

Yapay Zekâ ile Hasta Merkezli Bakım ve Klinik Güvenliğin Güçlendirilmesi

Leyla Sezgin¹

Özet

Sağlık hizmetlerinde giderek önem kazanan hasta merkezli bakım ve klinik güvenlik kavramlarını yapay zekâ teknolojileri bağlamında ele almaktadır. Bölümde öncelikle hasta merkezli bakım yaklaşımının temel ilkeleri ile klinik güvenliğin sağlık hizmet kalitesindeki yeri açıklanmakta, ardından yapay zekânın bu alanlardaki dönüştürücü etkisi kuramsal ve uygulamalı yönleriyle değerlendirilmektedir. Özellikle makine öğrenmesi, büyük veri analitiği, doğal dil işleme ve klinik karar destek sistemleri gibi yapay zekâ uygulamalarının kişiselleştirilmiş bakımın geliştirilmesi, klinik risklerin erken belirlenmesi, tıbbi hataların azaltılması ve hasta sonuçlarının iyileştirilmesindeki katkıları incelenmektedir. Akıllı hasta izleme sistemleri, erken uyarı mekanizmaları ve veri temelli karar verme süreçlerinin klinik güvenliği artırmadaki rolü güncel araştırma bulguları doğrultusunda tartışılmaktadır. Yapay zekâ uygulamalarının sağlık sistemlerine entegrasyonu sırasında ortaya çıkan veri gizliliği, etik sorumluluk, algoritmik önyargı, şeffaflık ve insan denetimi gibi etik ve yönetsel sorunlara da kapsamlı biçimde değinilmektedir. Sonuç olarak bölüm, yapay zekânın hasta merkezli bakım ve klinik güvenlik alanlarında sunduğu fırsatları ve karşılaşılan güçlükleri bütüncül bir perspektifle değerlendirerek geleceğin sağlık hizmetlerine ilişkin kapsamlı bir çerçeve sunmaktadır.

1. Giriş

Sağlık hizmetleri tarihsel süreç içerisinde büyük ölçüde hastalık odaklı bir paradigma doğrultusunda şekillenmiş; tanı, tedavi ve bakım uygulamaları çoğunlukla sağlık profesyonellerinin bireysel bilgi, deneyim ve klinik gözlemlerine dayalı olarak yürütülmüştür (van der Woude vd., 2025). Ancak kronik hastalık prevalansındaki artış, nüfusun yaşlanması, sağlık hizmetlerine erişimde yaşanan eşitsizlikler ve tıbbi hatalara bağlı hasta güvenliği sorunlarının giderek daha

1 Öğretim Görevlisi, Muş Alparslan Üniversitesi Varto Gıyasettin Bingöl Meslek Yüksekokulu, leyla.sezgin@alparslan.edu.tr, ORCID ID: 0000-0002-9364-1290

belirgin hâle gelmesi, geleneksel sağlık hizmeti sunum modellerinin yeniden değerlendirilmesini gerekli kılmıştır. Bu bağlamda çağdaş sağlık politikaları ve bakım yaklaşımları, yalnızca hastalığın tedavisine odaklanan geleneksel modellerden uzaklaşarak bireyin fiziksel, psikolojik, sosyal ve duygusal gereksinimlerini merkeze alan hasta merkezli bir anlayışa yönelmiştir (WHO, 2016). Dijital teknolojilerde meydana gelen hızlı ve kapsamlı gelişmeler, sağlık sistemlerinde yapısal ve işlevsel dönüşümleri beraberinde getirmiştir. Yapay zekâ (YZ), algoritmaların veri üzerinden öğrenme yoluyla tahmin, karar ve öneri üretebilmesini sağlayan bir teknoloji olarak tanımlanmaktadır (WHO, 2024; NCBI, 2024). Sağlık hizmetlerinde YZ'nin entegrasyonu; klinik karar destek sistemleri, erken tanı, risk analizi ve kişiselleştirilmiş tıp uygulamaları açısından önemli katkılar sunmaktadır (European Commission, 2024; WHO, 2023). Yapay zekânın alt alanları arasında yer alan makine öğrenmesi, derin öğrenme ve doğal dil işleme teknolojileri; büyük ölçekli ve çok boyutlu klinik veri setlerini analiz ederek anlamlı örüntülerin ortaya çıkarılmasına, hastalık risklerinin tahmin edilmesine ve klinisyenlere kanıta dayalı karar desteği sunulmasına olanak tanımaktadır (Topol, 2019). Bu bağlamda yapay zekâ uygulamaları, sağlık hizmetlerinin etkinliğini, doğruluğunu ve sürdürülebilirliğini artıran yenilikçi teknolojiler arasında değerlendirilmektedir.

1. Hasta Merkezli Bakım ve Klinik Güvenlik Kavramlarının Temelleri

Dünya Sağlık Örgütü (WHO, 2016) hasta merkezli bakımı; bireylerin sağlık hizmetlerine etkin katılımını teşvik eden, onların gereksinim, beklenti ve değerlerine duyarlı, saygılı ve bütüncül bir hizmet sunum modeli olarak tanımlamaktadır. Hasta merkezli bakımın uygulanması; hasta memnuniyetinin artırılması, bakım kalitesinin geliştirilmesi, tedaviye uyumun güçlendirilmesi ve sağlık çıktılarının iyileştirilmesi açısından önemli katkılar sağlamaktadır. Hasta merkezli yaklaşımların hasta memnuniyeti, öz-yönetim becerileri ve tedaviye bağlılık üzerinde anlamlı iyileşmeler oluşturduğunu göstermektedir (Aboumatar vd., 2022). Ayrıca bu yaklaşım, sağlık profesyonelleri ile hastalar arasında güvene dayalı terapötik ilişkinin güçlenmesini destekleyerek iletişim kalitesini artırmakta ve bakım süreçlerinin daha etkili ve sürdürülebilir olmasına katkı sağlamaktadır (Sharkiya, 2023). Klinik güvenlik, sağlık hizmeti sunumu sırasında ortaya çıkabilecek önlenebilir zararların azaltılması, hasta güvenliğini tehdit eden risklerin tanımlanması ve kontrol altına alınması ile bakım süreçlerinin güvenli koşullar altında sürdürülmesini kapsayan temel bir sağlık hizmeti bileşenidir. Güncel yaklaşımlar, klinik güvenliğin yalnızca hata önleme ile sınırlı olmayıp, aynı zamanda sistem düzeyinde risk yönetimi, hasta güvenliği kültürünün geliştirilmesi ve sürekli kalite iyileştirme süreçleri

ile desteklenmesi gerektiğini vurgulamaktadır (WHO, 2021; Slawomirski vd., 2017). Klinik güvenlik yaklaşımı; ilaç hatalarının önlenmesi, enfeksiyon kontrolü, doğru tanı ve tedavi uygulamalarının sağlanması, etkili iletişim süreçlerinin geliştirilmesi ve bakım standartlarının iyileştirilmesi gibi çok boyutlu uygulamaları kapsamaktadır. Bu bağlamda güvenli sağlık hizmeti sunumu, yalnızca bireysel klinik uygulamaların değil, aynı zamanda kurumsal yapıların, teknolojik altyapının ve sağlık politikalarının bütüncül biçimde yönetilmesini gerektirmektedir (WHO, 2021).

1.1. Klinik Güvenlik: Kavramsal Çerçeve

Klinik güvenlik, yalnızca olumsuz olayların önlenmesiyle sınırlı olmayıp; sağlık sistemlerinin dayanıklılığının artırılması, güvenlik kültürünün geliştirilmesi ve sürekli kalite iyileştirme süreçlerinin güçlendirilmesini kapsayan çok boyutlu bir yapı olarak değerlendirilmektedir. Bu çerçevede hasta güvenliğine yönelik uluslararası politika arayışları giderek daha sistematik bir nitelik kazanmış; Dünya Sağlık Örgütü (DSÖ), önlenebilir hasta zararlarının küresel ölçekte azaltılmasını sağlık sistemlerinin temel önceliklerinden biri olarak tanımlamıştır. “Sağlık hizmetlerinde hiç kimsenin zarar görmediği, her hastanın her yerde güvenli ve saygın bakım aldığı bir dünya” vizyonunu benimseyen DSÖ Hasta Güvenliği Küresel Eylem Planı (2021–2030), güvenli bakımın yalnızca klinik yeterliliğin değil; liderlik kapasitesi, sistem tasarımı, insan faktörleri ve veri temelli iyileştirme yaklaşımlarının bütüncül biçimde işletilmesinin bir ürünü olduğunu açıkça ortaya koymaktadır (WHO, 2021). Bu doğrultuda klinik güvenlik, klinik uygulamalar ile örgütsel yapı ve sağlık politikalarının karşılıklı etkileşimi sonucunda şekillenen sistem düzeyli bir çıktı olarak kavramsallaştırılmaktadır. Hasta güvenliğine ilişkin kuramsal literatür incelendiğinde, hata ve zarar olgusunu bireysel sorumluluktan sistem dinamiklerine taşıyan yaklaşımların belirleyici bir yer edindiği görülmektedir. Bu bağlamda Reason (2000) tarafından geliştirilen Savunma Modeli yaygın olarak İsviçre Peyniri Modeli olarak da anılmaktadır tıbbi hataların tek bir ihmal ya da bireysel yetkinlik eksikliğinden kaynaklanmadığını; aksine sistem içindeki birden fazla savunma katmanındaki zafiyetlerin eş zamanlı hizalanmasıyla ortaya çıktığını ileri sürmektedir. Bu model, hasta güvenliği alanında kök neden analizleri başta olmak üzere pek çok güvenlik faaliyetinin kuramsal zeminini oluşturmuş ve sonraki çalışmalar tarafından da kapsamlı biçimde ele alınmıştır (Wiegmann vd., 2022). Modelin hasta güvenliği söylemine katkısı yalnızca kavramsal düzeyde kalmamış; hata odağını bireyden sisteme kaydırması, sağlık kurumlarının güvenlik yaklaşımını köklü biçimde dönüştürmüştür. Benzer bir sistem perspektifini paylaşan Yüksek Güvenilirlik Organizasyonu (High Reliability Organization (HRO)) kuramı ise yüksek riskli ve karmaşık çalışma

ortamlarında güvenliğin nasıl kalıcı kılınabileceği sorusuna odaklanmaktadır. Weick ve Sutcliffe (2007, 2015) tarafından kavramsallaştırılan bu yaklaşım; operasyonlara duyarlılık, basitleştirmeye direnç, başarısızlığa odaklanma, uzmanlığa saygı ve dayanıklılığa bağlılık olmak üzere beş temel ilke üzerine inşa edilmektedir. Söz konusu ilkeler, beklenti ve müdahale şeklinde iki sütun altında ele alınmakta; proaktif risk yönetimi, ekip iletişimi ve öğrenen örgüt kültürünün güvenliğin vazgeçilmez bileşenleri olduğunu vurgulamaktadır (Weick & Sutcliffe, 2007). Güncel sistematik bir incelemede ise HRO ilkelerinin uygulamaya geçirilmesinin hasta güvenliği çıktıları ve çalışan psikolojik güvenliği üzerinde anlamlı iyileşmelerle ilişkilendirildiğini ortaya koymuştur (Morales vd., 2026).

1.2. Hasta Merkezli Bakım ile Klinik Güvenliğin Kesişimi

Hasta merkezli bakım ve klinik güvenlik, sağlık hizmeti kalitesini belirleyen ve birbirini karşılıklı olarak güçlendiren iki temel kavramdır. Güncel yaklaşımlar, hasta merkezli bakımın hastaların karar alma süreçlerine aktif katılımını artırarak daha güvenli, koordineli ve etkili sağlık hizmeti sunumuna katkı sağladığını göstermektedir. Bu yaklaşım; hasta katılımının güçlenmesi yoluyla tedaviye uyumun artırılması, iletişim kaynaklı hataların azaltılması, istenmeyen olayların erken fark edilmesi ve bakım süreçlerinde risk yönetiminin geliştirilmesi açısından önemli katkılar sunmaktadır (WHO, 2021; OECD, 2021). Buna paralel olarak güvenli bakım ortamlarının oluşturulması, hastaların sağlık sistemine olan güvenini artırmakta ve hasta katılımını destekleyerek hasta merkezli bakım uygulamalarının etkinliğini güçlendirmektedir. Bu karşılıklı etkileşim, hasta güvenliği ile hasta katılımının entegre biçimde ele alındığı çağdaş sağlık hizmeti modellerinin önem kazandığını göstermektedir (WHO, 2021).

2. Yapay Zekâ ile Kişiselleştirilmiş Bakım

Kişiselleştirilmiş tıp ya da hassas tıp, bireylerin genetik özellikleri, çevresel faktörleri, yaşam biçimleri ve biyolojik farklılıkları doğrultusunda kişiye özgü tanı, tedavi ve bakım süreçlerinin planlanmasını amaçlayan yenilikçi bir sağlık yaklaşımıdır. Bu yaklaşım, tüm hastalara aynı tedavi modelinin uygulanması yerine bireysel farklılıkların dikkate alınmasını esas almakta ve böylece daha etkili, güvenli ve sürdürülebilir sağlık hizmeti sunumunu hedeflemektedir. Özellikle genomik bilimler, biyoinformatik ve dijital sağlık teknolojilerindeki gelişmeler, hassas tıp uygulamalarının sağlık sistemlerinde giderek daha fazla önem kazanmasına katkı sağlamaktadır (Rajkomar vd. 2019). Yapay zekâ; öğrenme, yorumlama ve karar verme gibi bilişsel süreçlerin bilgisayar sistemleri aracılığıyla modellenmesini ifade etmektedir (Baltacı Yıldız & Şahin, 2024).

YZ tabanlı algoritmalar; genetik veriler, elektronik sağlık kayıtları, görüntüleme sonuçları, laboratuvar bulguları ve yaşam tarzı verileri gibi çok boyutlu ve büyük ölçekli veri kümelerini analiz ederek her bireye özgü risk profilleri oluşturabilmekte ve kişiselleştirilmiş tedavi önerileri geliştirebilmektedir. Geleneksel istatistiksel yöntemlerin analiz etmekte yetersiz kaldığı karmaşık veri yapılarının işlenebilmesi, yapay zekâ destekli sistemlerin klinik karar verme süreçlerinde önemli avantajlar sağlamasına olanak tanımaktadır (Topol, 2019). Bu doğrultuda yapay zekâ uygulamaları; hastalıkların erken tanınması, bireysel risklerin öngörülmesi, uygun tedavi seçeneklerinin belirlenmesi ve bakım süreçlerinin optimize edilmesinde önemli katkılar sunmaktadır. Ayrıca yapay zekâ destekli kişiselleştirilmiş bakım modellerinin, tedavi etkinliğini artırdığı, gereksiz müdahaleleri azalttığı ve hasta sonuçlarının iyileştirilmesine katkı sağladığı belirtilmektedir.

2.1. Genomik Verilerle Entegre Bakım

Yapay zekâ (YZ) tabanlı genomik analizler, hastalık yatkınlıklarının belirlenmesi, ilaç metabolizmasının değerlendirilmesi ve tedaviye yanıtı etkileyen genetik varyantların saptanmasında giderek daha etkili bir araç hâline gelmektedir. Makine öğrenmesi ve derin öğrenme algoritmaları, büyük ölçekli genomik verileri analiz ederek kişiselleştirilmiş tedavi yaklaşımlarının geliştirilmesine katkı sağlamaktadır (Libbrecht & Noble, 2015; Rajkomar vd., 2019). DeepMind tarafından geliştirilen AlphaFold sistemi, protein yapı tahmininde yüksek doğruluk sağlayarak ilaç geliştirme süreçlerini hızlandırmış ve moleküler düzeyde hastalık mekanizmalarının anlaşılmasına önemli katkılar sunmuştur (Jumper vd., 2021; Le Cun vd., 2015). Onkoloji alanında ise YZ destekli sistemler, tümörlerin genetik profillerini analiz ederek bireye özgü kemoterapi ve hedefe yönelik tedavi seçeneklerinin belirlenmesine yardımcı olmaktadır (Kourou vd., 2015; Esteva vd., 2019). Ayrıca klinik çalışmalar, yapay zekâ algoritmalarının kanser tanısı ve tedavi planlamasında sağlık profesyonellerine önemli düzeyde karar desteği sağladığını göstermektedir (Obermeyer & Emanuel, 2016).

2.2. Elektronik Sağlık Kayıtlarından Kişiselleştirilmiş İçgörüler

Elektronik sağlık kayıtları (ESK), hastaların klinik geçmişine, ilaç kullanımına, laboratuvar sonuçlarına ve demografik verilerine ilişkin zengin bir bilgi havuzu sunmaktadır. YZ sistemleri bu veri havuzunu tarayarak bireysel risk faktörlerini belirlemekte ve klinisyenlere önleyici müdahaleler için uyarı üretmektedir. Epic MyChart ve IBM Watson Health gibi platformlar, bu kapsamda klinik pratiğe entegre edilen başarılı uygulamalar arasında yer almaktadır (Rajpurkar vd., 2022).

2.3. Hasta Tercihleri ve Değer Tabanlı Karar Alma

Doğal dil işleme teknolojileri sayesinde YZ sistemleri, hasta görüşmeleri ve anket verilerinden tedavi tercihlerini, değerlerini ve yaşam kalitesi önceliklerini çıkarabilmektedir. Bu yetenek, klinisyenlerin yalnızca klinik verilere değil hastaların öznel deneyimlerine de duyarlı kararlar almasını olanaklı kılmaktadır. Söz konusu yaklaşım, özellikle kronik hastalık yönetimi ve palyatif bakım alanlarında büyük bir potansiyel taşımaktadır (Obermeyer & Emanuel, 2016).

3. Klinik Risklerin Erken Tanınmasında Yapay Zekâ Uygulamaları

Klinik risklerin öngörülmesi ve erken müdahale, hasta sonuçlarının iyileştirilmesinde kritik bir rol oynamaktadır. Geleneksel risk değerlendirme yaklaşımları çoğunlukla sınırlı sayıda değişkeni dikkate almakta ve bu nedenle karmaşık klinik durumların değerlendirilmesinde zaman zaman yetersiz duyarlılık gösterebilmektedir. Buna karşın yapay zekâ (YZ) temelli algoritmalar, geniş ölçekli ve çok değişkenli veri setleri üzerinde eğitilerek klinik veriler arasındaki karmaşık ilişkileri daha yüksek doğrulukla analiz edebilmekte ve risk örüntülerini daha hassas biçimde ortaya koyabilmektedir (Rajkomar vd., 2019; Topol, 2019). Bu özellikleri sayesinde YZ tabanlı sistemler, erken uyarı mekanizmalarının geliştirilmesi ve klinik karar destek süreçlerinin güçlendirilmesinde giderek daha önemli bir rol üstlenmektedir.

3.1. Sepsis ve Akut Klinik Kötüleşmenin Erken Tespiti

Sepsis, dünya genelinde hastane mortalitesinin başlıca nedenleri arasında yer almaya devam etmekte olup, erken tanı ve müdahale hasta sağkalımını belirgin şekilde artıran kritik bir faktördür. Bu bağlamda yapay zekâ (YZ) temelli erken uyarı sistemleri, klinik verilerdeki erken ve ince değişimleri tespit ederek sepsis gelişim riskini geleneksel yöntemlere kıyasla daha erken dönemde öngörebilmektedir. Johns Hopkins Üniversitesi tarafından geliştirilen TREWS (Targeted Real-time Early Warning System) ve elektronik sağlık kayıt sistemlerine entegre edilen Sepsis erken uyarı modelleri, klinik ekiplere zamanında müdahale olanağı sağlayarak tanı sürecini hızlandırmayı amaçlamaktadır (Henry vd., 2015). Güncel çalışmalar, bu tür YZ tabanlı erken uyarı sistemlerinin özellikle yoğun bakım ünitelerinde klinik karar süreçlerine entegre edilmesinin, erken antibiyotik uygulaması gibi müdahaleleri hızlandırarak mortalite oranlarında anlamlı azalma ile ilişkili olabileceğini göstermektedir (Adams vd., 2022; Wong vd., 2021).

3.2. Kardiyovasküler ve Nörolojik Risk Öngörüsü

Derin öğrenme algoritmaları, elektrokardiyografi (EKG) verilerinden atriyal fibrilasyon, kalp yetersizliği ve ani kardiyak ölüm riskini yüksek duyarlılıkla saptayabilmektedir (Hannun vd., 2019). Benzer şekilde YZ destekli beyin görüntüleme analizleri, iskemik inme ve nörodejeneratif hastalıkların prodromal bulgularını klinik semptomların ortaya çıkmasından yıllar önce tespit etme kapasitesine ulaşmaktadır. Bu yetenek, koruyucu tıp stratejilerinin daha etkin biçimde uygulanmasına önemli katkı sağlamaktadır.

3.3. Düşme ve Bası Yarası Riski Tahmininde Yapay Zekâ

Hastane içi düşmeler ve bası yaraları hem hasta güvenliğini tehdit etmekte hem de sağlık hizmet maliyetlerini önemli ölçüde artırmaktadır. Makine öğrenmesi modelleri; yaş, komorbidite, ilaç profili ve hareket kısıtlılığı gibi çok sayıda faktörü birlikte değerlendirerek yüksek riskli hastaları belirlemektedir. Bu doğrultuda uygulanan hedefe yönelik önleyici protokollerin söz konusu olumsuz olayların sıklığını anlamlı biçimde azalttığı bildirilmektedir (Padula vd., 2024; Lee vd., 2024).

4. Klinik Hataların Azaltılmasında Yapay Zekâ Uygulamaları

Tıbbi hatalar; ilaç hataları, tanı hataları ve cerrahi komplikasyonlar gibi farklı kategorilerde ele alınmakta olup, dünya genelinde önemli düzeyde morbidite ve mortaliteye yol açmaktadır. Güncel literatür, yapay zekâ (YZ) uygulamalarının bu hata türlerinin her birinde riskleri azaltma potansiyeline sahip olduğunu göstermektedir. Özellikle klinik karar destek sistemleri, ilaç etkileşim analizleri, görüntüleme temelli tanı algoritmaları ve cerrahi robotik sistemler; hata olasılığını azaltarak klinik süreçlerin daha güvenli hale gelmesine katkı sağlamaktadır (Topol, 2019; Obermeyer & Emanuel, 2016)

4.1. İlaç Güvenliği ve Hata Önleme

İlaç hataları, önlenebilir hasta zararlarının önde gelen kaynakları arasında yer almaktadır. YZ destekli ilaç kontrol sistemleri, elektronik reçete yazma sürecinde ilaç etkileşimlerini, doz aşımalarını ve hasta alerjilerini gerçek zamanlı olarak analiz etmekte; klinisyeni hatalı reçeteye karşı uyarmaktadır. İlgili sistemlerin ilaç hatalarını %50'ye varan oranlarda azalttığı rapor edilmektedir (Nuckols vd., 2014).

4.2. Tanısal Hata Azaltma

Tanısal hatalar sağlık sistemleri için ciddi bir sorun oluşturmakta; tanı gecikmesi ya da yanlış tanı biçiminde ortaya çıkmaktadır. YZ tabanlı görüntü

analiz sistemleri, radyolojik ve patolojik incelemelerde insan gözünün gözden kaçırabileceği ince bulguları tespit edebilmektedir. Google Health tarafından geliştirilen derin öğrenme modeli, meme kanseri tarama mamografilerinde yanlış negatif oranlarını radyologlara kıyasla belirgin biçimde düşürmüştür (McKinney vd., 2020). Dermatoloji alanında da YZ algoritmalarının cilt lezyonu sınıflandırmasında uzman dermatologlarla rekabet edebilir düzeye ulaştığı gösterilmiştir.

4.3. Cerrahi Hata Önleme

Robotik cerrahi sistemleri ile ameliyat öncesi, sırası ve sonrasında süreçleri izleyen YZ algoritmaları, cerrahi komplikasyon riskini azaltmada önemli adımlar atmıştır. Bilgisayar destekli ameliyat planlama araçları; anatomik varyasyonları görselleştirmekte, kritik yapıların hasar görme riskini saptamakta ve ameliyat öncesi simülasyonlara olanak tanımaktadır. Bu teknolojilerin laparoskopik prosedürler başta olmak üzere çeşitli cerrahi alanlarda komplikasyon oranlarını düşürdüğü bildirilmektedir (Maier-Hein vd., 2017).

5. Klinik Karar Almada Yapay Zekâ Uygulamaları

Klinik karar verme süreci, yüksek düzeyde karmaşıklık, belirsizlik ve zaman baskısı altında yürütülen çok boyutlu bir bilişsel süreçtir. Bu bağlamda yapay zekâ (YZ), klinik karar alma süreçlerine iki temel düzeyde katkı sunmaktadır. Birincisi büyük ölçekli ve heterojen veri setleri üzerinden örüntü tanıma ve tahmin kapasitesi sağlayarak klinik bilgi üretimini desteklemek, ikincisi klinisyenlerin karar verme süreçlerinde ortaya çıkabilen bilişsel önyargıların ve insan kaynaklı sınırlılıkların etkisini azaltmak. Bu yönüyle YZ tabanlı sistemler, klinik karar destek mekanizmalarının güçlendirilmesine ve daha tutarlı, veri temelli kararların alınmasına katkı sağlamaktadır (Topol, 2019; Rajkomar vd., 2019).

5.1. Klinik Karar Destek Sistemleri

Klinik Karar Destek Sistemleri, kanıta dayalı kılavuzları gerçek zamanlı hasta verileriyle ilişkilendirerek klinisyenlere eylem önerisi sunan yazılım tabanlı araçlardır. Modern YZ destekli Klinik Karar Destek Sistemler, kural tabanlı eski nesil sistemlerin ötesine geçerek makine öğrenmesi ve büyük veri analitiğini entegre etmektedir. Bu sistemlerin; antibiyotik reçeteleme pratiklerini geliştirdiği, gereksiz tetkik isteklerini azalttığı ve kılavuz uyumunu artırdığı kapsamlı çalışmalarla ortaya konmuştur (Sutton vd., 2020; Hatton vd., 2025).

5.2. Bilişsel Önyargıların Azaltılması

Klinisyenler teşhis sürecinde tutarlılık önyargısı, temsil önyargısı ve aşırı güven gibi bilişsel tuzaklara düşebilmektedir. YZ sistemleri, klinisyenin başlangıç değerlendirmesinden bağımsız olarak verileri nesnel biçimde analiz etmekte ve alternatif tanı olasılıklarını gündeme getirerek bilişsel kapanmayı önlemektedir. Yapılan araştırmalar bu yaklaşımın teşhis doğruluğunu anlamlı ölçüde artırdığını göstermektedir (Khullar vd., 2015; Jeong & Kim, 2026).

5.3. Etik Boyutlar ve İnsan-Makine İş Birliği

Yapay zekânın klinik karar alma süreçlerine entegrasyonu, teknik ilerlemenin ötesinde köklü etik soruları da gündeme getirmektedir. Bu sorulardan ilki sorumluluk meselesidir: bir YZ sisteminin önerisine dayanan hatalı bir klinik kararda hukuki ve mesleki sorumluluğun klinisyene, yazılım geliştiricisine yoksa kurumun kendisine mi ait olduğu henüz net biçimde tanımlanmamıştır. İkincisi, şeffaflık ve açıklanabilirlik sorunudur; özellikle derin öğrenme tabanlı modellerin “kara kutu” niteliği, klinisyenlerin algoritmik önerilerin arkasındaki mantığı hastalarına ve hukuki süreçlere açıklayabilmesini zorlaştırmaktadır. Üçüncüsü ise algoritmik önyargının dezavantajlı gruplar üzerindeki etkisidir; eğitim verilerinde yetersiz temsil edilen popülasyonlar söz konusu olduğunda, YZ sistemleri mevcut sağlık eşitsizliklerini azaltmak yerine pekiştirme riski taşımaktadır. Bu üç boyut sorumluluk, şeffaflık ve adalet YZ’nin klinik pratikte güvenli ve adil biçimde kullanılabilmesi için titizlikle ele alınması gereken birbirine bağlı sorunlar olarak literatürde tanımlanmaktadır (Topol, 2019).

6. Yapay Zekâ Destekli Veri Analizi ve Klinik Karar Süreçleri

Sağlık verisinin hacmi, çeşitliliği ve üretim hızındaki artış, geleneksel analitik yöntemlerin veri işleme ve anlamlandırma kapasitesini giderek zorlamaktadır. Bu bağlamda yapay zekâ (YZ) tabanlı büyük veri analitiği, heterojen ve yüksek boyutlu sağlık verilerinin etkin biçimde işlenmesi, örüntülerin ortaya çıkarılması ve klinik karar süreçlerine dönüştürülmesi açısından en güçlü ve umut vadeden yaklaşımlardan biri olarak öne çıkmaktadır. Güncel literatür, YZ destekli veri analitiğinin erken risk tespiti, klinik karar desteği ve sağlık hizmetlerinde öngörülebilirliğin artırılması gibi alanlarda önemli katkılar sunduğunu göstermektedir (Rajkomar vd., 2019; Topol, 2019).

6.1. Büyük Veri ve Sağlık Analitiği

Sağlık verisi; yapılandırılmış (laboratuvar sonuçları, tanı kodları), yarı yapılandırılmış (klinik notlar) ve yapılandırılmamış (radyoloji görüntüleri, patoloji slaytları) kategorilerinde küresel ölçekte katlanarak büyümektedir.

Makine öğrenmesi algoritmaları bu heterojen veri havuzunu tarayarak hasta popülasyonlarındaki gizli kalıpları, risk kümelerini ve tedavi yanıt örüntülerini ortaya çıkarabilmektedir. Bu sayede popülasyon düzeyinde koruyucu halk sağlığı müdahaleleri ile bireysel klinik protokoller eş zamanlı olarak optimize edilebilmektedir (Obermeyer & Emanuel, 2016).

6.2. Gerçek Dünya Verisi ve Kanıta Dayalı Tıp

Randomize kontrollü çalışmalar (RKÇ), iç geçerliliği yüksek, nedensellik ilişkilerini güvenilir biçimde test edebilen bir araştırma tasarımı olması nedeniyle kanıta dayalı tıpta altın standart kabul edilmektedir. Bununla birlikte, RKÇ'lerin getirdiği sıkı dahil etme ve dışlama kriterleri, sınırlı örneklem büyüklükleri ile yüksek zaman ve maliyet gereksinimleri, bu tasarımın kapsamını ve dış geçerliliğini önemli ölçüde sınırlandırmaktadır. Yapay zekâ destekli gerçek dünya verisi analizleri, bu metodolojik boşluğu tamamlayıcı bir kanıt kaynağı olarak doldurmakta; tedavilerin gerçek klinik ortamlardaki, daha büyük ve heterojen hasta popülasyonlarındaki etkinlik ve güvenlik profiline ilişkin daha kapsamlı ve klinik pratiğe daha yakın kanıtlar üretmektedir. Bu yaklaşım, özellikle nadir hastalıklar ve çoklu komorbiditeye sahip yaşlı hastalar gibi, düşük prevalans, heterojen klinik tablo veya sıkı dışlama kriterleri nedeniyle RKÇ'lere yeterli düzeyde katılımın güç olduğu hasta gruplarında büyük değer taşımaktadır (Blonde vd., 2018).

6.3. Tahmine Dayalı Analitik ve Proaktif Bakım

Tahmine dayalı analitik; hastane yeniden yatışlarını, acil servis başvurularını ve hastalık kötüleşmelerini öngörerek sağlık sistemlerinin reaktif değil proaktif bir tutum benimsemesine olanak tanımaktadır. Diyabet hastalarının HbA1c kontrolünü, kalp yetersizliği hastalarının dekompanseasyon olasılığını ya da kronik obstrüktif akciğer hastalığı (KOAH) olan hastaların alevlenme riskini önceden tahmin eden modeller geliştirilmiş ve bunların gereksiz hastane yatışlarını belirgin biçimde azalttığı gösterilmiştir (Rajpurkar vd., 2022).

7. Hasta İzleme ve Erken Uyarı Sistemlerinde Yapay Zekâ Kullanımı

Sürekli hasta izleme ve erken uyarı sistemleri, klinik güvenliğin önemli bileşenlerindendir. Ancak geleneksel eşik temelli alarm sistemleri sıklıkla “alarm yorgunluğuna” yol açarak klinik etkinliği azaltabilmektedir. Yapay zekâ tabanlı yaklaşımlar ise çok değişkenli veriyi analiz ederek bağlama duyarlı ve daha doğru risk değerlendirmesi sunan akıllı erken uyarı sistemleri geliştirme potansiyeline sahiptir (Zhu et al., 2025).

7.1. Giyilebilir Teknolojiler ve Sürekli Biyometrik İzleme

Akıllı saatler, biyosensörler ve implante edilebilir cihazlar gibi giyilebilir teknolojiler; kalp atım hızı, kan oksijen saturasyonu, kan basıncı ve uyku kalitesi gibi parametreleri kesintisiz olarak kaydetmektedir. YZ algoritmaları bu akış verilerini gerçek zamanlı analiz ederek bireysel biyometrik referans değerlerini öğrenmekte ve sapma noktalarında anlamlı uyarılar üretmektedir. Atrial fibrilasyon tespiti, kan şekeri değişkenlik örüntüsü ve nöbet öncüsü aktivite kalıplarının tanımlanması bu teknolojinin klinik uygulamalarına örnek gösterilebilir (Rajpurkar vd., 2022).

7.2. Erken Uyarı Puanlama Sistemleri

National Early Warning Score (NEWS) gibi geleneksel erken uyarı sistemleri belirli eşik değerlerin aşılması durumunda alarm üretmektedir; ancak bu yaklaşım hem yüksek yanlış alarm oranına hem de geç algılama riskine yol açmaktadır. YZ tabanlı erken uyarı modelleri ise hemodinamik, laboratuvar ve klinik parametreleri dinamik olarak bütünleştirerek klinisyenler için bireyselleştirilmiş uyarı eşikleri belirleyebilmektedir. Yapılan çalışmalar, YZ tabanlı sistemlerin geleneksel yöntemlere kıyasla yoğun bakım transferi ve mortaliteyi öngörmede daha üstün bir performans sergilediğini ortaya koymaktadır (Churpek vd., 2016).

7.3. Uzaktan Hasta İzleme ve Telesaglık

YZ destekli uzaktan izleme sistemlerinin klinik değerini sağlığı koruma ve geliştirme açısından açıkça gözler önüne sermiştir. Bu sistemler özellikle kronik hastalık yönetimi ve taburculuk sonrası takipte belirleyici bir rol üstlenmektedir. Video tabanlı görüşmeleri analiz ederek psikolojik durumu değerlendiren ya da solunum parametrelerini akıllı telefonun mikrofonu aracılığıyla izleyen YZ uygulamaları, bu alandaki yenilikçi gelişmelere örnek oluşturmaktadır (Shaik vd., 2023). Yapay zekâ destekli dijital sağlık sistemlerinin veri analizi, klinik değerlendirme ve bakım süreçlerinin izlenmesinde sağlık profesyonellerine önemli katkılar sunduğu belirtilmektedir (Baltacı Yıldız & Şahin, 2024; Baltacı Yıldız, 2025).

8. Hasta Sonuçlarının İyileştirilmesinde Yapay Zekânın Rolü

YZ uygulamalarının nihai hedefi; klinik süreçleri iyileştirmenin ötesine geçerek somut ve ölçülebilir hasta sonuçları üzerinde olumlu bir etki yaratmaktır. Bu etki; klinik sonuçlar, işlevsel durum, yaşam kalitesi ve hasta deneyimini kapsayan çok boyutlu bir perspektiften değerlendirilmelidir (Topol, 2019; Rossi & Rehman, 2025). Yapay zekâ destekli sistemlerin, büyük veri analitiği

ve klinik karar destek mekanizmaları aracılığıyla bireyselleştirilmiş bakım süreçlerinin geliştirilmesine, erken risk belirlemeye ve hasta sonuçlarının iyileştirilmesine katkı sağladığı bildirilmektedir (Baltacı Yıldız & Şahin, 2024).

8.1. Klinik Sonuçların İyileştirilmesi

Mevcut kanıtlar, iyi tasarlanmış YZ uygulamalarının mortalite, morbidite ve komplikasyon oranlarını anlamlı ölçüde düşürebildiğini göstermektedir. YZ destekli sepsis erken tanı sistemlerinin hastane içi ölüm oranlarını yaklaşık %18 oranında azalttığı bildirilmektedir (Henry vd., 2015).

8.2. Hasta Deneyimi ve Memnuniyeti

YZ uygulamaları yalnızca klinik sonuçları değil, hasta deneyimini de olumlu yönde dönüştürmektedir. YZ destekli hasta iletişim araçları; bilgi paylaşımını kişiselleştirmekte, bekleme sürelerini kısaltmakta ve taburculuk sonrası takibi kolaylaştırmaktadır. Sohbet robotları ve sanal sağlık asistanları aracılığıyla hastalar; ilaç hatırlatmaları, semptom takibi ve sağlık okuryazarlığı geliştirme konularında sürekli destek alabilmektedir. Bu müdahalelerin hasta memnuniyetini ve tedaviye uyumu güçlendirdiği çeşitli çalışmalarla doğrulanmıştır (Kumar, 2023).

8.3. Sağlıkta Eşitsizliklerin Azaltılması

YZ, sağlık hizmetlerine erişimdeki coğrafi ve sosyoekonomik eşitsizlikleri gidermede önemli bir işlev üstlenebilmektedir. Telesağlık ile YZ'nin birleşimi, uzak bölgelerde yaşayan ve uzman hizmetlere erişimde güçlük çeken hastalara yüksek kaliteli klinik karar desteği sunabilmektedir. Öte yandan algoritmaların mevcut sağlık eşitsizliklerini yeniden üretme riski de göz ardı edilmemelidir; bu nedenle YZ modellerinin eğitiminde çeşitli ve temsil edici veri setlerinin kullanılması zorunludur (Obermeyer vd., 2019).

8.4. Zorluklar ve Gelecek Perspektifleri

YZ'nin sağlık alanındaki dönüştürücü potansiyeline karşın aşılması gereken önemli engeller bulunmaktadır. Veri gizliliği ve güvenliği, algoritmaların açıklanabilirliği, düzenleyici onay süreçleri, klinik iş akışına entegrasyon güçlükleri ve sağlık profesyonellerinin mesleki değişime direnç göstermesi bu engellerin başında gelmektedir. Geleceğe bakıldığında; çok merkezli veri paylaşımını destekleyen federatif öğrenme modelleri, klinisyen-algoritma iş birliğine dayalı insan-YZ hibrit sistemleri ve sürekli güncellenen gerçek zamanlı öğrenme platformları en umut verici teknolojik yönelimler olarak öne çıkmaktadır (Rossi & Rehman, 2025).

9. Sonuç

Yapay zekâ, hasta merkezli bakım ve klinik güvenlik alanlarında köklü dönüşümlerin kapılarını aralarken beraberinde yeni sorumluluklar da getirmektedir. Kişiselleştirilmiş bakımdan erken risk tespiti, hata önlemeden karar desteğine ve hasta sonuçlarının iyileştirilmesine uzanan geniş bir yelpazede YZ uygulamaları güçlü bir kanıt temeli oluşturmaktadır. Ancak bu teknolojilerin sağlık sistemlerine başarılı entegrasyonu; teknik yetkinliğin yanı sıra etik duyarlılık, eşitlik bilinci ve paydaş katılımını da gerektirmektedir.

Sağlık profesyonelleri, araştırmacılar, politika yapıcılar ve hasta temsilcilerinin ortak çalışmasıyla şekillendirilecek bir YZ ekosistemi, teknolojiyi insan sağlığının gerçek anlamda hizmetine sokacak en sağlam zemini oluşturmaktadır. Bu bölümde ele alınan kavramsal ve uygulamalı bilgilerin; sağlık profesyonellerinin YZ okuryazarlığını geliştirmelerine ve kanıta dayalı, etik ve hasta odaklı bir YZ benimseme kültürünün oluşmasına katkıda bulunması beklenmektedir.

Kaynaklar

- Aboumatar, H., Pitts, S., Sharma, R., Das, A., Smith, B. M., Day, J., ... & Bennett, W. L. (2022). Patient engagement strategies for adults with chronic conditions: an evidence map. *Systematic reviews*, 11(1), 39.
- Adams, R., Henry, K. E., Sridharan, A., Soleimani, H., Zhan, A., Rawat, N., ... & Saria, S. (2022). Prospective, multi-site study of patient outcomes after implementation of the TREWS machine learning-based early warning system for sepsis. *Nature medicine*, 28(7), 1455-1460.
- Baltacı Yıldız, E. A. (2025). Yapay zekâ destekli görme tarama sistemlerinde hemşire ve optisyenin rolü. In M. Toptan (Ed.), *Göz hastalıkları alanında uluslararası araştırmalar-I* (ss. 31–54). Eğitim Yayınevi.
- Baltacı Yıldız, E. A., & Şahin, A. (2024). Kadın sağlığında yapay zekâ uygulamaları. In T. Çavuşoğlu & A. Gökhan (Eds.), *Sağlık bilimleri alanında uluslararası araştırmalar V* (ss. 43–60). Eğitim Yayınevi.
- Blonde, L., Khunti, K., Harris, S. B., Meizinger, C., & Skolnik, N. S. (2018). Interpretation and impact of real-world clinical data for the practicing clinician. *Advances in Therapy*, 35(11), 1763–1774. <https://doi.org/10.1007/s12325-018-0805-y>
- Churpek, M. M., Yuen, T. C., Winslow, C., Meltzer, D. O., Kattan, M. W. ve Edelson, D. P. (2016). Multicenter comparison of machine learning methods and conventional regression for predicting clinical deterioration on the wards. *Critical Care Medicine*, 44(2), 368-374. <https://doi.org/10.1097/CCM.0000000000001571>
- Esteva, A., Robicquet, A., Ramsundar, B., vd. (2019). *A guide to deep learning in healthcare*. *Nature Medicine*, 25(1), 24–29.
- European Commission. (2024). Artificial intelligence in healthcare. https://health.ec.europa.eu/ehealth-digital-health-and-care/artificial-intelligence-healthcare_en
- Hannun, A. Y., Rajpurkar, P., Haghpanahi, M., Tison, G. H., Bourn, C., Turakhia, M. P. ve Ng, A. Y. (2019). Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature Medicine*, 25(1), 65-69. <https://doi.org/10.1038/s41591-018-0268-3>
- Hatton, C., Quarton, S., Livesey, A., Alenazi, B. A., Jeff, C., & Sapey, E. (2025). Impact of clinical decision support software on empirical antibiotic prescribing and patient outcomes: A systematic review and meta-analysis. *BMJ Open*, 15(11), e099100. <https://doi.org/10.1136/bmjopen-2025-099100>
- Henry, K. E., Hager, D. N., Pronovost, P. J. ve Saria, S. (2015). A targeted real-time early warning score (TREWScore) for septic shock. *Science Translational Medicine*, 7(299), 299ra122. <https://doi.org/10.1126/scitranslmed.aab3719>

- Jeong, M.-A., & Kim, S.-D. (2026). Impact of AI-based clinical decision support systems on diagnostic accuracy among healthcare professionals: A systematic review and meta-analysis of randomized controlled trials. *Applied Sciences*, 16(10), 5146. <https://doi.org/10.3390/app16105146>
- Jumper, J., Evans, R., Pritzel, A., Green, T., Figurnov, M., Ronneberger, O. ve Hassabis, D. (2021). Highly accurate protein structure prediction with AlphaFold. *Nature*, 596(7873), 583-589. <https://doi.org/10.1038/s41586-021-03819-2>
- Khullar, D., Jha, A. K. ve Jena, A. B. (2015). Reducing diagnostic errors — why now? *New England Journal of Medicine*, 373(26), 2491-2493. <https://doi.org/10.1056/NEJMp1508044>
- Kourou, K., Exarchos, T. P., Exarchos, K. P., vd. (2015). *Machine learning applications in cancer prognosis and prediction*. Computational and Structural Biotechnology Journal, 13, 8–17.
- Kumar, M. (2023). AI-driven healthcare chatbots: Enhancing access to medical information and lowering healthcare costs. *Journal of Artificial Intelligence & Cloud Computing*, 2(4), 1–5.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). *Deep learning*. *Nature*, 521, 436–444.
- Lee, J. H., Kim, H., & colleagues. (2024). Development of a pressure injury machine learning prediction model and integration into a clinical decision support system. *Korean Journal of Adult Nursing*, 36(3), 191–203.
- Libbrecht, M. W., & Noble, W. S. (2015). *Machine learning applications in genetics and genomics*. *Nature Reviews Genetics*, 16(6), 321–332.
- Maier-Hein, L., Vedula, S. S., Speidel, S., Navab, N., Kikinis, R., Park, A. ve Jannin, P. (2017). Surgical data science for next-generation interventions. *Nature Biomedical Engineering*, 1(9), 691-696. <https://doi.org/10.1038/s41551-017-0132-7>
- McKinney, S. M., Sieniek, M., Godbole, V., Godwin, J., Antropova, N., Ashrafian, H. ve Shetty, S. (2020). International evaluation of an AI system for breast cancer screening. *Nature*, 577(7788), 89-94. <https://doi.org/10.1038/s41586-019-1799-6>
- Morales, M. J. G., Hilton, P., Hong, O., Bialous, S., Martin, M., Sewnath, J., & Lee, S.-J. (2026). High reliability organizations and healthcare safety outcomes on patients and staff: Scoping review. *PLOS Global Public Health*.
- Nuckols, T. K., Smith-Spangler, C., Morton, S. C., Asch, S. M., Patel, V. M., Anderson, L. J. ve Shanman, R. M. (2014). The effectiveness of computerized order entry at reducing preventable adverse drug events and medication errors in hospital settings: A systematic review and meta-analysis. *Systematic Reviews*, 3(56). <https://doi.org/10.1186/2046-4053-3-56>

- Obermeyer, Z. & Emanuel, E. J. (2016). Predicting the future — big data, machine learning, and clinical medicine. *New England Journal of Medicine*, 375(13), 1216-1219. <https://doi.org/10.1056/NEJMp1606181>
- Obermeyer, Z., Powers, B., Vogeli, C. ve Mullainathan, S. (2019). Dissecting racial bias in an algorithm used to manage the health of populations. *Science*, 366(6464), 447-453. <https://doi.org/10.1126/science.aax2342>
- OECD. (2021). Patient-Reported Indicators Surveys (PaRIS) initiative. <https://www.oecd.org/health/paris/>
- Padula, W. V., Armstrong, D. G., Pronovost, P. J., & Saria, S. (2024). Predicting pressure injury risk in hospitalised patients using machine learning with electronic health records: A US multilevel cohort study. *BMJ Open*, 14(4), e082540. <https://doi.org/10.1136/bmjopen-2023-082540>
- Rajkomar, A., Dean, J., & Kohane, I. (2019). Machine learning in medicine. *New England Journal of Medicine*, 380(14), 1347-1358.
- Rajpurkar, P., Chen, E., Banerjee, O. ve Topol, E. J. (2022). AI in health and medicine. *Nature Medicine*, 28(1), 31-38. <https://doi.org/10.1038/s41591-021-01614-0>
- Reason, J. (2000). Human error: Models and management. *BMJ*, 320(7237), 768-770. <https://doi.org/10.1136/bmj.320.7237.768>
- Rossi, M., & Rehman, S. (2025). Integrating artificial intelligence into telemedicine: Evidence, challenges, and future directions. *Cureus*, 17(6), e90829. <https://doi.org/10.7759/cureus.90829>
- Slawomirski, L., Auraaen, A., & Klazinga, N. (2017). The economics of patient safety. Paris: Organisation for Economic Co-operation and Development.
- Shaik, T., Tao, X., Higgins, N., Li, L., Gururajan, R., Zhou, X., & Acharya, U. R. (2023). Remote patient monitoring using artificial intelligence: Current state, applications, and challenges. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 13(2), e1485. <https://doi.org/10.1002/widm.1485>
- Sharkiyya, S. H. (2023). Quality communication can improve patient-centred health outcomes among older patients: a rapid review. *BMC health services research*, 23(1), 886.
- Sharma, A. E., Rivadeneira, N. A., Barr-Walker, J., Stern, R. J., Johnson, A. K., & Sarkar, U. (2018). Patient engagement in health care safety: an overview of mixed-quality evidence. *Health affairs*, 37(11), 1813-1820.
- Sutton, R. T., Pincock, D., Baumgart, D. C., Sadowski, D. C., Fedorak, R. N. ve Kroeker, K. I. (2020). An overview of clinical decision support systems: Benefits, risks, and strategies for success. *npj Digital Medicine*, 3(1), 17. <https://doi.org/10.1038/s41746-020-0221-y>
- Şahin, A., & Sezgin, L. (2025). Kadın sağlığı ve hemşirelik uygulamalarında etik ikilemler: Karar verme süreçleri ve uygulama zorlukları. In Ü. Sevil (Ed.),

- Hasta bakımında mükemmellik: Hemşirelik için klinik uygulamalar ve etik ikileler (ss. 123–139). Güven Plus Grup Yayıncılık.
- Topol, E. J. (2019). High-performance medicine: The convergence of human and artificial intelligence. *Nature Medicine*, 25(1), 44-56. <https://doi.org/10.1038/s41591-018-0300-7>
- van der Woude, L. A., Welker, G. A., Brand, P. L., & Festen, S. (2025). Barriers to implementing shared decision-making in postgraduate medical education: The role of disease-centered beliefs. *Perspectives on Medical Education*, 14(1), 436.
- Wiegmann, D. A., Wood, L. J., Cohen, T. N., & Shappell, S. A. (2022). Understanding the “Swiss cheese model” and its application to patient safety. *Journal of Patient Safety*, 18(2), 119–123. <https://doi.org/10.1097/PTS.0000000000000810>
- Weick, K. E., & Sutcliffe, K. M. (2007). *Managing the unexpected: Resilient performance in the age of uncertainty* (2nd ed.). Jossey-Bass.
- Weick, K. E., & Sutcliffe, K. M. (2015). *Managing the unexpected: Sustained performance in a complex world* (3rd ed.). Wiley.
- Wong, A., Otles, E., & Donnelly, J. P. (2021). External validation of a widely implemented proprietary sepsis prediction model in hospitalized patients (vol 181, pg 1065, 2021). *JAMA INTERNAL MEDICINE*, 181(8), 1144-1144.
- World Health Organization. (2024). Artificial intelligence for health. <https://www.who.int/publications/m/item/artificial-intelligence-for-health>
- World Health Organization (WHO). (2016). *Framework on integrated, people-centred health services*. WHO Press. <https://www.who.int/teams/integrated-health-services/clinical-services-and-systems/people-centred-care>
- World Health Organization. (2021). Global patient safety action plan 2021-2030: Towards eliminating avoidable harm in health care. WHO. <https://www.who.int/teams/integrated-health-services/patient-safety/policy/global-patient-safety-action-plan>
- World Health Organization. (2023–2024). Harnessing artificial intelligence for health. <https://www.who.int/teams/digital-health-and-innovation/harnessing-artificial-intelligence-for-health>
- Zhu, L., Wei, S., An, Y., Hu, W., & Xie, X. (2025). Mechanism, contributing factors, and coping strategies of alarm fatigue in intensive care nursing: A qualitative study. *Frontiers in Public Health*, 13, 1654389.

