Arşiv Kaynak Tarama Dergisi
Archives Medical Review Journal

DERLEME/REVIEW

Yoğun Bakımda Yapay Zekâ Uygulamaları: Güncel Durum ve Yenilikçi Yaklaşımlar

Artificial Intelligence Applications in Intensive Care: Current State and Innovative Perspectives

Kadir Kabahasanoğlu[1], Muammer Hayri Bektaş[1]

[1]Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi, Anesteziyoloji ve Reanimasyon Anabilim Dalı, Balıkesir, Türkiye

ABSTRACT

Artificial intelligence (AI) and machine learning techniques hold great promise for intensive care units (ICUs) by extracting clinically relevant patterns from high-volume, multimodal data that may elude human observation. Deep learning algorithms already outperform clinicians in the rapid, objective detection of infiltrates, oedema, pneumonia and haemorrhage on chest radiographs, thoracic computed tomography (CT) and trauma head CT, and are poised to extend to real-time ultrasound interpretation. Early warning systems that continuously analyse vital-sign streams can predict hypotension, cardiorespiratory instability and sepsis hours in advance, surpassing established scoring systems for predicting hospital mortality. Unsupervised clustering and classification have begun to dissect heterogeneous syndromes such as sepsis and acute respiratory distress syndrome (ARDS) into biologically and clinically distinct sub-phenotypes, paving the way for precision therapeutics. Reinforcement learning frameworks are emerging that dynamically optimise fluid–vasopressor management and ventilator settings, creating AI–clinician hybrids for patient-specific decision-making. Nevertheless, inadequate data standardisation and sharing restrict external validity, while biases in observational datasets and the opacity of "black-box" models erode clinical confidence. Ethical and legal frameworks remain unsettled regarding algorithmic fairness, accountability and patient privacy. Future priorities include secure multicentre data ecosystems, interpretable and prospectively validated models, smart user interfaces that mitigate alarm fatigue, digital-twin simulations and a workforce proficient in AI literacy. Ultimately, AI will not supplant human expertise but, when thoughtfully integrated, will augment clinical decision-making to deliver faster, more personalised and evidence-based critical-care services.

Keywords: Intensive care, artificial intelligence, machine learning, clinical decision support systems, personalised therapy

ÖZET

Yoğun bakım ünitelerinde (YBÜ) yapay zekâ (YZ) ve makine öğrenimi tabanlı yaklaşımlar, yüksek hacimli çok modlu veriden klinisyenin gözden kaçırabileceği örüntüleri ortaya çıkarmaya olanak tanıyarak erken tanı, risk öngörüsü ve tedavi optimizasyonu için umut vaat etmektedir. Derin öğrenme algoritmaları akciğer grafisi, toraks-bilgisayarlı tomografi (BT) ve travma beyin BT'sinde infiltrat, ödem, pnömoni veya kanama gibi bulguları insan gözleminden daha hızlı ve objektif saptayabilmekte; gerçek zamanlı ultrason analizi gibi alanlara da genişleme potansiyeli göstermektedir. Sürekli vital bulgulara dayanan erken uyarı sistemleri, hipotansiyon, kardiyorespiratuvar instabilite veya sepsis gelişimini saatler öncesinden yüksek doğrulukla tahmin edebilmekte, hastane mortalitesi öngörüsünde geleneksel skorlama sistemlerini aşmaktadır. Kümelenme ve sınıflandırma yöntemleri, sepsis ve akut solunum sıkıntısı sendromu (ARDS) gibi heterojen sendromları biyolojik ve klinik alt fenotiplere ayırarak kişiselleştirilmiş tedavi olasılığını artırmıştır. Pekiştirmeli öğrenme ise sıvı-vazopresör yönetimi ve mekanik ventilatör ayarlarını dinamik olarak optimize eden "YZ-klinisyeni" modelleriyle hasta bazlı kararlara rehberlik edebilmektedir. Bununla birlikte, veri standardizasyonu ve paylaşımındaki yetersizlik, algoritmaların farklı merkezlere genellenebilirliğini sınırlamakta; gözlemsel verideki yanlılıklar ve "kara kutu" modellerin açıklanamazlığı klinik güveni zedelemektedir. Etik ve yasal çerçeveler, algoritmik adalet, sorumluluk paylaşımı ve hasta gizliliği konularında hâlen netleşmemiştir. Geleceğin odak noktaları; güvenli çok merkezli veri ekosistemleri, yorumlanabilir ve prospektif olarak doğrulanmış modeller, alarm yorgunluğunu azaltan akıllı arayüzler, dijital ikiz simülasyonları ve YZ okuryazarlığı yüksek sağlık profesyonelleridir. Sonuç olarak, YZ insan

Correspondence Address / Yazışma Adresi
Kadir Kabahasanoğlu, Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi, Anesteziyoloji ve Reanimasyon Anabilim Dalı, Balıkesir, Türkiye
e-mail: kadirkho@gmail.com

2025;34(4):274-281
doi:10.17827/aktd.1707456
Geliş tarihi/ Received: 27.05.2025
Kabul tarihi/Accepted: 03.12.2025

uzmanlığının yerini almayacak; ancak iyi tasarlandığında klinik karar süreçlerini tamamlayan, hızlı, özelleştirilmiş ve kanıta dayalı yoğun bakım hizmeti sunulmasına katkı sağlayacaktır.
Anahtar kelimeler: Yoğun bakım, yapay zekâ, makine öğrenimi, klinik karar destek sistemleri, kişiselleştirilmiş tedavi

Giriş

Yoğun bakım ünitelerinde (YBÜ) elde edilen klinik sonuçlar son otuz yılda belirgin şekilde iyileşmiştir; 1988–2012 arasında yoğun bakım hastalarında hastane mortalitesinin azaldığı bildirilmektedir[1]. Bununla birlikte, günümüz yoğun bakım pratiğinde karmaşık ve değişken hasta durumlarını anlamada, klinik kötüleşmeyi önceden öngörmede ve bozulma gerçekleşmeden önce erken tedavi stratejileri uygulamada halen önemli kısıtlılıklar mevcuttur[2]. Yoğun bakım hastaları çok çeşitli sebeplerle kritik durumda olabilir ve her hasta için en uygun yaklaşımı belirlemek güç olabilmektedir. Bu noktada, yapay zekâ (YZ) ve makine öğrenimi tabanlı yöntemler, yoğun bakım ortamındaki büyük hacimli ve çok boyutlu verilerde gizli kalıpları ortaya çıkararak klinisyenin fark edemeyeceği ilişkileri saptama potansiyeli ile dikkat çekmektedir[2]. Artan hesaplama gücü ve veri toplama kapasitesi sayesinde, artık yoğun bakım gibi veri yoğun alanlarda YZ uygulamaları mümkün hale gelmiştir[2]. Yoğun bakımda monitörler, cihazlar ve elektronik sağlık kayıtları aracılığıyla yüksek boyutlu sürekli veriler üretilmektedir ve bu veri bolluğu, yapay zekâ destekli klinik karar destek sistemleri için benzersiz bir fırsat sunmaktadır[3]. Öte yandan, akut bakım alanlarında YZ'nin kullanımı beklenenden yavaş ilerlemektedir; YZ tekniklerinin yoğun bakım gibi gerçek zamanlı ve kritik ortamlara entegrasyonu halen başlangıç aşamasındadır ve düzensiz bir seyir izlemektedir[4]. Bu makalede, yoğun bakımda yapay zekâ uygulamalarının başlıca alanları, güncel literatürde öne çıkan yenilikçi yaklaşımlar ve bu teknolojilerin getirdiği avantajlar ile olası zorluklar derlenecektir.

Yoğun Bakımda Yapay Zekânın Uygulama Alanları

Tanı ve Erken Tespit

Yoğun bakım hastalarında altta yatan durumu hızlı ve doğru teşhis edebilmek, karmaşık tablo ve eşlik eden sorunlar nedeniyle her zaman kolay değildir[2]. Özellikle çoklu organ tutulumuna yol açan sendromlarda veya görüntüleme bulgularının birden fazla nedene bağlı olabileceği durumlarda tanı belirsiz kalabilir. Yapay zekâ uygulamaları, büyük veri içinde örüntü tanıma kapasitesi sayesinde bu alanda destek sunmaya başlamıştır. Özellikle tıbbi görüntüleme alanında derin öğrenme algoritmaları, yoğun bakım hastalarında tanısal doğruluğu artırmaya yönelik başarılı örnekler ortaya koymaktadır. Örneğin, Seah ve arkadaşlarının (2019) çalışmalarında bir yapay zekâ modeli standart akciğer grafisindeki infiltratların nedenini belirlemede kullanılmış; konjestif kalp yetmezliğine bağlı pulmoner ödem ile diğer nedenleri ayırt edebildiği gösterilmiştir[5]. Yine Horng ve arkadaşlarının 2021 yılında yaptıkları çalışmaya göre göğüs radyografilerinde pulmoner ödem miktarının kantitatif analizi, derin öğrenme ile geleneksel yaklaşımlardan daha objektif şekilde yapılabilmiştir[6]. Bilgisayarlı tomografi (BT) görüntülerinde yapay zekâ kullanımı da önemli örnekler sunmaktadır: Li ve arkadaşlarının 2020 yılında yaptıkları çalışmaya göre COVID-19 pandemisi sırasında, akciğer BT verilerini işleyen derin öğrenme modelleri COVID-19 pnömonisini toplum kaynaklı diğer pnömonilerden ayırt etmede yüksek tanısal doğruluk sergilemiştir[7]. Monteiro ve arkadaşlarının (2020) çalışmalarında yoğun bakım travma hastalarında beyin BT'si üzerinde otomatik lezyon tespiti yapabilen bir derin öğrenme algoritması, travmatik beyin hasarını radyologların manuel değerlendirmesinden daha yüksek doğrulukla sınıflandırmıştır[8]. Benzer şekilde, Dreizin ve arkadaşlarının (2020) çalışmalarında batın BT görüntülerinde intrabdominal kanama (hemoperitoneum) alanını piksel düzeyinde hesaplayabilen bir yapay zekâ modeli geliştirilmiş ve subjektif tahminlere kıyasla daha tutarlı nicel ölçümler üretmiştir[9]. Bu örnekler, yapay zekânın karmaşık görüntü verilerini analiz ederek tanısal sürece hız ve objektiflik katabileceğini göstermektedir. İlerleyen dönemde, yoğun bakım hastalarında ultrason görüntülerinin YZ ile gerçek zamanlı yorumlanması, klinik durumun erken saptanması ve tedaviye yön verilmesi konularında da çalışmaların artması beklenmektedir.

Hastalık Seyrinin Tahmini ve Risk Değerlendirmesi

Yoğun bakım hastalarında klinik kötüleşmenin önceden tahmin edilerek proaktif önlemler alınması, "kutsal kâse" olarak nitelenebilecek zorlukta bir hedeftir[10]. Hastalık süreçleri süreklilik arz eder ve kritik bir hastanın durumu ani değişiklikler gösterebilir. Bu nedenle, YZ destekli erken uyarı sistemleri ve prognostik modeller

yoğun bakımda giderek önem kazanmaktadır. Nitekim, Chen ve arkadaşları (2017) yoğun bakıma yatış öncesi ara bakım (step-down) ünitesindeki hastalar üzerinde yapılan çalışmalarında, kalp hızı, kan basıncı ve solunum gibi sürekli vital bulguları takip eden bir makine öğrenimi modeli, kişiselleştirilmiş risk tahminleri üreterek kardiyorespiratuvar instabilite gelişimini ortalama 90 dakika öncesinden öngörebilmiştir[11]. Yoğun bakım ünitelerinde de hemodinamik bozulma, solunum yetmezliği veya kardiyak arrest gibi kritik olayları önceden haber vermeye yönelik modeller geliştirilmektedir. Örneğin, Wijnberge ve arkadaşlarının 2020 yılında yaptıkları çalışmaya göre cerrahi hastalarda geliştirilmiş bir erken uyarı sistemi, makine öğrenimi ile intraoperatif hipotansiyonu öngörmüş ve yapılan müdahaleler sonucunda hipotansif sürenin kısaltılmasını sağlamıştır[12]. Yoğun bakım hastalarında benzer yaklaşımla, ani hipotansiyon ataklarını veya septik şoka gidişi dakikalar önce haber verebilecek risk skorları üzerinde çalışılmaktadır. Nitekim, Nemati ve arkadaşlarının (2018) çalışma verilerine göre yoğun bakımda gelişebilecek sepsis tablosunu yaklaşık 4-6 saat önceden %85'in üzerinde doğrulukla tahmin edebilen, özellikleri anlaşılabilir bir makine öğrenimi modeli geliştirilmiştir[13]. Benzer şekilde, Bartkowiak ve arkadaşlarının 2019 yılında yaptıkları çalışmaya göre post-operatif cerrahi hastalarda yapay zekâ tabanlı bir puanlama sistemi (Electronic Cardiac Arrest Risk Triage, eCART skoru) kullanılarak hangi hastaların kardiyak arrest açısından yüksek risk taşıdığı belirlenebilmiştir[14]. YZ ayrıca yoğun bakımda mortalite tahmini için de kullanılmaktadır; Thorsen-Meyer ve arkadaşlarının (2020) çalışmalarında yüksek boyutlu ve sürekli verilerle beslenen derin öğrenme modelleri, yoğun bakım hastalarının hastane içi mortalitesini geleneksel skorlardan daha isabetli şekilde öngörebilmektedir[15]. Banoei ve arkadaşlarının 2021 yılında yaptıkları çalışmaya göre özellikle COVID-19 hastalarında klinik, laboratuvar ve görüntüleme verilerini bir arada işleyerek mortalite riskini hesaplayan yapay zekâ araçları, yüksek riskli hastaların erken dönemde tanınmasına katkı sunmuştur[16]. Tüm bu örnekler, yapay zekânın yoğun bakımda prognostik öngörü gücünü artırarak klinisyenin karar alma sürecine destek olabileceğini göstermektedir. Gelecekte, gerçek zamanlı veri akışını kullanan ve hasta başı monitörlerle entegre çalışan YZ sistemlerinin, kritik olayları daha oluşmadan haber veren akıllı alarm sistemleri olarak görev yapması hedeflenmektedir.

Hasta Fenotiplemesi ve Kişiselleştirilmiş Tedavi

Kritik hastalıklar, altta yatan neden ve hasta özelliklerine bağlı olarak oldukça farklı klinik fenotiplerle karşımıza çıkabilir. Benzer şekilde, yoğun bakımda gözlenen sendromlar tek tip bir tablo yerine hastadan hastaya değişkenlik gösterir ve heterojen yapılara sahiptir[2]. Bu heterojenite, tüm hastalara aynı standart tedaviyi uygulamanın her zaman en iyi sonuçları vermemesine yol açmaktadır. Yapay zekâ teknikleri, karmaşık verilerden desen tanıma gücü sayesinde kritik hastalıkların altta yatan fenotip veya alt gruplarını belirleme konusunda çığır açan gelişmeler sağlamıştır. Örneğin, sepsis hastalarında Seymour ve arkadaşları (2019) tarafından yapılan bir yapay zekâ çalışması, geniş hasta kohortlarındaki klinik ve biyolojik verileri analiz ederek dört farklı sepsis fenotipi tanımlamıştır[17]. "Alfa, beta, gamma, delta" olarak adlandırılan bu sepsis alt tipleri; demografik özellikler, laboratuvar bulguları ve bağışıklık yanıt paternleri açısından belirgin farklılıklar göstermiş ve farklı klinik sonuçlarla ilişkili bulunmuştur[17]. Bu bulgular, sepsisin tek bir sendrom olmayıp alt gruplara ayrılabileceğini ortaya koymuş ve gelecekte tedavinin bu alt grup özelliklerine göre kişiselleştirilebileceğine işaret etmiştir. Benzer şekilde, Calfee ve arkadaşlarının 2018 yılında yaptıkları çalışmaya göre akut solunum sıkıntısı sendromu (ARDS) olgularında yapılan bir kümeleme analizi, hiperinflamatuar ve hipoinflamatuar olmak üzere iki ayrı alt fenotip tanımlamıştır. Bu alt tiplerin klinik özellikleri ve tedaviye verdikleri yanıtlar farklı olup, örneğin yüksek PEEP düzeyine ve sıvı kısıtlamasına yanıt hiperinflamatuar grupta daha belirgin bulunmuştur[18]. Daha da önemlisi, Sinha ve arkadaşlarının (2020) çalışmalarında bu ARDS alt tiplerini basit klinik ve biyolojik parametrelere dayanarak ayırt edebilen bir sınıflandırma modeli geliştirilmiş ve farklı randomize klinik çalışmaların verileri üzerinde doğrulanmıştır[19]. Yoğun bakım pratiğinde fenotipleme çalışmaları sadece sepsis veya ARDS ile sınırlı değildir; örneğin Geri ve arkadaşlarının 2019 yılında yaptıkları çalışmada septik şoklu hastalarda yapılan bir analizde, ekokardiyografi ile izlenen kardiyak performanslarına göre farklı hemodinamik alt gruplar (örneğin yüksek debili – düşük dirençli profil vs. düşük debili – yüksek dirençli profil) tanımlanmış ve bu alt grupların prognozlarının farklı olduğu gösterilmiştir[20].

Fenotipleme yoluyla elde edilen bu tür alt grup bilgilerinin, yoğun bakımda kişiselleştirilmiş tedavi yaklaşımlarını mümkün kılması hedeflenmektedir. Örneğin Seymour ve arkadaşlarının (2019) çalışmalarında sepsis için tanımlanan dört fenotipin, gelecekte klinik çalışmalarda hasta seçimini ve tedavi stratejilerini

fenotipe özgü şekilde belirlemek amacıyla kullanılabileceği vurgulanmıştır[17]. Nitekim, son yıllarda başarısızlıkla sonuçlanan bazı geniş ölçekli yoğun bakım tedavi denemelerinin (örneğin standart protokollere dayalı tek tip sepsis tedavileri) arkasında, hasta popülasyonunun homojen olmayıp alt grupların farklı tedavi ihtiyaçlarının bulunması yatabileceği düşünülmektedir. Bu bağlamda, yapay zekâ destekli analizler sayesinde her bir hastanın "kritik hastalık imzası" ortaya konarak, uygun hastaya uygun tedaviyi, doğru zamanda verme imkânı doğabilir.

Klinik Karar Destek Sistemleri ve Tedavi Optimizasyonu

Yoğun bakım pratiğinde "tek tip tedavi herkese uyar" anlayışı çoğu zaman geçerli olmamaktadır. Nitekim son yıllarda septik şok yönetimine yönelik ardışık klinik araştırmalar, standart protokollerin hasta sonuçlarını belirgin şekilde iyileştiremediğini göstermiştir[21]. Septik şoktaki aşırı heterojen yapı, altta yatan farklı nedenler ve hastadan hastaya değişen konak yanıtları göz önüne alındığında, yoğun bakımda tedavi yaklaşımlarının bireyselleştirilmesi gerektiği açıktır. Yapay zekâ, özellikle pekiştirmeli öğrenme (reinforcement learning) algoritmaları aracılığıyla hasta bazlı tedavi önerileri sunma potansiyeli taşımaktadır[22]. Pekiştirmeli öğrenme yönteminde algoritma, belirli bir klinik durum için çok sayıda değişkeni göz önüne alarak bir eylem (tedavi) modeli oluşturmakta ve her eylemin sonucundan ödül/ceza mantığıyla öğrenerek en optimal stratejiyi belirlemektedir[23]. Komorowski ve arkadaşlarının 2018 yılında yaptıkları çalışmaya göre yoğun bakım hastalarının geçmiş verileri üzerinde eğitilen bir pekiştirmeli öğrenme algoritmasının, sepsis tedavisinde sıvı ve vazopressör kullanımına yönelik optimal karar zincirlerini öğrenebileceği ve böylece hasta bazında en uygun tedavi seyrini önerebileceği gösterilmiştir[23]. "Yapay zekâ klinisyeni" olarak anılan bu model, retrospektif verilerde insan uzmanlardan daha başarılı tedavi stratejileri ortaya koymuş ve sepsis yönetiminde veri güdümlü karar desteğinin mümkün olabileceğini kanıtlamıştır[23]. Benzer şekilde, Peine ve arkadaşlarının 2021 yılında yaptıkları çalışmaya göre mekanik ventilasyondaki yoğun bakım hastaları için geliştirilmiş bir pekiştirmeli öğrenme algoritması, solunum cihazı ayarlarını dinamik olarak optimize etmiş ve 90 günlük mortalite gibi sonuçlar açısından hekimlerin standart uygulamalarından daha iyi sonuçlar üretebilmiştir[24]. Bu örnekler, yapay zekânın yoğun bakımda klinik karar destek sistemleri şeklinde kullanılmasının kritik tedavi kararlarına ışık tutabileceğini göstermektedir. Özellikle kaynak kısıtlı veya uzman hekimin olmadığı ortamlarda, ileri YZ algoritmalarının uygun tedavi önerileri sunabilmesi, yoğun bakım hizmetinin standardizasyonu ve kalitesini artırabilir[2]. Bununla birlikte, yapay zekâ tarafından önerilen tedavilerin güvenli ve etkin olmasının sağlanması için, bu modellerin sonuçlarının prospektif klinik çalışmalarda doğrulanması şarttır[2]. Nitekim, önerilen doz veya müdahale dizilerinin sadece geçmiş verilere dayalı olması, gerçek hayatta her zaman en iyi sonuç vereceğinin garantisi değildir. Bu nedenle, YZ tabanlı karar destek sistemleri klinik uygulamaya girmeden önce, kontrol gruplu çalışmalarla hasta sonuçlarına etkisinin titizlikle değerlendirilmesi gerekmektedir.

Yapay Zekâ Uygulamalarının Sınırlılıkları ve Zorlukları

Veri Paylaşımı, Kalitesi ve Bütünlüğü

Yapay zekâ modellerinin başarısı büyük ölçüde veriye dayalıdır. Yoğun bakım ünitelerinde aslında çok zengin ve yüksek yoğunluklu veri akışı mevcut olsa da bu verilerin araştırma amaçlı ikincil kullanımı önünde bazı engeller bulunmaktadır[25]. Elektronik sağlık kayıtlarındaki farklılıklar, veri standartlarının kurumlar arası uyumsuzluğu ve hasta mahremiyetine ilişkin yasal kısıtlamalar, büyük ölçekli veri havuzlarının oluşturulmasını güçleştirmektedir[25]. Mevcut yoğun bakım veri setlerinin çoğu tek merkezli olup, veri içerikleri ve tanımlamaları kurumdan kuruma değişebilmektedir. Bu da geliştirilen bir modelin başka bir merkeze genellenmesini zorlaştırır. Örneğin, aynı klinik kavramın (örneğin "akut böbrek hasarı" tanımının) farklı veri tabanlarında farklı biçimlerde kodlanması, algoritmaların bu verileri anlamlandırmasını güçleştirmekte ve modellerde anlamsal uyumsuzluklara yol açmaktadır[26]. Bunun yanında, hassas sağlık verilerinin paylaşımıyla ilgili etik ve yasal endişeler, yoğun bakım verilerinin açık bilim camiasıyla paylaşılmasını kısıtlamaktadır[3]. Sonuç olarak, her ne kadar yapay zekâ için gerekli "büyük veri", yoğun bakım ortamında potansiyel olarak mevcut olsa da, bu verinin kaliteli, temizlenmiş ve geniş kitlelere açık bir şekilde temin edilmesi önemli bir sorundur.

Bununla birlikte, son yıllarda açık erişimli yoğun bakım veri tabanları oluşturma yönünde olumlu adımlar atılmaktadır. Örneğin, Fleuren ve arkadaşlarının 2020 yılında yaptıkları çalışmaya göre MIMIC ve eICU gibi veri setleri on binlerce yoğun bakım hastasının anonimleştirilmiş detaylı klinik verilerini araştırmacılara sunarak yapay zekâ çalışmalarını hızlandırmıştır[27]. Thoral ve arkadaşlarının (2021) çalışmalarında Avrupa ve ABD'de yoğun bakım derneklerinin ortak girişimiyle hayata geçirilen AmsterdamUMCdb projesi de hasta verilerinin güvenli paylaşımı konusunda bir örnek teşkil etmektedir[25]. Bunlar sayesinde, farklı merkezlerden elde edilen verilerle modellerin beslenmesi ve daha genellenebilir sonuçlar elde edilmesi mümkün olmuştur. Ancak halen birçok kurum, verilerini paylaşma konusunda istekli değildir ve bu durum YZ algoritmalarının gelişimini yavaşlatmaktadır[25]. Gelecekte, veri standartlaştırma (ontolojiler, birim ve kavram bütünlüğü), veri temizleme (hatalı veya eksik verilerin ayıklanması) ve kurumlar arası güvenli veri paylaşım protokollerinin geliştirilmesi, yoğun bakım yapay zekâ uygulamalarının ilerlemesi için kritik önem taşıyacaktır.

Algoritmik Güvenilirlik ve Genellenebilirlik

Yapay zekâ modellerinin klinik uygulamada başarılı olabilmesi için güvenilir ve genellenebilir olmaları gerekir. Ancak literatürdeki pek çok YZ çalışması, kendi geliştikleri veri setinde yüksek performans gösterirken, bağımsız dış veri setlerinde benzer başarıyı sürdürememektedir. Bunun bir nedeni, modellerin eğitildiği veri dağılımının gerçek hayattaki yeni hasta popülasyonlarından farklılık göstermesidir. Yoğun bakım hastaları ve uygulamaları kurumlar arasında değişkenlik arz ettiğinden, bir merkezde geliştirilen model başka bir merkeze uygulandığında veri kayması (dataset shift) sorunu ortaya çıkabilir. Bu da modelin öngörü performansını düşürür. Ayrıca, makine öğrenimi modelleri genellikle verideki yanlılık ve hataları da öğrenebilir; örneğin bir veri setinde belirli bir alt grubun (ör. kadın hastaların) az temsil edilmesi, modelin bu grupta düşük performans sergilemesine yol açabilir. Bu tür algoritmik önyargıların farkında olunması ve azaltılmasına yönelik önlemler alınması, TÜBİTAK'ın ilgili rehberinde de vurgulandığı üzere, yapay zekânın sorumlu ve adil kullanımı için kritik önem taşımaktadır[28]. Yoğun bakım veri tabanlarının geriye dönük ve gözlemsel doğası, karıştırıcı değişkenlerin etkilerini ve sistematik hataları da beraberinde getirir. Dolayısıyla, geliştirilen YZ araçlarının dış doğrulaması mutlaka yapılmalı ve farklı kohortlarda tutarlı sonuç verdiği gösterilmelidir[27]. Bununla birlikte, yoğun bakım gibi dinamik bir alanda karar destek amaçlı kullanılacak sistemlerin mutlaka prospektif klinik çalışmalarda test edilmesi gereklidir. Ne yazık ki bugüne kadar bu alanda gerçekleştirilen prospektif çalışma sayısı çok sınırlıdır ve mevcut YZ modellerinin çoğu gerçek zamanlı klinik ortamlarda denemeye tabi tutulmamıştır[29]. Bu durum, yapay zekânın kâğıt üzerindeki başarısının fiilen hasta bakımına yansıması konusunda belirsizlik yaratmaktadır. Sonuç olarak, yoğun bakımda yapay zekâ uygulamalarının güvenilirliği için algoritmaların sağlam olması, ufak veri değişikliklerinden veya ölçüm hatalarından aşırı etkilenmemesi, farklı hasta gruplarında benzer doğrulukta çalışması ve klinik ortama transfer edilebilir olması şarttır. Bunu sağlamak için gelişmiş model doğrulama teknikleri, transfer öğrenimi ve sürekli model güncelleme stratejileri üzerinde çalışmalar sürmektedir.

Açıklanabilirlik ve Şeffaflık

Yoğun bakım hekimlerinin yapay zekâ destekli sistemleri günlük pratiğe dahil etmesinin önündeki engellerden biri de bu araçların karar mekanizmalarının anlaşılabilir olmamasıdır. Birçok derin öğrenme modeli, binlerce parametre içeren karmaşık nöral ağlar şeklinde bir kara kutu (black-box) gibi davranır. Modelin bir hasta için örneğin "72 saat içinde sepsis gelişecek" tahmini, eğer klinisyen tarafından hangi veriler ve ilişkiler sonucunda üretildiği anlaşılamazsa, hekim nezdinde güven oluşturmayabilir[30]. Nitekim, şeffaflık ve açıklanabilirlik, Üretken Yapay Zekânın Sorumlu ve Güvenilir Kullanımı Rehberi'nde de hesap verebilirliği destekleyen ve güveni artıran temel ilkeler olarak vurgulanmaktadır[28]. Yoğun bakım gibi yüksek riskli kararlara sahne olan bir alanda, hekimlerin YZ önerilerine güvenebilmesi için model çıktılarının açıklanabilir olması önemlidir. Bu nedenle, son yıllarda yapay zekâ modellerinin yorumlanabilirliğini artırmaya yönelik yoğun çaba harcanmaktadır. Örneğin, derin öğrenme modellerinin kararlarını insan tarafından anlaşılır hale getirmek için özellik önem skorları, karar ağaçlarına dayalı yaklaşımlar veya oyun teorisinden uyarlanan SHAP (Shapley Additive Explanations) değeri gibi yöntemler kullanılmaktadır. Nitekim Lundberg ve arkadaşlarının 2018 yılında yaptıkları çalışmada, ameliyat sırasında gelişen hipoksiyi öngören bir makine öğrenimi modelinin karar kriterlerini açıklamak için oyun teorisinden esinlenen bir yöntem uygulanmış; modelin hangi fizyolojik ölçümlere ne düzeyde ağırlık verdiği görselleştirilerek

klinisyenin anlayabileceği şekilde sunulmuştur[31]. Benzer şekilde Davoudi ve arkadaşlarının 2019 yılında yaptıkları çalışmada yoğun bakımda hipotansiyon gelişimini öngören bir modelde, algoritmanın dikkat ettiği belirti ve bulguların önem derecesi açıklanarak, hekimlerin alarm çıktısını daha iyi yorumlaması sağlanmıştır[32]. Yapay zekâ modellerinin açıklanabilir olması, sadece güven oluşturmakla kalmaz, aynı zamanda modele duyulan hukuki ve etik sorumluluğu da paylaşılır hale getirir. Bir karar destek sistemi ciddi bir hata yaptığında, eğer modelin hangi mantıkla o hatalı kararı verdiği şeffaf değilse, sorumluluğun kime ait olduğu belirsiz kalacaktır. Bu nedenle, birçok uzmana göre hayati kararlar için opak modeller yerine yorumlanabilir modellerin kullanılması tercih edilmelidir[25]. Sonuç olarak, yoğun bakımda YZ uygulamalarının başarılı bir şekilde benimsenebilmesi için, model çıktılarının klinik gerçeklikle örtüşecek biçimde açıklanabilir olması ve kullanıcıya anlaşılır geri bildirim sunması büyük önem taşımaktadır.

Etik ve Yasal Boyutlar

Yapay zekânın sağlık alanında kullanımında etik sorular ve yasal düzenlemeler de önemli bir yer tutar. Yoğun bakım hastaları üzerinde karar destek sağlayacak bir yapay zekâ sistemi, öncelikle güvenlik ve adalet prensipleri açısından değerlendirilmelidir. Algoritmaların eğitildiği verilerdeki yanlılıklar (örneğin belirli bir etnik grubun az temsil edilmesi veya veri toplama sürecindeki hatalar), YZ sistemlerinin de yanlı kararlar üretmesine sebep olabilir. Bu durum, farklı hasta gruplarına karşı istenmeden de olsa ayrımcılık yapılmasına yol açabilir. Bu bağlamda, ulusal düzeyde oluşturulan çerçeveler de YZ kullanımında adalet ve ayrımcılık yapmama ilkelerinin gözetilmesi gerektiğini vurgulamaktadır[28]. Örneğin, geçmiş verilerde yaşlı hastalara yoğun bakımda daha az agresif tedavi uygulanmışsa, bir yapay zekâ sistemi tedavi önerilerinde bu örüntüyü devam ettirebilir ve genç hastalara kıyasla yaşlılara sistematik olarak daha az müdahale öneren bir bias geliştirebilir. Bu tür riskleri önlemek için YZ modellerinin eğitildiği veri setlerinin çeşitliliğinin sağlanması ve adaletli performans gösterip göstermediğinin test edilmesi gerekir[3].

Diğer yandan, yapay zekâ ile alınan kararların hukuki sorumluluğu belirsiz olabilir. Yoğun bakımda bir YZ sistemi yanlış bir alarm verip gereksiz invaziv girişimlere yol açarsa veya tam tersi şekilde gerekli bir uyarıyı vermeyerek gecikmeye sebep olursa, bundan doğan zararın sorumluluğu kime ait olacaktır? Bu konuda henüz net yasal çerçeveler oluşmamıştır. Ancak YZ sistemlerinin birer araç olduğu ve nihai sorumluluğun her zaman insanlarda olduğu temel bir ilke olarak kabul edilmektedir[28]. Düzenleyici otoriteler, yapay zekâ tabanlı tıbbi cihaz ve yazılımların onaylanmasına yönelik değerlendirme süreçleri geliştirmektedir; ABD Gıda ve İlaç Dairesi (FDA) bazı yapay zekâ algoritmalarına onay vermiş olsa da sürekli öğrenen ve kendini güncelleyen sistemlerin denetlenmesi konusunda soru işaretleri devam etmektedir. Ayrıca, yoğun bakım verilerinin kullanımında hasta mahremiyeti ve verinin mülkiyeti konuları da etik bir tartışma alanıdır. Özellikle Türkiye bağlamında, Kişisel Verilerin Korunması Kanunu (KVKK) hükümlerine uyum sağlanması ve hassas sağlık verilerinin YZ araçları kullanılırken korunması gerektiği vurgulanmaktadır[28]. Hastalardan toplanan büyük verilerin yapay zekâ şirketleri veya araştırmacılar tarafından kullanılması durumunda, hastaların onamının nasıl alınacağı ve verinin ticari amaçla kullanımının sınırları belirsizdir. Tüm bu nedenlerle, yoğun bakımda yapay zekâ uygulamalarının yaygınlaşması, sadece teknik zorlukların değil, aynı zamanda etik ilke ve yasal düzenlemelerin de ele alınmasını gerektirmektedir. Klinik uygulamada güvenle yer alabilmeleri için YZ araçlarının şeffaf, adil ve hesap verebilir olması; geliştirme sürecinden kullanımına kadar çok disiplinli bir denetime tabi tutulması şarttır.

Gelecek Yönelimler

Yapay zekâ tabanlı klinik karar destek sistemleri yoğun bakım tıbbında hızla gelişmekte ve kalıcı hale gelmeleri beklenmektedir[3]. Geleceğin yoğun bakımı, veriden öğrenen ve durumları gerçek zamanlı izleyerek klinisyene proaktif öneriler sunan akıllı sistemlerle desteklenecektir. Bu dönüşümün başarısı ise birkaç önemli adıma bağlıdır: Öncelikle, yapay zekâ sistemlerinin klinik iş akışına entegrasyonu kullanıcı dostu bir şekilde gerçekleştirilmelidir. Hekimler, hemşireler ve diğer sağlık çalışanları, bu sistemlerin tasarım ve uygulama süreçlerine erkenden dahil edilmeli; arayüzlerin sezgisel ve uyarıların anlamlı olacak şekilde tasarlanması sağlanmalıdır[33]. Özellikle yoğun bakım ortamında, her an çok sayıda alarm ve uyarı gelmesi bakım ekibinde alarm yorgunluğu yaratabilmektedir. Gelecekte YZ sistemleri, çoklu sinyalleri birleştirerek daha akıllı alarm stratejileri geliştirebilir; örneğin tek bir model yerine, birden fazla modeli ardışık olarak kullanıp yalnız gerçek pozitif olasılığı yüksek durumlarda alarm üreterek, gereksiz uyarıları en aza indirebilir.

Nitekim Hravnak ve arkadaşlarının 2018 yılında yaptıkları çalışmada, yoğun bakımda hipotansiyon öngörüsü için geliştirilen bir sistemde, iki kademeli bir makine öğrenimi modeli kullanılmış ve yalancı alarm oranı 10 kat azaltılırken duyarlılık korunabilmiştir[33]. Bu tür yaklaşımlar, gelecekte alarm kirliliğini önleyerek kritik uyarıların zamanında fark edilmesini kolaylaştıracaktır.

Bir diğer gelecek yönelimi, çok modaliteli veri entegrasyonu ve dijital ikiz (digital twin) uygulamalarıdır. Yoğun bakım hastasının tüm klinik seyrini, fizyolojik verilerini, laboratuvar sonuçlarını ve görüntülerini gerçek zamanlı olarak bir araya getirip, sanal bir ikiz model üzerinde farklı senaryoları test eden yaklaşımlar teorik olarak mümkündür. Yapay zekâ, bu devasa veri bütününü anlamlandırıp hastanın birkaç saat/gün içindeki olası gidişatını simüle edebilir ve örneğin "şu an sıvı verilir veya ventilatör ayarı değiştirilirse 6 saat sonra ne olur?" sorusuna yanıt arayabilir. Henüz erken aşamada olan bu konsept, ileride kişiye özgü tedavi planlamasında faydalı olabilir. Ayrıca, görüntü işlemeye dayalı izlem de gelecek vadeden alanlardan biridir. Derin öğrenme modelleri, yoğun bakım odasına yerleştirilen kameralar vasıtasıyla hastanın yüz ifadelerini, vücut hareketlerini ve çevresel uyaranlarını analiz ederek, örneğin deliryum gelişimini veya ağrı düzeyini tespit edebilir[33]. Bu tür temassız izlem yöntemleri, klinik değerlendirmeye objektif bir boyut katabilir ve hemşirelerin yükünü hafifletebilir.

Tüm bu teknolojik gelişmelerin etkin bir şekilde hayata geçirilmesi için, sağlık çalışanlarının yapay zekâ okuryazarlığının artırılması da gereklidir. Gelecekte yoğun bakım ekipleri, temel YZ kavramlarına aşina olmalı ve bu sistemlerin güçlü ve zayıf yönlerini anlayarak onlarla iş birliği içinde çalışmalıdır. Eğitim programlarına bu konuların dahil edilmesi, YZ farkındalığı yüksek bir sağlık işgücü oluşturacaktır. Bu eğitimler, yapay zekânın sadece teknik yönlerini değil, aynı zamanda sorumlu ve etik kullanım ilkelerini de kapsamalıdır[28]. Son olarak, yapay zekânın yoğun bakımda yaratacağı etkinin sürekli olarak izlenmesi ve sonuçların kalite iyileştirme döngüleriyle değerlendirilmesi önem taşır. Model performansları gerçek dünyada izlenerek gerektiğinde güncellenmeli, beklenmeyen olumsuz etkiler tespit edildiğinde hızlıca müdahale edilmelidir.

Sonuç

Yapay zekâ uygulamaları yoğun bakım tıbbında çığır açıcı bir potansiyele sahiptir. Erken tanı, risk öngörüsü, tedavinin kişiselleştirilmesi ve klinik karar desteği gibi kritik alanlarda şimdiden ümit vadeden sonuçlar elde edilmiştir. Ancak bu teknolojilerin günlük pratiğe sorunsuz bir şekilde girebilmesi için veri paylaşımından etik ilkelere, algoritma güvenilirliğinden kullanıcı dostu tasarıma dek uzanan geniş bir yelpazede dikkatli planlama ve çalışma gerekmektedir. Bu süreçte, ulusal/uluslararası rehberlerde belirtilen sorumlu ve güvenilir yapay zekâ kullanımı ilkelerine uyum sağlanması kritik önem taşımaktadır. Yapay zekâ, yoğun bakım ekiplerinin yerini almayacak; tersine, doğru uygulandığında onların yetkinliklerini tamamlayan bir destekçi araç olacaktır. Geleceğin yoğun bakım ünitelerinde, yapay zekâ ile insan becerisi el ele vererek, en kritik durumlarda dahi hızlı, isabetli ve özelleştirilmiş hasta bakımı sunulmasına yardımcı olacaktır.

Kaynaklar

1. Zimmerman JE, Kramer AA, Knaus WA. Changes in hospital mortality for United States intensive care unit admissions from 1988 to 2012. Crit Care. 2013;17(2):R81. Published 2013 Apr 27. doi:10.1186/cc12695.
2. Yoon JH, Pinsky MR, Clermont G. Artificial Intelligence in Critical Care Medicine. Crit Care. 2022;26:75. Published 2022 Mar 22. doi:10.1186/s13054-022-03915-3.
3. Pinsky MR, Bedoya A, Bihorac A, et al. Use of artificial intelligence in critical care: opportunities and obstacles. Crit Care. 2024;28:113. Published 2024 Apr 8. doi:10.1186/s13054-024-04860-z
4. Reddy S, Fox J, Purohit MP. Artificial intelligence-enabled healthcare delivery. J R Soc Med. 2019;112:22-28. doi:10.1177/0141076818815510.
5. Seah JCY, Tang JSN, Kitchen A, Gaillard F, Dixon AF. Chest Radiographs in Congestive Heart Failure: Visualizing Neural Network Learning. Radiology. 2019;290:514-22. doi:10.1148/radiol.2018180887.
6. Horng S, Liao R, Wang X, Dalal S, Golland P, Berkowitz SJ. Deep Learning to Quantify Pulmonary Edema in Chest Radiographs. Radiol Artif Intell. 2021;3:e190228. Published 2021 Jan 6. doi:10.1148/ryai.2021190228.
7. Li L, Qin L, Xu Z, et al. Using Artificial Intelligence to Detect COVID-19 and Community-acquired Pneumonia Based on Pulmonary CT: Evaluation of the Diagnostic Accuracy. Radiology. 2020;296:E65-E71. doi:10.1148/radiol.2020200905.
8. Monteiro M, Newcombe VFJ, Mathieu F et al. Multiclass semantic segmentation and quantification of traumatic brain injury lesions on head CT using deep learning: an algorithm development and multicentre validation study. Lancet Digit Health. 2020;2:e314-e322. doi:10.1016/S2589-7500(20)30085-6.

9. Dreizin D, Zhou Y, Fu S et al. A Multiscale Deep Learning Method for Quantitative Visualization of Traumatic Hemoperitoneum at CT: Assessment of Feasibility and Comparison with Subjective Categorical Estimation. Radiol Artif Intell. 2020;2:e190220. Published 2020 Nov 11. doi:10.1148/ryai.2020190220.
10. Vincent JL. The continuum of critical care. Crit Care. 2019;23:122. Published 2019 Jun 14. doi:10.1186/s13054-019-2393-x.
11. Chen L, Ogundele O, Clermont G, Hravnak M, Pinsky MR, Dubrawski AW. Dynamic and Personalized Risk Forecast in Step-Down Units. Implications for Monitoring Paradigms. Ann Am Thorac Soc. 2017;14:384-91. doi:10.1513/AnnalsATS.201611-905OC.
12. Wijnberge M, Geerts BF, Hol L et al. Effect of a Machine Learning-Derived Early Warning System for Intraoperative Hypotension vs Standard Care on Depth and Duration of Intraoperative Hypotension During Elective Noncardiac Surgery: The HYPE Randomized Clinical Trial. JAMA. 2020;323:1052-60. doi:10.1001/jama.2020.0592.
13. Nemati S, Holder A, Razmi F, Stanley MD, Clifford GD, Buchman TG. An Interpretable Machine Learning Model for Accurate Prediction of Sepsis in the ICU. Crit Care Med. 2018;46(4):547-553. doi:10.1097/CCM.0000000000002936.
14. Bartkowiak B, Snyder AM, Benjamin A et al. Validating the Electronic Cardiac Arrest Risk Triage (eCART) Score for Risk Stratification of Surgical Inpatients in the Postoperative Setting: Retrospective Cohort Study. Ann Surg. 2019;269:1059-63. doi:10.1097/SLA.0000000000002665.
15. Thorsen-Meyer HC, Nielsen AB, Nielsen AP et al. Dynamic and explainable machine learning prediction of mortality in patients in the intensive care unit: a retrospective study of high-frequency data in electronic patient records. Lancet Digit Health. 2020;2:e179-e191. doi:10.1016/S2589-7500(20)30018-2.
16. Banoei MM, Dinparastisaleh R, Zadeh AV, Mirsaeidi M. Machine-learning-based COVID-19 mortality prediction model and identification of patients at low and high risk of dying. Crit Care. 2021;25:328. Published 2021 Sep 8. doi:10.1186/s13054-021-03749-5.
17. Seymour CW, Kennedy JN, Wang S et al. Derivation, Validation, and Potential Treatment Implications of Novel Clinical Phenotypes for Sepsis. JAMA. 2019;321:2003-17. doi:10.1001/jama.2019.5791
18. Calfee CS, Delucchi KL, Sinha P et al. Acute respiratory distress syndrome subphenotypes and differential response to simvastatin: secondary analysis of a randomised controlled trial. Lancet Respir Med. 2018;6:691-98. doi:10.1016/S2213-2600(18)30177-2.
19. Sinha P, Delucchi KL, McAuley DF, O'Kane CM, Matthay MA, Calfee CS. Development and validation of parsimonious algorithms to classify acute respiratory distress syndrome phenotypes: a secondary analysis of randomised controlled trials. Lancet Respir Med. 2020;8:247-57. doi:10.1016/S2213-2600(19)30369-8.
20. Geri G, Vignon P, Aubry A, et al. Cardiovascular clusters in septic shock combining clinical and echocardiographic parameters: a post hoc analysis. Intensive Care Med. 2019;45:657-67. doi:10.1007/s00134-019-05596-z.
21. Rivers E, Nguyen B, Havstad S, et al. Early goal-directed therapy in the treatment of severe sepsis and septic shock. N Engl J Med. 2001;345:1368-77. doi:10.1056/NEJMoa010307.
22. PRISM Investigators, Rowan KM, Angus DC et al. Early, Goal-Directed Therapy for Septic Shock - A Patient-Level Meta-Analysis. N Engl J Med. 2017;376:2223-34. doi:10.1056/NEJMoa1701380.
23. Komorowski M, Celi LA, Badawi O, Gordon AC, Faisal AA. The Artificial Intelligence Clinician learns optimal treatment strategies for sepsis in intensive care. Nat Med. 2018;24:1716-20. doi:10.1038/s41591-018-0213-5.
24. Peine A, Hallawa A, Bickenbach J et al. Development and validation of a reinforcement learning algorithm to dynamically optimize mechanical ventilation in critical care. NPJ Digit Med. 2021;4:32. Published 2021 Feb 19. doi:10.1038/s41746-021-00388-6.
25. Thoral PJ, Peppink JM, Driessen RH et al. Sharing ICU Patient Data Responsibly Under the Society of Critical Care Medicine/European Society of Intensive Care Medicine Joint Data Science Collaboration: The Amsterdam University Medical Centers Database (AmsterdamUMCdb) Example. Crit Care Med. 2021;49:e563-e577. doi:10.1097/CCM.0000000000004916.
26. Sauer CM, Dam TA, Celi LA et al. Systematic Review and Comparison of Publicly Available ICU Data Sets-A Decision Guide for Clinicians and Data Scientists. Crit Care Med. 2022;50:e581-e588. doi:10.1097/CCM.0000000000005517.
27. Fleuren LM, Thoral P, Shillan D, Ercole A, Elbers PWG; Right Data Right Now Collaborators. Machine learning in intensive care medicine: ready for take-off?. Intensive Care Med. 2020;46:1486-88. doi:10.1007/s00134-020-06045-y.
28. Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK). Destek Süreçlerinde Üretken Yapay Zekânın (ÜYZ) Sorumlu ve Güvenilir Kullanımı Rehberi. Available from: https://tubitak.gov.tr/sites/default/files/2025-10/UYZ_Rehberi_v03_TR.pdf. Accessed: 24 October 2025.
29. Nagendran M, Chen Y, Lovejoy CA et al. Artificial intelligence versus clinicians: systematic review of design, reporting standards, and claims of deep learning studies. BMJ. 2020;368:m689. Published 2020 Mar 25. doi:10.1136/bmj.m689
30. Rudin C. Stop Explaining Black Box Machine Learning Models for High Stakes Decisions and Use Interpretable Models Instead. Nat Mach Intell. 2019;1:206-15. doi:10.1038/s42256-019-0048-x.
31. Lundberg SM, Nair B, Vavilala MS, et al. Explainable machine-learning predictions for the prevention of hypoxaemia during surgery. Nat Biomed Eng. 2018;2:749-60. doi:10.1038/s41551-018-0304-0.
32. Davoudi A, Malhotra KR, Shickel B et al. Intelligent ICU for Autonomous Patient Monitoring Using Pervasive Sensing and Deep Learning. Sci Rep. 2019;9:8020. Published 2019 May 29. doi:10.1038/s41598-019-44004-w.
33. Hravnak M, Pellathy T, Chen L et al. A call to alarms: Current state and future directions in the battle against alarm fatigue. J Electrocardiol. 2018;51:S44-S8. doi:10.1016/j.jelectrocard.2018.07.024.