunu optimize etmek için eczacıları, yapay zekâyı eczacılık uygulamalarına etkili bir şekilde entegre etmek üzere gereken beceri ve anlayışla donatmaya yardımcı olabilir.

9 Kaynakça

1. Templin T, Perez MW, Sylvia S, Leek J, Sinnott-Armstrong N. Addressing 6 challenges in generative AI for digital health: A scoping review. PLOS Digital Health. 2024;3(5):e0000503. Available at: <https://pubmed.ncbi.nlm.nih.gov/38781686>.
2. Jiang T, Gradus JL, Rosellini AJ. Supervised Machine Learning: A Brief Primer. Behav Ther. 2020;51(5):675-87. Available at: <https://pubmed.ncbi.nlm.nih.gov/32800297>.
3. Stokes JM, Yang K, Swanson K, Jin W, Cubillos-Ruiz A, Donghia NM, et al. A Deep Learning Approach to Antibiotic Discovery. Cell. 2020;180(4):688-702.e13. Available at: <https://pubmed.ncbi.nlm.nih.gov/32084340>.
4. Arulkumaran K, Deisenroth MP, Brundage M, Bharath AA. Deep Reinforcement Learning: A Brief Survey. IEEE Signal Processing Magazine. 2017;34(6):26-38. Available at: <https://ieeexplore.ieee.org/document/8103164>
5. Silver D, Hubert T, Schrittwieser J, Antonoglou I, Lai M, Guez A, et al. Mastering chess and shogi by self-play with a general reinforcement learning algorithm. arXiv preprint arXiv:1712.01815. 2017. Available at: <https://arxiv.org/abs/1712.01815>.
6. Heo J, Kang Y, Lee S, Jeong D-H, Kim K-M. An Accurate Deep Learning-Based System for Automatic Pill Identification: Model Development and Validation. J Med Internet Res. 2023;25:e41043. Available at: <https://pubmed.ncbi.nlm.nih.gov/36637893>.
7. Mitchell M, Wu S, Zaldivar A, Barnes P, Vasserman L, Hutchinson B, et al., editors. Model Cards for Model Reporting 2019: ACM. Available at: <https://dl.acm.org/doi/10.1145/3287560.3287596>.
8. Fang H, Miao H, Shukla K, Nanas D, Xu C, Greer C, et al. Introducing the model card toolkit for easier model transparency reporting. Google AI Blog. 2020. Available at: <https://research.google/blog/introducing-the-model-card-toolkit-for-easier-model-transparency-reporting>.
9. Jelinek F, Mercer RL, Bahl LR, Baker JK. Perplexity—a measure of the difficulty of speech recognition tasks. The Journal of the Acoustical Society of America. 1977;62(S1):S63-S. Available at: <https://pubs.aip.org/asa/jasa/article/62/S1/S63/642598/Perplexity-a-measure-of-the-difficulty-of-speech>.
10. Lin C-Y, Och FJ, editors. Orange: a method for evaluating automatic evaluation metrics for machine translation. COLING 2004: Proceedings of the 20th International Conference on Computational Linguistics; 2004. Available at: <https://aclanthology.org/C04-1072>.
11. Papineni K, Roukos S, Ward T, Zhu W-J, editors. Bleu: a method for automatic evaluation of machine translation. Proceedings of the 40th annual meeting of the Association for Computational Linguistics; 2002. Available at: <https://aclanthology.org/P02-1040>.
12. Wang A. Glue: A multi-task benchmark and analysis platform for natural language understanding. arXiv preprint arXiv:1804.07461. 2018. Available at: <https://arxiv.org/abs/1804.07461>.
13. Lin C-Y, editor ROUGE; A package for automatic evaluation of summaries. Text summarization branches out; 2004; Barcelona, Spain: Association for Computational Linguistics. Available at: <https://aclanthology.org/W04-1013>.
14. Hossin M, Sulaiman MN. A review on evaluation metrics for data classification evaluations. International journal of data mining & knowledge management process. 2015;5(2):1. Available at: <https://www.aircconline.com/ijdkp/V5N2/5215ijdkp01.pdf>.
15. High-Level Expert Group on Artificial Intelligence. Ethics guidelines for trustworthy AI 2019. Available at: <https://digital-strategy.ec.europa.eu/en/library/ethics-guidelines-trustworthy-ai>.
16. Harrer S. Attention is not all you need: the complicated case of ethically using large language models in healthcare and medicine. eBioMedicine. 2023;90:104512. Available at: <https://pubmed.ncbi.nlm.nih.gov/36924620>.

17. Morley J, Machado CC, Burr C, Cowls J, Joshi I, Taddeo M, et al. The ethics of AI in health care: a mapping review. *Social Science & Medicine*. 2020;260:113172. Available at: <https://pubmed.ncbi.nlm.nih.gov/32702587>.
18. Mccradden M, Odusi O, Joshi S, Akrouf I, Ndlovu K, Glocker B, et al. What's fair is... fair? Presenting JustEFAB, an ethical framework for operationalizing medical ethics and social justice in the integration of clinical machine learning: JustEFAB. *Proceedings of the 2023 ACM Conference on Fairness, Accountability, and Transparency*; Chicago, IL, USA: Association for Computing Machinery; 2023. p. 1505–19. Available at: <https://dl.acm.org/doi/10.1145/3593013.3594096>.
19. Beauchamp TL, Childress JF. *Principles of biomedical ethics*. 7th ed. New York: Oxford University Press; 2013.
20. WHO Guidance. *Ethics and governance of artificial intelligence for health*. World Health Organization. 2021. Available at: <https://www.who.int/publications/i/item/9789240029200>.
21. Jobin A, Ienca M, Vayena E. The global landscape of AI ethics guidelines. *Nature machine intelligence*. 2019;1(9):389-99. Available at: <https://www.nature.com/articles/s42256-019-0088-2>.
22. Abby Sen A, Joy J, Jennex M. *Illuminating Ethical Dilemmas in AI-Driven Regulation of Healthcare Marketing on Social Media*. 2025. Available at: <https://hdl.handle.net/10125/109472>.
23. Leben D. Ethical issues for AI in medicine. *Digital Health*. 2025:309-19.
24. Hasan HE, Jaber D, Khabour OF, Alzoubi KH. Ethical considerations and concerns in the implementation of AI in pharmacy practice: a cross-sectional study. *BMC Medical Ethics*. 2024;25(1):55. Available at: <https://bmcmethics.biomedcentral.com/articles/10.1186/s12910-024-01062-8>.
25. Hefti E, Xie Y, Engelen K. Machine learning model better identifies patients for pharmacist intervention to reduce hospitalization risk in a large outpatient population. *Journal of Medical Artificial Intelligence*. 2025;8. Available at: <https://jmai.amegroups.org/article/view/9455/html>.
26. Act EAI. *The EU Artificial Intelligence Act*. Retrieved May; 2024. Available at: <https://artificialintelligenceact.eu>.
27. Health Insurance Portability and Accountability Act of 1996, 104 (1996). Available at: <https://aspe.hhs.gov/reports/health-insurance-portability-accountability-act-1996>.
28. Regulation (EU) 2016/679 of 27 April 2016 on the protection of natural persons with regard to the processing of personal data and on the free movement of such data, and repealing Directive 95/46/EC (General Data Protection Regulation), (2023). Available at: <https://eur-lex.europa.eu/eli/reg/2016/679/oj/eng>.
29. Baird P, Cobbaert K. Software as a medical device. A comparison of the EU's approach with the US's approach. Available at: <https://pages.bsigroup.com/l/35972/2023-12-11/3t7658k>.
30. Hermon R. Software as a Medical Device (SaMD): Useful or useless term? 2021. Available at: <https://researchnow.flinders.edu.au/en/publications/software-as-a-medical-device-samd-useful-or-useless-term>.
31. HL-7. HL7 2023 [Available at: <https://www.hl7.org/>].
32. Meskó B, Topol EJ. The imperative for regulatory oversight of large language models (or generative AI) in healthcare. *npj Digital Medicine*. 2023;6(1):120. Available at: <https://www.nature.com/articles/s41746-023-00873-0>.
33. Levi R, Gorenstein D. AI in medicine needs to be carefully deployed to counter bias—and not entrench it. *NPR Health Shots*. 2023. Available at: <https://www.npr.org/sections/health-shots/2023/06/06/1180314219/artificial-intelligence-racial-bias-health-care>.
34. Kohsiyama A, Lomas E, Polle R, Almeida D, Kazim E, Inness C. *Assessing and Mitigating Bias and Discrimination in AI: The Alan Turing Institute*; 2024. Available at: <https://www.turing.ac.uk/courses/assessing-and-mitigating-bias-and-discrimination-ai>.

35. Castelnovo A, Crupi R, Greco G, Regoli D, Penco IG, Cosentini AC. A clarification of the nuances in the fairness metrics landscape. *Scientific Reports*. 2022;12(1):4209. Available at: <https://www.nature.com/articles/s41598-022-07939-1>.
36. Holdsworth J, Belcic I, Stryker C. What is model drift? : IBM; 2024. Available at: <https://www.ibm.com/think/topics/model-drift>.
37. AWS. What is Overfitting? : AWS Amazon; 2024. Available at: <https://aws.amazon.com/what-is/overfitting/>.
38. Ahmed MI, Spooner B, Isherwood J, Lane M, Orrock E, Dennison A. A Systematic Review of the Barriers to the Implementation of Artificial Intelligence in Healthcare. *Cureus*. 2023;15(10):e46454. Available at: <https://pmc.ncbi.nlm.nih.gov/articles/PMC10623210>.
39. Adamopoulou E, Moussiades L. An Overview of Chatbot Technology. *Artificial Intelligence Applications and Innovations*; Neos Marmaras, Greece: Springer, Cham; 2020. p. 373-83. Available at: https://link.springer.com/chapter/10.1007/978-3-030-49186-4_31.
40. Kumar Y, Koul A, Singla R, Ijaz MF. Artificial intelligence in disease diagnosis: a systematic literature review, synthesizing framework and future research agenda. *J Ambient Intell Humaniz Comput*. 2023;14(7):8459-86. Available at: <https://link.springer.com/article/10.1007/s12652-021-03612-z>.
41. Mello-Thoms C, Mello CAB. Clinical applications of artificial intelligence in radiology. *Br J Radiol*. 2023;96(1150):20221031. Available at: <https://pubmed.ncbi.nlm.nih.gov/37099398>.
42. Shen J, Zhang CJP, Jiang B, Chen J, Song J, Liu Z, et al. Artificial Intelligence Versus Clinicians in Disease Diagnosis: Systematic Review. *JMIR Med Inform*. 2019;7(3):e10010. Available at: <https://medinform.jmir.org/2019/3/e10010>.
43. Benjamins S, Dhunoo P, Meskó B. The state of artificial intelligence-based FDA-approved medical devices and algorithms: an online database. *npj Digital Medicine*. 2020;3(1):118. Available at: <https://www.nature.com/articles/s41746-020-00324-0>.
44. World Health Organization. Regulatory considerations on artificial intelligence for health: World Health Organization; 2023. Available at: <https://www.who.int/publications/i/item/9789240078871>.
45. Davis S, Zhang J, Lee I, Rezaei M, Greiner R, McAlister FA, et al. Effective hospital readmission prediction models using machine-learned features. *BMC Health Services Research*. 2022;22(1):1415. Available at: <https://bmchealthservres.biomedcentral.com/articles/10.1186/s12913-022-08748-y>.
46. Pall R, Gauthier Y, Auer S, Mowaswes W. Predicting drug shortages using pharmacy data and machine learning. *Health Care Management Science*. 2023;26(3):395-411. Available at: https://ideas.repec.org/a/kap/hcarem/v26y2023i3d10.1007_s10729-022-09627-y.html.

Ek- Bu araç setinde kullanılan terimler sözlüğü

Terim	Tanım
Algoritma	Belirli bir sorunu çözmek veya belirli bir görevi gerçekleştirmek için tasarlanmış ardışık bir prosedür veya kurallar kümesi. Bir girdiyi alan, işleyen ve bir çıktı üreten açık, sonlu bir talimat dizisidir.
Uygulama program arayüzü (API)	Farklı yazılım uygulamalarının birbirleriyle iletişim kurmasını sağlayan bir dizi kılavuz ve protokol. Uygulamaların bilgi istemek ve bilgi alışverişinde bulunmak için kullandıkları yöntemleri ve veri biçimlerini özetleyerek sorunsuz etkileşime olanak tanır. API'ler sıklıkla sistemleri, hizmetleri veya uygulamaları entegre etmek için kullanılır ve veri alma, hizmetleri çağırma ve işlevleri paylaşma gibi görevlerde yardımcı olur.
Yapay zekâ (AI)	Öğrenme, muhakeme, problem çözme ve desen tanıma gibi genellikle insan zekâsı gerektiren görevleri yerine getirebilen sistemler oluşturmaya adanmış bir bilgisayar bilimi dalı.
Yapay genel zekâ (AGI)	İnsan bilişsel yeteneklerine benzer şekilde, geniş bir görev yelpazesinde bilgiyi anlama, öğrenme ve uygulama konusunda insan benzeri yeteneğe sahip bir yapay zekâ türü. AGI yeni zorluklara uyum sağlayabilir, sorunlarla ilgili akıl yürütebilir ve bilgiyi bir alandan diğerine aktarabilir
Yapay farmakoloji zekâsı (API)	Farmakoloji ile ilgili verileri analiz etmek ve yorumlamak için gelişmiş yapay zekâ tekniklerinin kullanımı. İlaç etkileşimleri, ilaç keşfi ve maddelerin biyolojik sistemler üzerindeki etkilerinin anlaşılmasını geliştirmeyi amaçlamaktadır.
Büyük veri	Geleneksel veri yönetim sistemlerinin işleyemeyeceği kadar büyük olan geniş bir veri koleksiyonu. Yapay zekâ, öğrenme ve analizde model verimliliğini artırmak için büyük verileri kullanır.
Veri bilimi	İstatistiksel analiz, veri madenciliği, makine öğrenmesi ve veri görselleştirme gibi çeşitli teknikler yoluyla verilerden içgörü ve bilgi çıkarmaya odaklanan disiplinler arası bir alandır.
Derin öğrenme	Sürekli (gerçek sayı) gösterimleri kullanarak verileri işleyen büyük, çok katmanlı yapay sinir ağlarının kullanımını içerir. Küçük veri kümelerinden gelişmiş genelleme sunar ve büyük veri kümeleri ve bilgi işlem kaynaklarıyla daha verimli bir şekilde ölçeklenir.
Kullanım	Verilere dayalı tahminler ve analizler yapmak amacıyla bir yapay zekâ modelinin üretim ortamına entegre edilmesi süreci.
Üretken yapay zekâ (eczacılık)	Eczacılıkta üretken yapay zekâ, mevcut bilgilere dayalı olarak yeni veriler, çözümler veya içgörüler oluşturabilen gelişmiş yapay zekâ tekniklerinin uygulanması anlamına gelir. Bu teknolojiler, özellikle üretken modeller olmak üzere makine öğrenmesi modellerinden yararlanarak ilaç uygulamalarının ve araştırmalarının çeşitli yönlerini geliştirir.
Büyük dil modeli (LLM)	LLM'ler, insan benzeri metin üretmeye odaklanan belirli bir tür üretken yapay zekâ modelidir. Üretken yapay zekâ, yeni içerik oluşturmak için tasarlanmış geniş bir yapay zekâ tekniği ve model yelpazesini ifade ederken (metin, resim, ses veya video), LLM'ler metin oluşturma konusunda uzmanlaşmıştır.
Makine öğrenimi (ML)	Bilgisayarların deneyim veya veriler aracılığıyla algılarını, bilgilerini, akıl yürütmelerini veya eylemlerini nasıl geliştirebileceklerine odaklanan bir yapay zekâ dalı. Makine öğrenmesi, bilgisayar bilimi, istatistik, psikoloji, sinirbilim, ekonomi ve kontrol teorisi gibi alanlardan kavramları entegre eder.
Doğal dil üretimi (NLG)	Yapılandırılmış verilerden otomatik olarak insan benzeri metin oluşturan sistemler geliştirmeye adanmış bir yapay zekâ dalıdır. NLG, bilgisayarların raporlar, özetler veya yanıtlar dahil olmak üzere doğal dilde yazılı içerik oluşturmaya olanak tanır. Bu süreç, verileri, gerçekleri veya görüşleri tutarlı ve anlamlı cümlelere veya paragraflara dönüştürerek insanların bilgileri anlama ve onlarla etkileşime girme biçimlerini iyileştirir. NLG, sohbet robotları, otomatik raporlama, içerik oluşturma ve kişiselleştirilmiş iletişim gibi alanlarda yaygın olarak uygulanır.

Doğal dil işleme (NLP)	Bilgisayarların insan dilini anlamasını, yorumlamasını ve üretmesini sağlamaya odaklanan bir yapay zekâ alanı. Makinelerin metin veya konuşma verilerini anlamlı ve yararlı bir şekilde işlemesine ve analiz etmesine olanak tanıyan algoritmaların ve modellerin geliştirilmesini içerir.
Sinir ağı	İnsan beyninin yapısından esinlenen bilgisayar modelleri. Katmanlar halinde düzenlenen bu birbirine bağı yapay nöronlar, makine öğrenmesinde tahminler yapmak için verilerden öğrenir ve derin öğrenmeyi destekler.
Komut	Bir kullanıcının belirli bir yanıt almak için bir yapay zekâ modeline sunduğu girdi.
Geri çağırma artırılmış üretim (RAG)	Bilgi çağırmayı metin üretimiyle birleştiren, doğal dil işlemede gelişmiş bir teknik.
Robotik süreç otomasyonu (RPA)	Sabit kurallara ve girdilere dayalı olarak tekrarlayan görevleri otomatikleştirmek için yazılım robotlarını kullanan ve görevleri çoğu zaman insanlardan daha verimli bir şekilde gerçekleştiren rakip bir teknoloji.

Uluslararası

Eczacılık

Federasyonu

Fédération

Internationale

Pharmaceutique

Andries Bickerweg 5

2517 JP Lahey

Hollanda

-

Tel: +31 (0)70 302 19 70

Faks: +31 (0)70 302 19 99

fip@fip.org

-

www.fip.org

03/2025 | An artificial intelligence toolkit for pharmacy



Orijinal raporun bu çevirisi
Türk Eczacıları Birliği
tarafından hazırlanmıştır.

