

İnfeksiyon Hastalıkları ve Klinik Mikrobiyolojide Yapay Zekâ: Güncel ve Gelecek Yönelimler

Artificial Intelligence in Infectious Diseases and Clinical Microbiology: Current and Future Directions

Ahmet Görkem Er¹ , Ezgi Gülten² , Fatih Temoçin³ , Nazlım Aktuğ-Demir⁴ 

¹Stanford Üniversitesi Tıp Fakültesi, İç Hastalıkları Anabilim Dalı, Göğüs Hastalıkları, Alerji ve Yoğun Bakım Bilim Dalı, Stanford, Kaliforniya, ABD; ²Ankara Üniversitesi Tıp Fakültesi, İnfeksiyon Hastalıkları ve Klinik Mikrobiyoloji Anabilim Dalı, Ankara, Türkiye;

³Ondokuz Mayıs Üniversitesi Tıp Fakültesi, İnfeksiyon Hastalıkları ve Klinik Mikrobiyoloji Anabilim Dalı, Samsun, Türkiye; ⁴Selçuk Üniversitesi Tıp Fakültesi, İnfeksiyon Hastalıkları ve Klinik Mikrobiyoloji Anabilim Dalı, Konya, Türkiye

ÖZET

Yapay zekâ, infeksiyon hastalıkları ve klinik mikrobiyoloji alanında tanı, tedavi, infeksiyon kontrolü ve antimikrobiyal yönetim süreçlerinde giderek daha fazla kullanılmakta ve günlük pratiğin birçok alanında dönüştürücü bir potansiyel sunmaktadır. Görüntüleme yöntemleri, moleküler ve mikrobiyolojik testler ile konak yanıtına dayalı sınıflayıcıların yapay zekâ algoritmalarıyla bütünleşmesi, tanısal doğruluğun artırılmasına ve klinik karar süreçlerinin desteklenmesine olanak sağlamaktadır. Tedavi alanında yapay zekâ; kişiselleştirilmiş antibiyotik seçimi, tedavi süresinin optimizasyonu, direnç öngörüsü ve klinik karar destek sistemleri aracılığıyla hasta yönetimine katkı sunmaktadır. İnfeksiyon kontrolünde ise erken salgın tespiti, gerçek zamanlı sürveyans, el hijyeni izlemi ve çevresel dezenfeksiyon uygulamaları öne çıkmaktadır. Buna karşın veri heterojenliği, algoritmik açıklanabilirlik, etik ve hukuki düzenlemeler ile hasta mahremiyeti önemli sınırlılıklardır. Ancak multidisipliner iş birliği, yüksek kaliteli veri üretimi ve uygun regülasyonlarla desteklenen yapay zekâ sistemlerinin, infeksiyon hastalıkları pratiğinde güvenilir ve etkili bir destek aracı hâline gelmesi beklenmektedir.

Anahtar Sözcükler: Yapay zekâ, infeksiyon hastalıkları, infeksiyon kontrolü, antimikrobiyal yönetim

ABSTRACT

Artificial intelligence (AI) is increasingly applied in infectious diseases and clinical microbiology, encompassing diagnostics, treatment, infection control, and antimicrobial stewardship, with transformative potential across many aspects of daily clinical practice. The integration of imaging modalities, molecular and microbiological tests, and host-response-based classifiers with AI algorithms enhances diagnostic accuracy and facilitates clinical decision-making. In the context of treatment, AI supports patient management by enabling personalized antibiotic selection, optimizing treatment duration, predicting resistance, and providing clinical decision support. For infection control, AI-driven applications such as early outbreak detection, real-time surveillance, hand hygiene monitoring, and environmental disinfection are becoming more prevalent. Despite these advancements, challenges persist, including data heterogeneity, limited algorithmic explainability, ethical and legal considerations, and concerns regarding patient privacy. With multidisciplinary collaboration, high-quality data generation, and robust regulatory frameworks, AI systems are anticipated to become reliable and effective decision-support tools in infectious diseases practice.

Keywords: Artificial intelligence, infectious diseases, infection control, antimicrobial stewardship

GİRİŞ

Yapay zekâ, bilgisayar biliminin, insan zekâsı gerektiren görevleri yerine getirebilen sistemler geliştirmeye odaklanan bir dalıdır (1). Yapay zekânın temel amacı, makinelerin çevrelerini algılayabilmesi, edindikleri bilgileri kullanarak yeni durumlara uyum sağlayabilmesi ve insan benzeri düşünme, akıl yürütme, öğrenme ve karar verme süreçlerini taklit edebilmesidir. Bu bağlamda yapay zekâ; sağlık, finans, eğitim, üretim ve ulaşım gibi birçok farklı alanda sorunların çözümünde, süreçlerin otomasyonunda ve verimliliğin artırılmasında kullanılmaktadır.

MAKİNE ÖĞRENMESİ PARADİGMALARI VE MODEL MİMARİLERİ

Makine öğrenmesi (machine learning), yapay zekânın bir alt disiplini olup büyük miktarda veriyi işleyerek açıkça programlanmadan öğrenen; doğal dili anlama, örüntü tanıma, problem çözme, tahminde bulunma ve karar verme gibi işlevleri yerine getiren istatistiksel algoritmaların geliştirilmesi ve incelenmesiyle ilgilenir (2).

Cite this article as: Er AG, Gülten E, Temoçin F, Aktuğ-Demir N. [Artificial intelligence in infectious diseases and clinical microbiology: Current and future directions]. Klimik Derg. 2026;39(1):1–10. Turkish. **Sorumlu Yazar / Correspondence:** Ezgi Gülten, **E-posta / E-mail:** ezgiioztop@gmail.com, **Gelis / Received:** 23 Eylül / September 2025, **Kabul / Accepted:** 13 Aralık / December 2025, **Yayın Tarihi / Published Date:** 24 Mart / March 2026, **DOI:** 10.36519/kd.2026.5400

Makine Öğrenmesi Paradigmaları

Makine öğrenmesi, hedeflenen sonuca göre gözetimli öğrenme, gözetimsiz öğrenme ve pekiştirmeli öğrenme şeklinde temel öğrenme paradigmlarına ayrılmaktadır. Gözetimli öğrenmede model, önceden etiketlenmiş veriler üzerinden eğitilir; veri ve etiketler modele birlikte sunulur ve model bu ilişkiyi öğrenerek yeni veriler üzerinde doğru tahminler yapmaya çalışır. Örneğin, bir gözetimli öğrenme paradigması, binlerce etiketli akciğer görüntüsüyle eğitilerek yeni bir görüntüde hastalık varlığını sınıflandırabilir.

Gözetimli öğrenmeden farklı olarak gözetimsiz öğrenme, etiketli verilerin bulunmadığı durumlarda kullanılır. Bu yaklaşımın amacı, verilerdeki gizli yapıları, grupları veya örüntüleri ortaya çıkarmaktır. Kümeleme ve boyut indirgeme bu yöntemin tipik örnekleri arasında yer almaktadır. Örneğin, gözetimsiz bir paradigma hastalık belirtilerine göre benzer hasta gruplarını belirleyebilir.

Pekiştirmeli öğrenme ise önceki iki paradigmadan farklı bir yaklaşım izler. Bu yöntemde bir ajan, bir ortamda eylemler gerçekleştirir ve aldığı ödül veya ceza sinyalleri aracılığıyla zamanla en uygun stratejiyi öğrenir. Satranç oynayan yapay zekâ sistemleri veya otonom araçların sürüş davranışlarını geliştiren uygulamalar bu öğrenme tipine örnek olarak gösterilebilir (3).

Bu ana sınıflara ek olarak yarı gözetimli öğrenme, sınırlı miktarda etiketli veri bulunduğu ve geri kalan büyük veri kümesinin etiketsiz olduğu durumlarda kullanılır. Model, az sayıdaki etiketli örnekten edindiği bilgiyi etiketsiz verilerle birleştirerek genelleme yeteneğini artırır. Bu yöntem, etiketleme maliyetinin yüksek veya zor olduğu tıp, biyoloji ve doğal dil işleme gibi alanlarda özellikle öne çıkmaktadır (4).

Öz-denetimli öğrenme (self-supervised learning) ise son yıllarda önem kazanan bir diğer yaklaşımdır. Bu yöntem verinin kendi içindeki yapıları kullanarak yapay etiketler üretir ve modelin bu görevler üzerinden eğitilmesini sağlar. Böylece model, büyük miktarda etiketsiz veriden güçlü temsiller öğrenebilir ve daha sonra sınırlı etiketli veriyle farklı görevlerde yüksek başarı gösterebilir (5). Bir görselde gizlenmiş bir bölümün tahmin edilmesi veya bir cümlede eksik kelimenin doldurulması bu yaklaşımın tipik örnekleri arasında yer almaktadır.

Model Mimarileri

Makine öğrenmesinde kullanılan paradigmların yanı sıra, belirli görevlerde yüksek başarı gösteren çeşitli model mimarileri de geliştirilmiştir.

ÖNE ÇIKANLAR

- Yapay zekâ, radyolojik görüntüleme, moleküler testler ve konak yanıt profillerinin analizi yoluyla enfeksiyon hastalıklarının tanısında doğruluğu ve hızını artırmaktadır.
- Klinik karar destek sistemleri, kişiselleştirilmiş tedavi ve antibiyotik seçimi süreçlerinde uygun olmayan reçeteleme oranlarını azaltma potansiyeli taşımaktadır.
- Enfeksiyon kontrolünde yapay zekâ tabanlı süreyans ve erken uyarı sistemleri, sağlık bakımı ilişkili enfeksiyonların ve salgınların erken tespitine katkı sağlamaktadır.
- Antimikrobiyal yönetim alanında yapay zekâ, direnç öngörüsü, antibiyotik kullanım örüntülerinin izlenmesi ve hasta bazlı antibiyotik önerileriyle karar süreçlerini desteklemektedir.
- Veri kalitesi, algoritmik şeffaflık, hasta mahremiyeti, etik ve hukuki düzenlemeler, yapay zekânın klinik uygulamalara entegrasyonunda başlıca sınırlılıklar olmakla birlikte multidisipliner iş birliği güvenli kullanımın anahtarıdır.

Bu yapılardan biri evrişimli sinir ağlarıdır (convolutional neural networks, CNNs) ve özellikle görüntü işleme alanında öne çıkmaktadır. Evrişimli sinir ağları, çok katmanlı evrişim ve ortaklama (pooling) katmanları aracılığıyla görsel verilerdeki yerel örüntüleri ve hiyerarşik özellikleri öğrenebilir (6).

Tekrarlayan yapay sinir ağları (recurrent neural networks, RNNs) ise sıralı verilerin analizi için tasarlanmış olup geçmiş bilginin bellekte tutulmasını sağlayarak zaman serileri, konuşma tanıma ve doğal dil işleme gibi ardışık verilerle ilgili görevlerde kullanılmaktadır (7). Ancak uzun vadeli bağımlılıkların öğrenilmesinde karşılaşılan zorluklar nedeniyle bu mimariler, yerini giderek “transformer” tabanlı modellere bırakmıştır.

“Transformer” mimarisi, dikkat (attention) mekanizmasını kullanarak verilerdeki uzun vadeli bağımlılıkları verimli biçimde modelleyebilir. Bu yaklaşım, doğal dil işleme başta olmak üzere görüntü analizi ve çok modlu öğrenme alanlarında günümüzde en yaygın kullanılan yöntemlerden biri hâline gelmiştir (8). ChatGPT-4 gibi büyük dil modelleri (large language models, LLMs) de “transformer” mimarisi üzerine inşa edilmiş, çok büyük ölçekli modellerdir.

Çekişmeli üretici ağlar (generative adversarial networks, GANs) ise bir üretici (generator) ve bir ayırt edici (discriminator) ağdan oluşan çift yapı bir mimari kullanır. Bu iki ağın karşılıklı etkileşimi yoluyla gerçek verilere oldukça yakın sentetik veriler üretilebilmektedir (9). Çekişmeli üretici ağlar, görüntü sentezi, yapay veri üretimi ve yaratıcı uygulamalar gibi alanlarda etkili sonuçlar ortaya koymuştur. Bu farklı mimariler, yapay zekânın çeşitli problem türlerine uyarlanabilmesi için zengin ve esnek araçlar sunmaktadır.

Sağlık Bakımında Dönüşüm ve Veri Yönetimi

Sağlık sistemleri; hasta ve hasta yakınlarından sağlık yöneticileri ve çalışanlarına, özel sektör ve teknoloji sağlayıcılarından akademik kurumlara ve araştırmacılara kadar tüm paydaşlar açısından karmaşık ve zorlu yapılarıdır. Yapay zekâ, son yıllarda birçok alanda olduğu gibi sağlık alanında da dönüşüm yaratmış, hasta bakımını ve yaşam kalitesini iyileştirme potansiyelini ortaya koymuştur. Yapay zekânın sağlık sistemlerine entegrasyonu ile tanı, tedavi ve laboratuvar uygulamalarında iyileşme sağlanması, büyük verinin tahmin modellerinde kullanılması, maliyetlerin azaltılması, zaman tasarrufu ve insan kaynaklı hataların en aza indirilmesi gibi önemli avantajlar elde edilmektedir (10).

Sağlık sistemlerinde büyük verinin yönetimi, sunduğu fırsatların yanı sıra beraberinde getirdiği zorluklar nedeniyle kritik bir öneme sahiptir. Veri çeşitliliği ve mahremiyeti ile verinin toplanması, saklanması, işlenmesi ve yorumlanması süreçlerinin her biri ciddi teknik ve organizasyonel güçlükler içermektedir (11). Elektronik sağlık kayıtları, laboratuvar sonuçları ve klinik notlar gibi yapılandırılmış veya yapılandırılmamış klinik veriler; histopatoloji slaytları, immüno Floresans boyamalar, tek hücre transkriptomik veya coğrafi transkriptomik veriler gibi patoloji verileri; moleküler veriler; X-ışını, bilgisayarlı tomografi, manyetik rezonans veya ultrasonografi gibi görüntüleme yöntemlerine ait veriler; giyilebilir sensör verileri; elektrokardiyografi, elektroensefalografi ve mekanik ventilatör verileri ile matriks ile desteklenmiş lazer desorpsiyon/ionizasyon uçuş zamanı kütle spektrometresi (MALDI-TOF-MS) çıktıları dâhil olmak üzere çok sayıda veri türü sağlık verisi kapsamında değerlendirilerek vektörize edilebilmekte ve yapay zekâ araçlarıyla birleştirilerek analiz edilebilmektedir (12).

Çok boyutlu ve çok modlu veri füzyonu olarak tanımlanan yaklaşım, veri bilimi çalışmalarında önemli bir yer bulmuş; enfeksiyon hastalıkları ve klinik mikrobiyoloji alanlarında da kullanılmaya başlanmıştır (13). Kişiselleştirilmiş tedavilerden yeni nesil tıbbi uygulamalara kadar pek çok alanda yenilikçi çözümler sunarak sağlık hizmetlerinin kalitesini artıran

ve mali avantajlar sağlayan bu yaklaşım, modern sağlık hizmetlerinde dönüştürücü bir potansiyele sahiptir.

Bu derlemede; infeksiyon hastalıklarının tanı ve tedavisinde, infeksiyon kontrolü ve antimikrobiyal yönetim (AMY) alanlarında güncel yapay zekâ uygulamalarının özetlenmesi ve karşılaşılabilecek olası zorlukların ve geleceğe yönelik perspektifin sunulması amaçlanmaktadır.

İNFEKSİYON HASTALIKLARININ TANISINDA YAPAY ZEKÂ

Tarih boyunca insanlık için en büyük tehditlerden biri olan infeksiyon hastalıkları, milyonlarca insanın yaşamını yitirmesine yol açmış ve toplumların yapısını derinden etkilemiştir. Bu hastalıklarla mücadelede dönüm noktalarından biri, 17. yüzyılda Antonie van Leeuwenhoek'un geliştirdiği mikroskopla mikroorganizmaların varlığını ilk kez gözlemlemesi olmuştur. Robert Hooke'un *Micrographia* adlı eserinde mikro dünyaya dair yaptığı çizimler, infeksiyon etkenlerinin keşfi ve anlaşılması yolunda çığır açmıştır. On dokuzuncu yüzyılda Louis Pasteur ve Robert Koch'un öncülüğünde mikrobiyoloji biliminin gelişmesiyle, patojenlerin izolasyonu, tanımlanması ve salgınların nedenlerinin anlaşılması mümkün hâle gelmiştir (14). Yirminci yüzyılda aşılardan yaygınlaştırılması, antibiyotiklerin keşfi ve hijyen uygulamalarının geliştirilmesi sayesinde infeksiyon hastalıklarıyla mücadelede önemli başarılar elde edilmiştir. Buna karşın günümüzde artan antibiyotik direnci, küreselleşme ile hızla yayılan zoonotik patojenler ve bağışıklık sistemi baskılanmış bireylerin sayısındaki artış gibi etkenler nedeniyle infeksiyon hastalıklarının tanısı ve kontrolü hâlen büyük önem taşımaktadır.

Geleneksel tanı yöntemleri (kültür, mikroskopi ve seroloji) infeksiyon etkenlerinin tespitinde temel ve değerli yaklaşımlar olmakla birlikte, zaman alıcı olmaları, duyarlılıklarının sınırlı olması ve uygulamalarının büyük ölçüde uzman deneyimine ve yetkinliğine bağlı olması önemli kısıtlılıklar arasında yer almaktadır. Son yıllarda yapay zekâ teknolojileri, büyük hacimli sağlık verilerini işleyerek daha hızlı, duyarlı ve doğru tanı koyma potansiyeli nedeniyle dikkat çekmektedir. Bu bölümde, yapay zekânın infeksiyon hastalıkları tanısındaki rolü; radyolojik analiz, moleküler ve mikrobiyolojik testler, konak yanıtına dayalı sınıflayıcılar ve alternatif yaklaşımlar başlıkları altında ele alınacak, güncel literatür eşliğinde durum değerlendirmesi yapılacaktır.

Radyolojik Görüntü Analizi ile Tanı

Radyoloji, yapay zekânın infeksiyon hastalıkları tanısına önemli katkılar sunduğu öncü alanlardan biridir. Derin öğrenme tabanlı görüntü analiz algoritmaları, özellikle akciğer infeksiyonlarında, radyologların iş yükünü azaltabilecek ve tanı doğruluğunu artıracak şekilde geliştirilmiştir. Örneğin, akciğer grafilerinde tüberküloz odaklarının saptanmasında yapay zekâ destekli tarama sistemlerinin uzman radyologlarla karşılaştırılabilir performans düzeylerine ulaştığı bildirilmiştir (15). Bu ilerleme sayesinde Dünya Sağlık Örgütü (DSÖ) tarafından 2021 yılında tüberküloz taramasında dijital akciğer grafilerinin otomatik değerlendirilmesinde yapay zekâ destekli yazılımların kullanılması önerilmiş ve hekimler yerine bilgisayar destekli tanı (computer-aided diagnosis, CAD) yazılımlarının erişkin taramalarında yer alabileceğini belirtilmiştir (16). Akciğer grafilerindeki anormallikleri yüksek duyarlılık oranlarıyla tespit edebilen bilgisayar destekli tanı sistemleri, sınırlı kaynağa sahip bölgelerde semptom taramasına ek olarak pratik bir triyaj aracı olarak da kullanılmaktadır.

Derin öğrenme algoritmaları, tüberküloz dışındaki diğer akciğer infeksiyonlarının tanısında da umut verici sonuçlar ortaya koymaktadır. Koronavirüs hastalığı 2019 (COVID-19) pandemisi sürecinde çok sayıda çalışma, akciğer bilgisayarlı tomografisi ve akciğer grafilerinde yapay zekâ kullanılarak viral pnömoninin tespit edilmesine odaklanmıştır. Bazı

platformların COVID-19 pnömonisini yüksek doğruluk oranlarıyla tanımlayabildikleri bildirilmiştir. Örneğin, 2020 yılında gerçekleştirilen bir çalışmada geliştirilen derin öğrenme modelinin, açık veri setleri üzerinden eğitilerek COVID-19 ilişkili viral pnömoniye başarılı bir şekilde tanımlayabildiği bildirilmiştir (17). Bununla birlikte, bu tür algoritmaların gerçek yaşam koşullarında rutin klinik kullanıma girebilmesi için farklı popülasyonları ve görüntüleme cihazlarını kapsayan geniş ölçekli validasyon çalışmalarına gereksinim bulunmaktadır.

Moleküler Tanı ve Mikrobiyoloji Uygulamaları

Mikrobiyoloji laboratuvarlarında yapay zekâ hem doğrudan patojen tespitinde hem de antibiyotik duyarlılık testlerinin hızlandırılmasında kullanılmaktadır. Büyük ve karmaşık verileri (MALDI-TOF-MS çıktıları, genom dizileri, mikroskopi görüntüleri, vb.) analiz etme yeteneği sayesinde yapay zekâ, geleneksel yöntemlerin sınırlarını genişletmektedir. Örneğin, MALDI-TOF-MS verilerinin makine öğrenmesi ile işlenmesi, tür ve alt tür düzeyinde ayırt edici tanı koymayı mümkün kılmıştır. Yapılan bir çalışmada MALDI-TOF-MS verilerinin yapay zekâ ile analizi sonucunda *Staphylococcus aureus*'un iki alt tipinin %100 doğrulukla sınıflandırıldığı bildirilmiştir (18). Benzer şekilde, açık kaynaklı bir yazılım olan *Findaureus*, immüno Floresans boyalı doku kesitlerinde bakteri odaklarını otomatik olarak tespit ederek geleneksel manuel eşikleme süreçlerini ortadan kaldırmıştır (19). Bu tür yenilikler, karmaşık örneklerde patojen aranmasını kolaylaştırarak tanı süreçlerini hızlandırmaktadır.

Mikrobiyolojide yapay zekâ desteği, kültür tabanlı yöntemlerle günler sürebilen antimikrobiyal duyarlılık testlerinin süresinin kısaltılmasına da katkı sağlamaktadır. Örneğin, görüntü analiz yazılımları otomatik ekim ve koloni tanıma sistemleriyle bütünleşerek idrar yolu infeksiyonu etkenlerinin ve direnç profillerinin saatler içinde belirlenmesini mümkün kılmaktadır (20). Bir diğer örnek olarak, dijital görüntüleme kullanılarak Grup B streptokok tespitine yönelik geliştirilen bir sistemin, duyarlılık açısından moleküler yöntemlere benzer performans sergilediği ve laboratuvar verimliliğini artırdığı bildirilmiştir (21). Ayrıca DNA mikroarray tabanlı bir makine öğrenmesi platformunun, solunum yolu infeksiyonlarıyla ilişkili 11 farklı bakteriyi yaklaşık 4 saat içinde >%95 doğrulukla saptayabildiği gösterilmiştir (22). Mikroskobik incelemelerde de yapay zekâ hız ve duyarlılığın artırılmasına katkı sağlamaktadır. Özellikle tüberküloz gibi tanısı zor hastalıklarda, balgam yaymalarının otomatik taranmasına yönelik geliştirilen derin öğrenme tabanlı sistemler klinik uygulamaya girmeye başlamıştır. Örneğin, floresan boyalı preparatların otomatik mikroskobik tarayıcılarla incelenip bir derin sinir ağı tarafından yorumlanması sayesinde bir preparatın değerlendirme süresi birkaç dakikadan yaklaşık 10 saniyeye kadar düşürülmüştür (23). Böylece yapay zekâ destekli sistemler, infeksiyon etkenlerinin daha çabuk tanınmasına ve erken tedaviye olanak sağlamaktadır.

Konak Yanıt Profilleri ve mRNA Sınıflayıcılar

Patojenin saptanmasının yanı sıra, konak bağışıklık yanıtının ölçülebilir profilleri yoluyla infeksiyon varlığını ve tipini belirlemek de son yıllarda dikkat çekici bir alan hâline gelmiştir. İnfeksiyon varlığında insan vücudu tarafından üretilen haberci (messenger) RNA (mRNA), mikroRNA ve çeşitli protein biyobelirteçlerinin karmaşık örüntüleri, yapay zekâ algoritmalarıyla analiz edilerek tanı için anlamlı bilgiler elde edilebilmektedir. Bu yaklaşım klinik pratikte kritik bir sorun olan viral ve bakteriyel infeksiyonların ayırt edilmesi amacıyla geliştirilen gen ekspresyon temelli analizleri öne çıkarmaktadır.

2020 yılında yayımlanan kapsamlı bir çalışmada, akut infeksiyon hastalığı şüphesi olan hastalarda, kandan ölçülen 29 mRNA düzeyinin analiz edilmesiyle viral ve bakteriyel infeksiyonları ayırt edebilen bir sinir ağı modeli ortaya konmuştur; 18 farklı kohorttan 1069 hastanın verisiyle eğitilen bu modelin, yeni verilerle de genellenebilir bir performans sergilediği ve her

iki enfeksiyon türünü yüksek doğrulukla tespit edebildiği bildirilmiştir. Söz konusu modelin, klinisyene enfeksiyon etiyolojisine ilişkin hızlı bir öngörü sunarak gereksiz antibiyotik kullanımının azaltılmasına katkı sağlayabileceği değerlendirilmektedir (24).

Aynı araştırma ekibi tarafından geliştirilen mRNA paneli, COVID-19 pandemisi sırasında da uygulanmış; acil servise başvuran hastalarda bakteriyel ve viral enfeksiyon ayırımında eğrinin altında kalan alanın (area under the receiver operating characteristic curve, AUROC) 0.94 gibi çok yüksek bir değere ulaştığı bildirilmiştir. Bu performansın, geleneksel biyobelirteçler olan prokalsitonin ve C-reaktif proteine kıyasla belirgin biçimde daha üstün olduğu gösterilmiştir (sırasıyla AUROC $\approx$ 0.88 ve 0.80). Söz konusu test prototipi, enfeksiyon hastalıklarından şüphelenilen hastalarda bakteriyel enfeksiyonu dışlama veya doğrulama amacıyla eşik değerler de tanımlayarak klinik kararlara doğrudan katkı sunacak şekilde tasarlanmıştır. Örneğin, “yüksek olasılıkla bakteriyel” çıkan sonuç grubunda %98 özgüllükle pozitif öngörü değeri elde edilirken, “düşük olasılıkla bakteriyel” grubunda %95 duyarlılıkla güvenli bir dışlama yapılabildiği bildirilmiştir. 2020 yılında geliştirilen bu model, yeni hasta verileri ile güçlendirilerek 2025 yılında bir pilot çalışma ile son ürün hâline getirilmiştir (25).

Konak yanıtı profillerine dayalı yapay zekâ uygulamalarının en somut çıktılarından biri, sepsis gibi yaşamı tehdit eden enfeksiyon sendromlarının erken tespitidir. Yapay zekâ destekli risk skorlama sistemleri, çok sayıda klinik veriyi entegre ederek hekime hastada sepsis gelişme olasılığına ilişkin nicel bir risk skoru sunabilmektedir. Örneğin, 2024 yılında Amerika Birleşik Devletleri Gıda ve İlaç Dairesi (United States Food and Drug Administration, FDA) onayı alan Sepsis ImmunoScore, acil servise veya hastaneye kabul edilen hastalarda 24 saat içinde sepsis gelişme riskini öngörmek için tasarlanmış ilk yapay zekâ tabanlı tanısal yazılımdır. Bu sistem, elektronik sağlık kayıtlarından elde edilen vital bulgular, laboratuvar sonuçları ve biyobelirteçler dahil olmak üzere 22 farklı parametreyi analiz ederek bir risk skoru hesaplamakta ve hastaları dört farklı risk kategorisinden birine atamaktadır. Sepsis ImmunoScore’un, klinisyenlere hastanın biyolojik durumuna ilişkin kapsamlı bir bakış sunarak sepsisin erken tanınmasını ve uygun tedavinin zamanında planlanmasını kolaylaştırmayı amaçladığı bildirilmiştir (26). Amerika Birleşik Devletleri Gıda ve İlaç Dairesi onayının alınmış olması, bu yaklaşımın klinik doğrulamasının yapıldığını ve güvenli şekilde kullanılabileceğini göstermesi bakımından önemlidir.

Benzer şekilde, son yıllarda gerçekleştirilen çok merkezli, retrospektif ve prospektif olarak hasta örnekleri üzerinde yapılan testlere dayanarak SeptiCyte RAPID’in klinik validasyonun yapıldığı çalışmada, makine öğrenmesi ile desteklenen bir immün yanıt skoru sayesinde acil servisteki hastalarda sepsisin hızlı ve erken tanısında ve ölüm riskinin öngörülmesinde anlamlı iyileşme sağlandığı gösterilmiştir (27).

İNFEKSİYON HASTALIKLARININ TEDAVISİNDE YAPAY ZEKÂ

Yapay zekâ tabanlı destek sistemleri, enfeksiyon hastalıklarının tedavisinde; kişiselleştirilmiş tedavi ve yeni tedavi stratejilerinin geliştirilmesinde, tahmine dayalı modellemelerde, klinik karar destek sistemleri ile tedavi optimizasyonunda, hasta eğitimi ve ilaç uyumunun artırılmasında, veri analizi ve görselleştirme ile ilaç keşfi gibi alanlarda kullanılmaktadır.

Kişiselleştirilmiş Tedavi

Yapay zekâ, hastaların bireysel özelliklerini ve hastanın enfeksiyon hastalıklarıyla ilişkili verilerini analiz ederek kişiselleştirilmiş tedavi planlarının oluşturulmasına katkı sağlayabilmektedir. Bu yaklaşım sayesinde tedavi etkinliğinin artırılması ve yan etkilerin azaltılması mümkün olabilmektedir (28–35).

Yeni Tedavi Stratejileri

Yapay zekâ, antimikrobiyallere dirençli enfeksiyonlarla mücadelede yeni tedavi kombinasyonlarının veya alternatif tedavi yaklaşımlarının geliştirilmesine katkı sunabilmektedir (28,31–33,35).

Tahmine Dayalı Modelleme

Yapay zekâ temelli modeller, antibiyotik direncinin yayılımını öngörerek gelecekteki direnç eğilimlerine karşı proaktif önlemler alınmasına yardımcı olabilir (28,36).

Klinik Karar Destek Sistemleri ile Tedavi Optimizasyonu

Klinik karar destek sistemleri klinisyenlere tanı, tedavi ve hasta yönetimi süreçlerinde yardımcı olan yazılım tabanlı araçlardır. Bu sistemler; hasta verilerini, yerel antibiyotik direnç profillerini ve güncel klinik kılavuzları entegre ederek klinisyenlere gerçek zamanlı tedavi önerileri sunabilmektedir. Ayrıca hastaların tedaviye verdikleri yanıtı izleyerek tedavi planlarının dinamik olarak optimize edilmesine ve potansiyel komplikasyonların önlenmesine katkıda bulunabilmektedir. Söz konusu sistemler, uygun olmayan antibiyotik reçetelerini saptayarak klinisyenleri uyarması ve geniş spektrumlu antibiyotikler yerine daha uygun dar spektrumlu ajanların tercih edilmesini teşvik etmesi açısından da önem taşımaktadır (28,29,31–35,37).

Hasta Eğitimi ve İlaç Uyumu

Yapay zekâ tabanlı sohbet robotları (chatbots), doğal dil işleme ve makine öğrenme algoritmalarını kullanarak kullanıcılarla etkileşim kurabilen sistemlerdir. Bu araçlar, antibiyotiklerin doğru kullanımı, direnç riskleri ve enfeksiyon kontrol önlemleri hakkında bilgilendirme yapmaktadır. Ayrıca ilaç alımını hatırlatan uyarılar göndererek ve tedavi sürecinde destek sunarak ilaç uyumunu artırmanın yanı sıra antibiyotik kullanımında görülebilen yan etkilerle ilgili duygusal destek de verebilmektedirler. Bu süreçte sohbet robotlarının 7/24 ulaşılabilir olması da önemli bir avantajdır. (28,29,31).

Veri Analizi ve Görselleştirme

Yapay zekâ tabanlı araçlar, antibiyotik direnciyle ilişkili büyük veri setlerini analiz ederek direnç modellerini ve eğilimlerini belirleyebilmekte ve bu verileri anlaşılır biçimde görselleştirerek sağlık profesyonellerine sunulabilmektedir. Bu sayede sürekli ve güncel epidemiyolojik veri tabanlarının oluşmasına da sağlanmaktadır (28).

İlaç Keşfi

Yapay zekâ tabanlı araçlar ile yeni antibiyotiklerin ve tedavi stratejilerinin geliştirilmesi hızlandırılabilmektedir. Mevcut ilaçların yeniden konumlandırılması veya yeni moleküllerin tasarlanması süreçlerinde, yapay zekâ algoritmaları, potansiyel adayların belirlenmesi ve ilaç geliştirme sürecinin optimize edilmesi amacıyla kullanılmaktadır (28,38).

Günümüzde Yapay Zekâ Tabanlı Destek Sistemlerinin Enfeksiyon Hastalıklarının Tedavisinde Kullanımı

Sistemik Derlemelerden Elde Edilen Bulgular

2016–2022 yılları arasında yapılan 18 çalışmayı inceleyen sistematik derlemede yapay zekâ uygulamalarının uygun antibiyotik tedavisini seçmede başarılı sonuçlar gösterdiği, uygun olmayan reçeteleme uygulamalarını belirlemede etkili olduğu, antibiyotik tedavisinin erken kesilmesi ile hastanede kalış süresini kısalttığı, ikinci basamak antibiyotik kullanımını %67 oranında azalttığı ve uygun olmayan antibiyotik tedavisini %18 oranında düşürdüğü, sepsis gibi ciddi sendromların erken teşhisinde, tedavisinde ve sonuçların iyileştirilmesinde yardımcı olabileceği, enfeksiyon tanısını koyma ve tedavi başarısını tahmin etmede başarılı sonuçlar elde ettiği bildirilmiştir. Ancak bu derlemede yapay zekânın sağlık alanında

kullanımına ilişkin etik, teknik ve düzenleyici zorlukların dikkatlice ele alınması gerektiği de vurgulanmıştır (30).

CBR Tabanlı Karar Destek Sistemleri

Rawson ve arkadaşları (39) tarafından 2017–2019 yılları arasında üç hastane yürütülen bir çalışmada, kan kültüründe *Escherichia coli* üremesi tespit edilen 145 hasta ile enfeksiyon hastalığı şüphesi olan 79 hastada “Case-Based Reasoning” (CBR) algoritmasının performansı değerlendirilmiştir. Bu çalışmada CBR tabanlı sistemin, hekim reçetelerine kıyasla daha dar spektrumlu antibiyotikleri önerdiği; algoritmanın antibiyotik önerilerinin %90 ve hekim reçetelerinin ise %83 oranında uygun olduğu bildirilmiştir. Elde edilen bulgular, CBR algoritmasının klinik uygulamada hekimlerin kararlarıyla benzer düzeyde olduğunu ve daha dar spektrumlu antibiyotik önerileri sunduğunu göstermiştir. Bu doğrultuda, CBR tabanlı klinik karar destek sistemlerinin AMY’yi iyileştirme ve antimikrobiyal direnç azaltılmasına katkı sağlama potansiyeline sahip olduğu bildirilmiştir.

ChatGPT-4 ve Büyük Dil Modelleri ile Karar Desteği

Cochin Üniversite Hastanesi’nde yürütülen prospektif gözlemsel bir çalışmada, kan kültüründe üreme tespit edilen 44 hasta 0. ve 3. günlerde bir enfeksiyon hastalıkları uzmanı ve ChatGPT-4 tarafından değerlendirilmiştir. ChatGPT-4’ün önerileri; 1 (%2) hastada uygun ve optimal, 17 (%39) hastada uygun ancak optimal değil ve 7 (%16) hastada ise zararlı olarak sınıflandırılmıştır. Ayrıca, ChatGPT-4’ün, 17 (%39) hastada enfeksiyon hastalıkları uzmanına danışılması gerektiğini önerdiği bildirilmiştir. Çalışmanın sonuç bölümünde, ChatGPT-4’ün uygun sonuçlar sunduğu ve doğru tıbbi terminolojiyi kullandığı, enfeksiyon hastalıkları danışmanlıklarını iyileştirmek için tıbbi asistan olarak ve özellikle enfeksiyon hastalıkları uzmanı olmayan hekimlerden gelen sorulara başlangıç yanıtı yazmak için kullanılabileceği belirtilmiştir. Bununla birlikte, karmaşık klinik senaryolarda henüz enfeksiyon hastalıkları uzmanının yerini alabilecek düzeyde olmadığı, klinik uygulamada kullanılmadan önce daha fazla geliştirilmesi ve titizlikle test edilmesi gerektiği vurgulanmıştır (28).

Karmaşık Klinik Senaryolarda Model Performansının Sınırları

De Vito ve arkadaşları (32) tarafından yürütülen bir çalışmada, endokardit, pnömoni, intra-abdominal enfeksiyonlar ve kan dolaşımı enfeksiyonlarına ilişkin doğru/yanlış, açık uçlu sorular ve antibiyogram içeren klinik olgulardan oluşan toplam 72 soru değerlendirilmiştir. Bu sorular dört enfeksiyon hastalıkları uzmanına, dört enfeksiyon hastalıkları asistanına ve ChatGPT-4’ün iki farklı sürümüne (standart ve eğitilmiş) yöneltilmiştir. Doğru/yanlış sorularında tüm grupların benzer performans göstermiş olduğu (~%70 doğru cevap) ve açık uçlu sorularda eğitilmiş ChatGPT-4’ün hem asistanlardan hem de uzmanlardan daha doğru ve eksiksiz yanıtlar verdiği bildirilmiştir. Ayrıca, klinik olgularda, ChatGPT-4’ün antibiyotik direnç mekanizmalarını tanımlamada daha düşük doğruluk gösterdiği ve daha eski antibiyotikleri tercih etme eğiliminde olduğu, tedavi sürelerini gereğinden uzun önerdiği ve eğitilmiş ChatGPT-4’ün standart versiyona göre daha iyi performans göstermekle beraber enfeksiyon hastalıkları uzmanlarının düzeyine ulaşmadığı ifade edilmiştir. Çalışmanın sonuçlarında, ChatGPT-4’ün teorik soruların yanıtlanmasında etkili olmasına karşın karmaşık klinik senaryolarda uzmanların karar verme yeteneğine tam olarak erişemediği, ChatGPT-4’ün tıp eğitimi ve ön tanısal değerlendirmelerde destekleyici bir araç olarak kullanılabileceği, ancak uzman konsültasyonunun yerini almaması gerektiği belirtilmiştir. Ayrıca, ChatGPT-4’ün tıp alanındaki potansiyelini ve sınırlamalarını ortaya koyarak, bu tür araçların klinik uygulamalarda dikkatli bir şekilde kullanılması gerektiği de vurgulanmıştır.

ChatGPT’nin Klinik Karar Süreçlerindeki Riskleri

Sarin ve arkadaşları (33) tarafından yürütülen çalışmada, Hollanda’daki üçüncü basamak bir hastanede oluşturulan 40 klinik enfeksiyon senaryosuna yönelik tanı ve tedavi önerileri ChatGPT tarafından üretilmiş ve bu öneriler enfeksiyon hastalıkları ile klinik mikrobiyoloji uzmanlarının

görüşleriyle karşılaştırılmıştır. ChatGPT’nin önerileri, 1 (kötü; yanlış veya uygun olmayan öneri) ile 5 (mükemmel; uzman önerileriyle tamamen uyumlu) arasında derecelendirilmiştir. Değerlendirme sonucunda ChatGPT’nin genel ortalama puanının 2.8 olduğu ve pozitif kan kültürü sonuçlarının yorumlanmasına ilişkin senaryolarda ortalama puanın 3.3’e yükseldiği görülmüştür. Öte yanda osteomyelit ve protez eklem enfeksiyonu gibi daha karmaşık klinik durumlarda tanı ve tedavi önerilerinin 1.3 ortalama ile belirgin biçimde daha düşük puan aldığı bildirilmiştir. Ayrıca çalışmada, ChatGPT’nin bazı senaryolarda mevcut klinik bilgileri yeterince dikkate almadığı, daha önce yapılmış görüntüleme incelemelerini göz ardı ederek ek görüntüleme önerilerinde bulunduğu ve gerçekte var olmayan kaynaklara atıf yaptığı gözlenmiştir. Sonuç olarak, ChatGPT’nin belirli durumlarda orta düzeyde tanı ve tedavi önerileri sunabildiği ancak klinisyenlerin karar verme yetkinliğinin yerini alamayacağı bildirilmiş; bu tür araçların ancak uzman bir klinisyenin gözetimi altında, destekleyici amaçla kullanılmasının uygun olacağı ifade edilmiştir.

Tedavi Optimizasyonu: OptAB Modeli

Wendland ve arkadaşları (34) tarafından sepsis hastalarında yan etkileri de dikkate alarak optimal antibiyotik seçimini desteklemek amacıyla yapılan çalışmada, veriye dayalı ve çevrimiçi olarak güncellenebilen OptAB modeli değerlendirilmiştir. Çalışmada, “Hastalık seyri ve tedavi etkinliği 1 saatlik, 4–5 saatlik ve 24–48 saatlik zaman aralıklarında tahmin edebilir mi?” ve “Bu tahminler, klinisyenlere hastanın durumunu sürekli olarak değerlendirme ve tedavi kararlarını optimize etme olanağı sunabilir mi?” sorularına yanıt aranmıştır. Modelin, çevrimiçi güncellenebilir özelliği sayesinde yeni klinik veriler elde edildikçe tahminlerini güncelleyebildiği; hastaların tedavi süreçlerini daha etkili ve güvenli hâle getirdiği; “Sequential Organ Failure Assessment” (SOFA) skoru ve laboratuvar tetkik sonuçlarının değişimine göre eskalasyon/de-eskalasyon ve doz değişimi önerebildiği ve yan etki tespiti yapabildiği bildirilmiştir. Çalışmanın bulguları doğrultusunda, OptAB modelinin gelecekteki sürümlerinde, daha fazla antibiyotiklerin modele entegre edilmesinin planlanabileceği, bölgesel antibiyotik direnç profillerini ve epidemiyolojik verileri kullanarak hangi antibiyotiklerin hangi bölgelerde daha etkili olacağının öngörebileceği ve hastaların bireysel özelliklerine göre daha geniş bir antibiyotik yelpazesi sunulabileceği ifade edilmiştir.

Erken Uyarı Sistemleri ve Ampirik Tedavi Uygunluğu

Goldschmidt ve arkadaşlarının (35) 2001–2012 yılları arasında yoğun bakım ünitelerinde yürüttükleri çalışmada, ampirik antibiyotik tedavisinin uygunluğunu öngörmek ve yapay zekâ temelli bir sistemin klinisyenlere erken uyarı sağlayıp sağlamayacağını değerlendirmek amaçlanmıştır. Bu kapsamda, 105 hastaya ait ilk 24–72 saatlik klinik ve laboratuvar verileri kullanılarak geliştirilen modelin, antibiyogram sonuçları elde edilmeden önce ampirik tedavinin uygunluğunu tahmin edebildiği gösterilmiştir. Çalışmada yapay zekâ modeli, 83 hastada ampirik antibiyotik tedavisini uygun, 22 hastada ise uygunsuz olarak sınıflandırmıştır.

Çalışmada modelin hem eğitim hem de harici doğrulama kümelerinde tutarlı bir performans gösterdiği ve farklı veri kümelerinde de benzer sonuçlar verdiği bildirilmiştir. Ayrıca, sistemin antibiyogram sonuçları alınmadan, klinisyenlere erken uyarı sunarak tedavinin yeniden değerlendirilmesine olanak sağlayabileceği ve bu yaklaşımın ampirik tedavi uygunluğunu artırarak antibiyotik direnciyle mücadelede katkı yapacağı ifade edilmiştir. (35).

İNFEKSİYON KONTROLÜ VE ANTİMİKROBİYAL YÖNETİŞİMDE YAPAY ZEKA

İnfeksiyon kontrolü ve AMY uygulamaları, sağlık hizmetlerinin kalitesini ve hasta güvenliğini doğrudan etkileyen kritik alanlardır. Sağlık bakımı

ilişkili enfeksiyonların (SBİİ'ler) artan sıklığı ve antibiyotik direncinin küresel düzeyde önemli bir halk sağlığı tehdidi hâline gelmesi, bu alanlarda daha yenilikçi ve veriye dayalı yaklaşımların benimsenmesini gerekli kılmıştır. Bu bağlamda yapay zekâ, enfeksiyon kontrolü ve AMY'de karar alma süreçlerini destekleme, erken uyarı sistemlerini geliştirme, süreyans verilerini analiz etme ve klinik rehberliğin optimize edilmesine katkı sunma potansiyeli ile dikkat çekmektedir (40).

Dünya Sağlık Örgütü'nün 2024 yılında yayımladığı *Antimikrobiyal Dirençle Mücadele İçin Küresel Eylem Çağrısı* raporunda, antimikrobiyal dirençle mücadelede büyük veri analitiği, gerçek zamanlı izleme sistemleri ve yapay zekâ temelli risk öngörü modellerinin küresel eylem planlarında merkezi bir rol üstlenmesi gerektiği vurgulanmaktadır (41).

Geleneksel enfeksiyon kontrol yöntemleri çoğunlukla geriye dönük ve manuel uygulamalara dayandığından, zaman alıcı ve insan hatasına açık olup ciddi bir kaynak tüketimine yol açmaktadır. Buna karşılık, yapay zekâ algoritmaları çok boyutlu büyük veri kümelerini işleyerek gerçek zamanlı analiz ve öngörü sağlamada kullanılabilir; bu sayede enfeksiyonların önlenmesi ve kontrolüne yönelik daha proaktif yaklaşımların geliştirilmesine olanak tanımaktadır (42).

İNFEKSİYON KONTROLÜNDE YAPAY ZEKÂ UYGULAMALARI

Sağlık Bakımı İlişkili Enfeksiyonların Sürveyansı

Yapay zekâ tabanlı enfeksiyon sürveyans sistemleri; hasta kayıtları, laboratuvar sonuçları, vital bulgular ve invazif araç kullanımı gibi çok kaynaklı verileri analiz ederek SBİİ'lerin erken tanınmasına olanak sağlamaktadır. Özellikle "random forest" gibi denetimli öğrenme algoritmalarının, kateter ilişkili üriner sistem enfeksiyonu, cerrahi alan enfeksiyonu ve ventilatör ilişkili pnömöni gibi SBİİ'leri yüksek duyarlılık ve özgüllükle öngörebildiği bildirilmiştir (43).

Prospektif gözlemsel bir çalışmada, yapay zekâ algoritmalarının klasik manuel sürveyansa yaklaşımlarına kıyasla daha fazla enfeksiyonu tespit ettiği ve enfeksiyon kontrol ekiplerine zaman kazandırdığı gösterilmiştir (44). Ayrıca yapay zekâ sistemlerinin enfeksiyon risk haritaları hazırlayarak üniteler arası karşılaştırmalara ve kaynak planlamasına katkı sağladığı bildirilmiştir (45).

Risk Tahmini ve Erken Uyarı Sistemleri

Yapay zekâ modelleri, vital bulgular, laboratuvar sonuçları ve invazif cihaz kullanımı gibi dinamik klinik verileri analiz ederek belirli enfeksiyonların gelişme riskini öngörebilmekte ve bu yolla hem klinisyenleri hem de enfeksiyon kontrol ekiplerini proaktif biçimde uyarabilmektedir. Özellikle dirençli mikroorganizmaların neden olduğu enfeksiyonlarda erken farkındalık sağlayarak, zamanında ve uygun müdahalelere olanak tanımakta ve klinik karar süreçlerine destek sunmaktadır (46).

Clostridioides difficile ve çok ilaca dirençli Gram-negatif mikroorganizmaların neden olduğu enfeksiyonlar için geliştirilen risk tahmin modellerinde, doğruluk oranlarının %90 düzeylerine ulaştığı bildirilmiş; bu sayede yüksek riskli hastaların erken dönemde tanımlanabildiği gösterilmiştir (47,48). Bu modellerin klinik karar destek sistemleri ile entegrasyonunun, enfeksiyon gelişimini önlemeye yönelik stratejilerin zamanında uygulanmasına katkı sağlayabileceği de belirtilmektedir (47,48).

El Hijyeni Eğitimi ve İzlemi

El hijyeni, enfeksiyon kontrolünün temel taşıdır. Gözlemci temelli izlemlerin sınırlamaları ve gözlem yanlılığı, objektif ölçüm sistemlerine olan ihtiyacı artırmıştır. Bu doğrultuda geliştirilen yapay zekâ destekli görüntü tanıma

sistemleri ve sensörlü el dezenfektan üniteleri, sağlık çalışanlarının el hijyeni uygulamalarını gerçek zamanlı ve bireysel düzeyde izleyebilmektedir (49). Derin öğrenme tabanlı video analiz sistemleri ise uygun ve uygun olmayan el hijyeni uygulamalarını yüksek doğrulukla ayırt edebilmekte ve anlık raporlama sağlayabilmektedir. "Soapy" olarak adlandırılan akıllı el yıkama istasyonunun, oyunlaştırma ve kişiselleştirilmiş geri bildirim yaklaşımları aracılığıyla el hijyeni uyumunu artırdığı gösterilmiştir (50).

Ortam Dezenfeksiyonu ve Ultraviyole-C Robotları

COVID-19 pandemisi ile ortam temizliği ve yüzey dezenfeksiyonunun önemi daha da belirginleşmiştir. Bu kapsamda yapay zekâ algoritmalarıyla yönlendirilen ultraviyole-C (UV-C) robotları, konvansiyonel temizlik yöntemlerine yardımcı olarak standardizasyonun artırılmasına ve temizlik kalitesinin iyileştirilmesine katkıda bulunmaktadır (51). Ayrıca, UV-C robotlarının, haritalama ve rota planlama algoritmaları aracılığıyla ortamın tüm yüzeylerini kapsayacak biçimde çalışabildiği bildirilmiştir (51). Bununla birlikte, UV-C robotlarının etkinliğinin ön temizlik uygulamalarına bağımlı olduğu ve dezenfeksiyonda tek başına yeterli olmadığı göz önünde bulundurularak konvansiyonel temizlik yöntemleri ile birlikte kullanılması önerilmektedir (52).

Salgın Tespiti ve Anomali Tabanlı Uyarılar

Yapay zekâ sistemleri, elektronik sağlık kayıtlarında zaman ve mekâna dayalı olağandışı kümelenmeleri saptayarak salgın başlangıcını tahmin edebilmektedir. Bu tür sistemler, klasik sürveyans yöntemleriyle gecikmeli olarak tanınabilecek kümelenmeleri daha erken aşamada belirleyerek enfeksiyon kontrol ekiplerine ve hastane yönetimine erken uyarı iletebilmektedir. Bu sayede temas izolasyonlarının başlatılması, olası kaynağın tespitine yönelik taramaların yapılması ve çevresel kontrol önlemlerinin zamanında uygulanması mümkün olabilmekte ve salgın yönetimi süreçleri daha etkin biçimde yürütülebilmektedir (53).

ANTİMİKROBİYAL YÖNETİŞİMDE YAPAY ZEKÂ

Antibiyotik Reçeteleme Analizi ve Karar Destek Sistemleri

Yapay zekâ destekli karar destek sistemleri, antibiyotik reçetelerinin uygunluğunun değerlendirilmesi ve güncel rehberler doğrultusunda alternatif tedavi seçeneklerinin sunulması açısından önemli avantajlar sağlamaktadır. Klinik karar destek sistemleriyle entegre edilen bu modeller; dozlama hatalarının önlenmesi, gereksiz geniş spektrumlu ajan kullanımının azaltılması ve tedavi süresinin optimize edilmesi gibi alanlarda klinisyenlere destek olmaktadır (54). Yoğun bakım ünitelerinde tedavi gören 18 988 hastanın retrospektif verileri kullanılarak geliştirilen bir modelde, antibiyotik tedavisinin erken sonlandırılmasının hastanede kalış süresini ortalama 2.71 gün azalttığı gösterilmiştir. Bu bulgu, yapay zekâ destekli sistemlerin tedavi süresini optimize etmede etkili olabileceğini ortaya koymaktadır (55).

Antibiyotik Direnç Öngörüsü ve Eğilim İzleme

Yapay zekâ, hastane düzeyinde antimikrobiyal direnç paternlerini öngörmek ve direnç eğilimlerini izlemek için de etkili bir araçtır. Hastane antibiyogram verileri, hasta demografisi ve tüketim miktarları gibi parametreleri analiz eden modeller, direnç artış potansiyeli olan patojenleri önceden belirleyebilmektedir (56). Bu durum, antimikrobiyal kullanım politikalarının dinamik olarak güncellenmesini ve riskli alanlara hedeflenmiş müdahaleleri mümkün kılmaktadır.

Kişiselleştirilmiş Antibiyotik Seçimi

Geliştirilmiş çeşitli yapay zekâ destekli modeller, hastaya özgü klinik özellikleri, laboratuvar sonuçlarını, önceki tedavi öyküsünü ve lokal direnç verilerini birlikte analiz ederek hasta bazlı antibiyotik önerileri sunabilmek-

tedir. Bu sistemler, özellikle sepsis veya immünsüprese hasta gruplarında uygun ampirik tedaviye zamanında başlanmasını sağlayabilmektedir (57).

Klinik Eczacılık ve Antimikrobiyal Yönetişim Ekipleriyle Entegrasyon

Yapay zekâ araçlarının, AMY ekipleri ve klinik eczacılarla bütünleşik olarak çalışacak şekilde tasarlanması önerilmektedir. Antibiyotik tedavi süresi, doz aralıkları, de-eskalasyon önerileri ve oral tedaviye geçiş zamanlaması gibi konularda otomatik öneriler sunan sistemlerin, AMY ekiplerinin iş yükünü azaltarak ve daha fazla sayıda hastanın değerlendirilmesine olanak tanıdığı bildirilmiştir. Ayrıca bu sistemlerin, yüksek riskli antibiyotiklerin gereksiz kullanımını sınırlamaya yönelik uyarı mekanizmaları geliştirilerek hastane protokollerine uyumu artırabildiği belirtilmiştir (58).

İzlem, Geri Bildirim ve Klinik Performans Göstergeleri

Yapay zekâ sistemleri, klinik birimler bazında antibiyotik kullanım örüntülerini analiz ederek kullanım sıklığı, tedavi süresi ve ajan dağılımına ilişkin veriler üretebilmekte ve bu verileri AMY ekipleri ile yöneticilere sunabilmektedir. Klinik kararlarının şeffaf bir şekilde izlenmesi, geri bildirim mekanizmalarının etkinliğini artırmakta ve davranışsal değişimin sürdürülebilirliğini sağlamaktadır (54). Antimikrobiyal yönetim için geliştirilen izlem panelleri aracılığıyla gerçek zamanlı takip sağlanarak aşırı reçetelemenin önüne de geçilebilmektedir (54).

SINIRLILIKLAR, ZORLUKLAR VE GELECEK PERSPEKTİF

Yapay zekâ uygulamalarının enfeksiyon hastalıkları ve klinik mikrobiyoloji alanında yaygın ve etkili biçimde kullanılabilmesi, bazı temel sınırlamaların aşılmasına bağlıdır. Algoritmaların eğitildiği veri setlerinin heterojenliği ve kullanılan verilerin kalitesi, bu sistemlerin doğruluğunu ve genellenebilirliğini doğrudan etkilemektedir. Farklı sağlık sistemlerinde aynı modelin benzer başarıyı göstermemesi, önemli bir sınırlayıcı olarak öne çıkmaktadır (59). Bunun yanı sıra, eksik, hatalı ya da standardize edilmemiş elektronik sağlık kayıtları yapay zekâ sistemlerinin güvenilirliğini olumsuz yönde etkilemektedir. Konuya ilişkin etik ve yasal sorunlar göz ardı edilemez; hasta mahremiyeti, veri güvenliği ve algoritmik yanlılık, yapay zekânın klinik uygulamalarına entegrasyonunu sınırlandıran önemli unsurlar arasındadır (59,60). Öte yandan, klinik yargının yerine geçemeyen bu sistemlerin, destekleyici rolünün doğru bir şekilde anlaşılması gerekir (61). Söz konusu sınırlılıklar ve zorluklar Tablo 1'de sunulmuştur.

Yapay zekâ uygulamalarının sağlık alanında kullanılmasında etik ilkelerin yanı sıra ulusal ve uluslararası mevzuata uyum da kritik öneme sahiptir. Türkiye'de kişisel sağlık verilerinin işlenmesi, 6698 sayılı Kişisel Verilerin Korunması Kanunu (KVKK) kapsamında "özel nitelikli kişisel veri" başlığı altında sıkı düzenlemelere tabidir ve sağlık verilerinin işlenmesi ancak kanunda belirtilen sınırlı koşullar altında mümkündür (62). Açık rıza, aydınlatma yükümlülüğü, veri minimizasyonu, amaçla sınırlılık ve güvenli saklama gibi ilkeler, yapay zekâ modellerinin eğitimi ve klinik kullanımı sırasında gözetilmesi gereken temel gerekliliklerdir. Avrupa Birliği Genel Veri Koruma Tüzüğü (General Data Protection Regulation, GDPR) ise sağlık verilerini hassas veri kategorisinde ele almakta; "privacy by design", veri koruma etki değerlendirmesi (Data Protection Impact Assessment, DPIA), şeffaflık ve bireylerin kendi verileri üzerindeki denetim hakkı gibi yükümlülüklerle yapay zekâ temelli klinik karar destek sistemlerinin hesap verebilir, izlenebilir ve güvenli şekilde tasarlanmasını zorunlu kılmaktadır (63). Ayrıca 2024 yılında kabul edilen AB Yapay Zekâ Yasası (EU Artificial Intelligence Act), sağlık alanındaki yapay zekâ uygulamalarını "yüksek riskli sistemler" arasında sınıflandırarak algoritmik şeffaflık, veri kalitesi, teknik dokümantasyon ve insan gözetimi gerekliliklerini daha da güçlendirmiştir (64). Bu nedenle enfeksiyon hastalıkları ve klinik mikrobiyoloji alanında geliştirilen yapay zekâ sistemlerinde hem KVKK hem GDPR ile uyumlu bir veri işleme yaklaşımı benimsenmesi, hukuki risklerin azaltılması ve güvenli uygulamaların desteklenmesi açısından kritik önem taşımaktadır.

Yapay zekânın sağlık alanında uygulanmasında en sık karşılaşılan zorluklardan biri, algoritmaların açıklanabilirliğidir. Klinik karar destek sistemlerinin güven oluşturabilmesi için şeffaf, izlenebilir ve doğrulanabilir olması büyük önem taşır (28). Bu sistemlerin güvenle kullanılabilmesi için sağlık profesyonellerinin teknolojiye olan güveninin artırılması ve gerekli eğitimin sağlanması gerekmektedir. Yetersiz kullanıcı eğitimi, teknolojik altyapı eksiklikleri ve kurumsal adaptasyon süreçlerindeki direnç, yapay zekânın sahadaki etkisini sınırlandıran diğer faktörlerdir (59). Ayrıca bu sistemlerin deneyim ve sezgiye dayalı klinik karar süreçlerini yeterince yansıtamaması da önemli bir dezavantaj olarak değerlendirilmektedir.

Yapay zekâ araştırmalarının büyük miktardaki veri ihtiyacı, çalışmaların çoğunlukla prospektif değil retrospektif olarak tasarlanmasına yol açmaktadır. Retrospektif çalışmalar, geçmişte etiketlenmiş verilerin kullanılmasıyla modellerin eğitilmesini ve test edilmesini mümkün kılmakla birlikte, klinik açıdan en değerli kanıt düzeyi olarak kabul edilen prospektif çalışmaların yerini tutamamaktadır. Benzer şekilde, klinik uygulamalarda randomize kontrollü çalışmalar altın standart

Tablo 1. Yapay Zekâ Uygulamalarının Temel Sınırlılıkları ve Zorluk Alanları

Sınırlılık / Zorluk Alanı	Açıklama
Veri kalitesi ve genellenebilirlik	Veri setlerinin heterojenliği, eksik veya standart dışı kayıtlar ve geliştirilen modellerin farklı kurum ve sağlık sistemlerinde aynı performansı gösterememesi.
Etik ve hukuki düzenlemeler	Kişisel Verilerin Korunması Kanunu, Avrupa Birliği Genel Veri Koruma Tüzüğü ve Avrupa Birliği Yapay Zekâ Yasası kapsamında sağlık verilerinin yüksek riskli veri kategorisine girmesi.
Model açıklanabilirliği ve güven	Algoritmik karar süreçlerinin yeterince şeffaf olmaması, yanlılık riski ve klinisyen güveninin sınırlı olması.
Metodolojik zorluklar	Retrospektif çalışma tasarımlarına bağımlılık, randomize kontrollü çalışma sayısının azlığı, model mimarileri arasındaki heterojenlik ve klinik kullanımı sınırlı performans metriklerinin tercih edilmesi.
Klinik entegrasyon engelleri	Teknolojik altyapı yetersizlikleri, kullanıcı eğitimi gereksinimi, kurumsal adaptasyon direnci ve yapay zekânın sezgisel klinik muhakemeyi tam olarak karşılayamaması.
Yeni teknolojilerin olgunluk düzeyi	Dijital ikiz ve erişim destekli üretim gibi teknolojilerin erken gelişim aşamasında olması ve daha fazla klinik doğrulamaya ihtiyaç duyulması.

kabul edilirken, yapay zekâ alanında randomize kontrollü çalışmaların sayısı görece sınırlıdır ve çok sayıda çalışma hakem değerlendirmesi olmaksızın yayımlanmaktadır (65). Tüm bunlara ek olarak yapay zekâ çalışmalarında kullanılan model mimari ve metodolojilerin heterojenliği, çalışmaların karşılaştırılabilirliğini azaltmakta; F1 skoru ve “cosine similarity” gibi tıp alanında yaygın olmayan performans metriklerinin sıklıkla kullanılması da sağlık alanına uyarlamada ek zorluklar olarak öne çıkmaktadır (66).

Buna karşın, yapay zekânın enfeksiyon hastalıkları, AMY ve enfeksiyon kontrolü alanlarındaki kullanım potansiyeli her geçen gün artmaktadır. Gelişmiş algoritmalar; birey düzeyinde risk analizi, gerçek zamanlı sürveyans, klinik mikrobiyoloji verilerinin entegrasyonu ve uzaktan hasta izlemi gibi yenilikçi uygulamaların önünü açmaktadır (45,54). Özellikle büyük veri analitiği ve derin öğrenme modelleri sayesinde, yerel direnç profilleri ile hasta verilerinin birlikte değerlendirilmesiyle kişiselleştirilmiş enfeksiyon kontrol stratejilerinin geliştirilmesi mümkün hâle gelmiştir (46,57). Dünya Sağlık Örgütü gibi uluslararası otoritelerin yapay zekâ tabanlı araçları rehberlerine entegre etmesi, bu teknolojilere olan güvenin küresel ölçekte arttığını göstermektedir.

Gelecekte yapay zekâ destekli sistemlerin, hastane bilgi yönetim sistemleriyle entegre biçimde çalışması, ulusal sürveyans ağlarına veri sağlaması ve kalite göstergeleri üretmesi hedeflenmektedir. Ancak bu entegrasyonun etik, hukuki ve ekonomik boyutları titizlikle değerlendirilmelidir. Klinik karar destek süreçlerinde yapay zekânın etkin biçimde yer alabilmesi için yüksek kaliteli veri üretimi, algoritmaların şeffaflığı ve sağlık çalışanlarının eğitimi öncelikli konular arasında yer almalıdır (59). Bu koşullar sağlandığında yapay zekâ sistemlerinin enfeksiyon hastalıklarının tanısı ve tedavisi, enfeksiyon kontrolü ve AMY alanlarında güçlü ve güvenilir bir destek aracı hâline gelmesi mümkün olacaktır.

Tüm bunlara ek olarak; dijital ikiz ve erişim destekli üretim (Retrieval-Augmented Generation, RAG) gibi yeni yapay zekâ uygulamaları klinik uygulamaları kalıcı olarak değiştirme potansiyeline sahiptir. Dijital ikiz, bir nesnenin, bir hastanın veya bir sistemin gerçek dünyadaki karşılığını yansıtan, gerçek zamanlı verilerle güncellenen ve simülasyon çalışmaları için kullanılan sanal bir temsildir. Dijital ikiz uygulamaları, çeşitli üretici ağlar gibi model mimarilerini kullanarak çalışmalarda veri sayısının artırılabilmesine, sağlık bakımı profesyonellerinin eğitimine, hatta farklı klinik senaryolarla klinik kohortların oluşturulmasına ve bu sayede klinik çalışmaların yapılabilmesine olanak sağlamaktadır (67). Erişim destekli üretim yaklaşımı ise hayatımızı dramatik olarak değiştiren ChatGPT-4 gibi büyük dil modellerinin kendisini değiştirmeden, dış bilgi kaynaklarıyla destekleyerek üretilen çıktının doğruluğunu ve güncelliğini artırmayı amaçlamaktadır. Bu sayede halüsinasyon, statik bilgi, şeffaflık ve yanlılık gibi kısıtlılıkların azaltılması ve kişiselleştirilmiş, konuya özgü büyük dil modellerinin sağlık alanına entegrasyonunu mümkün kılar (68).

Sonuç olarak; yapay zekâ klinik kararlarda hekimleri destekleyen güçlü bir araçtır. Gelecekte yüksek kaliteli veri, şeffaf algoritmalar, multidisipliner iş birliği ve etkin regülasyonlarla desteklendiğinde, yapay zekâ uygulamalarının hem hasta bakımını iyileştirmesi hem de sağlık sistemlerinin sürdürülebilirliğine katkı sağlaması beklenmektedir.

Danışman Değerlendirmesi

Bağımsız dış danışman

Yazar Katkıları

Fikir/Kavram – E.G., A.G.E., N.A.D., F.T.; Denetleme – E.G., A.G.E.; Analiz ve/veya Yorum – E.G., A.G.E., N.A.D., F.T.; Literatür Taraması – E.G., A.G.E., N.A.D., F.T.; Makale Yazımı – E.G., A.G.E., N.A.D., F.T.; Eleştirel İnceleme – E.G., A.G.E., N.A.D., F.T.

Çıkar Çatışması

Yazarlar herhangi bir çıkar çatışması bildirmemiştir.

Finansal Destek

Yazar finansal destek beyan etmemiştir.

Yapay Zekâ Kullanım Beyanı

Bu çalışmanın hazırlanması, veri analizi veya yazımı aşamalarında herhangi bir yapay zekâ programı kullanılmamıştır.

KAYNAKLAR

1. Kok JN, Boers EJW, Kösters WA, van der Putten P, Poel M. Artificial intelligence: definition, trends, techniques and cases. Encyclopedia of Life Support Systems (EOLSS). Vol 1. eBook:1–21.
2. Pugliese R, Regondi S, Marini R. Machine learning-based approach: global trends, research directions, and regulatory standpoints. Data Science and Management. 2021;4:19–29. [\[CrossRef\]](#)
3. Sapoval N, Aghazadeh A, Nute MG, Antunes DA, Balaji A, Baraniuk R, et al. Current progress and open challenges for applying deep learning across the biosciences. Nat Commun. 2022;13(1):1728. [\[CrossRef\]](#)
4. van Engelen JE, Hoos HH. A survey on semi-supervised learning. Mach Learn. 2020;109(2):373–440. [\[CrossRef\]](#)
5. Krishnan R, Rajpurkar P, Topol EJ. Self-supervised learning in medicine and healthcare. Nat Biomed Eng. 2022;6(12):1346–52. [\[CrossRef\]](#)
6. Kourounis G, Elmahmudi AA, Thomson B, Hunter J, Ugail H, Wilson C. Computer image analysis with artificial intelligence: a practical introduction to convolutional neural networks for medical professionals. Postgrad Med J. 2023;99(1178):1287–94. [\[CrossRef\]](#)
7. Das S, Tariq A, Santos T, Kantareddy SS, Banerjee I. Recurrent neural networks (RNNs): architectures, training tricks, and introduction to influential research. In: Colliot O, editor. Machine Learning for Brain Disorders. New York, NY: Humana; 2023. Chapter 4.
8. 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. [\[CrossRef\]](#)
9. Lan L, You L, Zhang Z, Fan Z, Zhao W, Zeng N, et al. Generative adversarial networks and its applications in biomedical informatics. Front Public Health. 2020;8:164. [\[CrossRef\]](#)
10. Alowais SA, Alghamdi SS, Alsuhbany N, Alqahtani T, Alshaya AI, Almohareb SN, et al. Revolutionizing healthcare: the role of artificial intelligence in clinical practice. BMC Med Educ. 2023;23(1):689. [\[CrossRef\]](#)
11. Dash S, Shakyawar SK, Sharma M, Kaushik S. Big data in healthcare: management, analysis and future prospects. J Big Data. 2019;6:54. [\[CrossRef\]](#)
12. Steyaert S, Pizurica M, Nagaraj D, Khandelwal P, Hernandez-Boussard T, Gentles AJ, et al. Multimodal data fusion for cancer biomarker discovery with deep learning. Nat Mach Intell. 2023;5(4):351–62. [\[CrossRef\]](#)
13. Er AG, Ding DY, Er B, Uzun M, Cakmak M, Sadee C, et al. Multimodal data fusion using sparse canonical correlation analysis and cooperative learning: a COVID-19 cohort study. NPJ Digit Med. 2024;7(1):117. [\[CrossRef\]](#)
14. Gest H. The discovery of microorganisms by Robert Hooke and Antoni Van Leeuwenhoek, fellows of the Royal Society. Notes Rec R Soc Lond. 2004;58(2):187–201. [\[CrossRef\]](#)

15. Hwang EJ, Jeong WG, David PM, Arentz M, Ruhwald M, Yoon SH. AI for detection of tuberculosis: Implications for global health. *Radiol Artif Intell.* 2024;6(2):e230327. [\[CrossRef\]](#)
16. World Health Organization. WHO consolidated guidelines on tuberculosis. Module 2: screening – systematic screening for tuberculosis disease [Internet]. Geneva: World Health Organization; 2021. [cited September 10, 2025]. Available from: <https://www.who.int/publications/i/item/9789240022676>
17. Li L, Qin L, Xu Z, Yin Y, Wang X, Kong B, 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(2):E65–E71. [\[CrossRef\]](#)
18. Pérez-Sancho M, Vela AI, Horcajo P, Ugarte-Ruiz M, Domínguez L, Fernández-Garayzábal JF, et al. Rapid differentiation of *Staphylococcus aureus* subspecies based on MALDI-TOF MS profiles. *J Vet Diagn Invest.* 2018;30(6):813–20. [\[CrossRef\]](#)
19. Mandal S, Tannert A, Löffler B, Neugebauer U, Silva LB. Findaureus: An open-source application for locating *Staphylococcus aureus* in fluorescence-labelled infected bone tissue slices. *PLoS One.* 2024;19(1):e0296854. [\[CrossRef\]](#)
20. Dutta A, Ramamoorthy A, Lakshmi MG, Kumar PK. Kolmogorov–Arnold networks for automated diagnosis of urinary tract infections. *J Mol Pathol.* 2025;6(1):6. [\[CrossRef\]](#)
21. Baker J, Timm K, Faron M, Ledebauer N, Culbreath K. Digital image analysis for the detection of group B *Streptococcus* from ChromID Strepto B medium using PhenoMatrix algorithms. *J Clin Microbiol.* 2020;59(1):e01902–19. [\[CrossRef\]](#)
22. Ma X, Li Y, Liang Y, Liu Y, Yu L, Li C, et al. Development of a DNA microarray assay for rapid detection of fifteen bacterial pathogens in pneumonia. *BMC Microbiol.* 2020;20(1):177. [\[CrossRef\]](#)
23. Horvath L, Hänselmann S, Mannsperger H, Degenhardt S, Last K, Zimmermann S, et al. Machine-assisted interpretation of auramine stains substantially increases through-put and sensitivity of microscopic tuberculosis diagnosis. *Tuberculosis (Edinb).* 2020;125:101993. [\[CrossRef\]](#)
24. Mayhew MB, Buturovic L, Luethy R, Midic U, Moore AR, Roque JA, et al. A generalizable 29-mRNA neural-network classifier for acute bacterial and viral infections. *Nat Commun.* 2020;11(1):1177. [\[CrossRef\]](#)
25. Lu J, Ter Voert MA, Ünal M, Whitfield NN, Liesenfeld O, Ter Maaten JC, et al. Early sepsis recognition: a pilot study using a rapid high-multiplex host-response mRNA diagnostic test. *Intensive Care Med Exp.* 2025;13(1):21. [\[CrossRef\]](#)
26. Bhargava A, López-Espina C, Schmalz L, Khan S, Watson GL, Urdiales D, et al. FDA-Authorized AI/ML tool for sepsis prediction: development and validation. *NEJM AI.* 2024;1(12):AIoa2400867. [\[CrossRef\]](#)
27. Balk R, Esper AM, Martin GS, Miller RR 3rd, Lopansri BK, Burke JP, et al. Validation of SeptiCyte RAPID to discriminate sepsis from non-infectious systemic inflammation. *J Clin Med.* 2024;13(5):1194. [\[CrossRef\]](#)
28. Abavisani M, Khoshrou A, Foroushan SK, Sahebkar A. Chatting with artificial intelligence to combat antibiotic resistance: opportunities and challenges. *Curr Res Biotechnol.* 2024;7:100197. [\[CrossRef\]](#)
29. Howard A, Hope W, Gerada A. ChatGPT and antimicrobial advice: the end of the consulting infection doctor? *Lancet Infect Dis.* 2023;23(4):405–6. [\[CrossRef\]](#)
30. Pinto-de-Sá R, Sousa-Pinto B, Costa-de-Oliveira S. Brave new world of artificial intelligence: Its use in antimicrobial stewardship-a systematic review. *Antibiotics (Basel).* 2024;13(4):307. [\[CrossRef\]](#)
31. Maillard A, Micheli G, Lefevre L, Guyonnet C, Poyart C, Canoui E, et al. Can chatbot artificial intelligence replace infectious diseases physicians in the management of bloodstream infections? A Prospective Cohort Study. *Clin Infect Dis.* 2024;78(4):825–32. [\[CrossRef\]](#)
32. De Vito A, Geremia N, Marino A, Bavaro DF, Caruana G, Meschiari M, et al. Assessing ChatGPT's theoretical knowledge and prescriptive accuracy in bacterial infections: a comparative study with infectious diseases residents and specialists. *Infection.* 2025;53(3):873–81. [\[CrossRef\]](#)
33. Sarink MJ, Bakker IL, Anas AA, Yusuf E. A study on the performance of ChatGPT in infectious diseases clinical consultation. *Clin Microbiol Infect.* 2023;29(8):1088–9. [\[CrossRef\]](#)
34. Wendland P, Schenkel-Häger C, Wenningmann I, Kschischo M. An optimal antibiotic selection framework for sepsis patients using artificial intelligence. *NPJ Digit Med.* 2024;7(1):343. [\[CrossRef\]](#)
35. Goldschmidt E, Rannon E, Bernstein D, Wasserman A, Roimi M, Shrot A, et al. Predicting appropriateness of antibiotic treatment among ICU patients with hospital-acquired infection. *NPJ Digit Med.* 2025;8(1):87. [\[CrossRef\]](#)
36. Kim W, Krause K, Zimmerman Z, Outterson K. Improving data sharing to increase the efficiency of antibiotic R&D. *Nat Rev Drug Discov.* 2021;20(1):1–2. [\[CrossRef\]](#)
37. Kung TH, Cheatham M, Medenilla A, Sillos C, De Leon L, Elepaño C, et al. Performance of ChatGPT on USMLE: Potential for AI-assisted medical education using large language models. *PLOS Digit Health.* 2023;2(2):e0000198. [\[CrossRef\]](#)
38. Cheng Y, Gong Y, Liu Y, Song B, Zou Q. Molecular design in drug discovery: a comprehensive review of deep generative models. *Brief Bioinform.* 2021;22(6):bbab344. [\[CrossRef\]](#)
39. Rawson TM, Hernandez B, Moore LSP, Herrero P, Charani E, Ming D, et al. A real-world evaluation of a case-based reasoning algorithm to support antimicrobial prescribing decisions in acute care. *Clin Infect Dis.* 2021;72(12):2103–11. [\[CrossRef\]](#)
40. Godbole AA, Paras, Mehra M, Banerjee S, Roy P, Deb N, et al. Enhancing infection control in ICUS through AI: A literature review. *Health Sci Rep.* 2025;8(1):e70288. [\[CrossRef\]](#)
41. World Health Organization. Global call to action to address antimicrobial resistance [Internet]. Geneva: World Health Organization; October 7, 2025. [cited December 7, 2025]. Available from: <https://www.who.int/publications/m/item/global-call-to-action-to-address-antimicrobial-resistance>
42. Hanna JJ, Medford RJ. Navigating the future: machine learning's role in revolutionizing antimicrobial stewardship and infection prevention and control. *Curr Opin Infect Dis.* 2024;37(4):290–5. [\[CrossRef\]](#)
43. Chen Y, Zhang Y, Nie S, Ning J, Wang Q, Yuan H, et al. Risk assessment and prediction of nosocomial infections based on surveillance data using machine learning methods. *BMC Public Health.* 2024;24(1):1780. [\[CrossRef\]](#)
44. Lukasewicz Ferreira SA, Franco Meneses AC, Vaz TA, da Fontoura Carvalho OL, Hubner Dalmora C, Pressotto Vanni D, et al. Hospital-acquired infections surveillance: The machine-learning algorithm mirrors National Healthcare Safety Network definitions. *Infect Control Hosp Epidemiol.* 2024;45(5):604–8. [\[CrossRef\]](#)
45. Mukhtar SA, McFadden BR, Islam MT, Zhang QY, Alvandi E, Blatchford P, et al. Predictive analytics for early detection of hospital-acquired complications: An artificial intelligence approach. *Health Inf Manag.* 2025;54(2):109–20. [\[CrossRef\]](#)
46. Kherabi Y, Thy M, Bouzid D, Antcliffe DB, Rawson TM, Peiffer-Smadja N. Machine learning to predict antimicrobial resistance: future applications in clinical practice? *Infect Dis Now.* 2024;54(3):104864. [\[CrossRef\]](#)
47. Kim J, Kim JS, Kim SH, Yoo S, Lee JK, Kim K. Deep learning-based prediction of *Clostridioides difficile* infection caused by antibiotics using longitudinal electronic health records. *NPJ Digit Med.* 2024;7(1):224. [\[CrossRef\]](#)
48. Stachel A, Keegan LT, Blumberg S; CDC MInD Healthcare Program. Modeling transmission of pathogens in healthcare settings. *Curr Opin Infect Dis.* 2021;34(4):333–8. [\[CrossRef\]](#)
49. Singh A, Haque A, Alahi A, Yeung S, Guo M, Glassman JR, et al. Automatic detection of hand hygiene using computer vision technology. *J Am Med Inform Assoc.* 2020;27(8):1316–20. [\[CrossRef\]](#)
50. Simioli F, Annunziata A, Coppola A, Iervolino A, Boccia M, Fiorentino G. Artificial intelligence for training and reporting infection prevention measures in critical wards. *Front Public Health.* 2024;12:1442188. [\[CrossRef\]](#)
51. Hong H, Shin W, Oh J, Lee S, Kim T, Lee W, et al. Standard for the quantification of a sterilization effect using an artificial intelligence disinfection robot. *Sensors (Basel).* 2021;21(23):7776. [\[CrossRef\]](#)
52. Diab-El Schahawi M, Zingg W, Vos M, Humphreys H, Lopez-Cerero L, Fueszl A, et al; ESCMID Study Group on Nosocomial Infections “The decontamination research working group”. Ultraviolet disinfection robots to improve hospital cleaning: Real promise or just a gimmick? *Antimicrob Resist Infect Control.* 2021;10(1):33. [\[CrossRef\]](#)

53. MacIntyre CR, Lim S, Quigley A. Preventing the next pandemic: Use of artificial intelligence for epidemic monitoring and alerts. *Cell Rep Med*. 2022;3(12):100867. [[CrossRef](#)]
54. Tokgöz P, Albrecht J, Dockweiler C. Implementation of artificial intelligence-based decision support systems for antibiotic prescribing in hospitals: a Delphi study. *Front Digit Health*. 2025;7:1555042. [[CrossRef](#)]
55. Bolton WJ, Rawson TM, Hernandez B, Wilson R, Antcliffe D, Georgiou P, et al. Machine learning and synthetic outcome estimation for individualised antimicrobial cessation. *Front Digit Health*. 2022;4:997219. [[CrossRef](#)]
56. Vihta KD, Pritchard E, Pouwels KB, Hopkins S, Guy RL, Henderson K, et al. Predicting future hospital antimicrobial resistance prevalence using machine learning. *Commun Med (Lond)*. 2024;4(1):197. [[CrossRef](#)]
57. Bonazzetti C, Rocchi E, Toschi A, Derus NR, Sala C, Pascale R, et al. Artificial intelligence model to predict resistances in Gram-negative bloodstream infections. *NPJ Digit Med*. 2025;8(1):319. [[CrossRef](#)]
58. Alves J, Schouten J, Thursky K, Paz RN, Rello J, Lye DC, et al; AMS Competencies Study Group. Establishing core competencies for antimicrobial stewardship teams: a consensus development using the modified Delphi technique-an European Society of Clinical Microbiology and Infectious Diseases Study Group for Antimicrobial Stewardship position paper. *Clin Microbiol Infect*. 2025;31(8):1313–20. [[CrossRef](#)]
59. 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. [[CrossRef](#)]
60. Mello MM, Guha N. ChatGPT and physicians' malpractice risk. *JAMA Health Forum*. 2023;4(5):231938. [[CrossRef](#)]
61. Dave T, Athaluri SA, Singh S. ChatGPT in medicine: an overview of its applications, advantages, limitations, future prospects, and ethical considerations. *Front Artif Intell*. 2023;6:1169595. [[CrossRef](#)]
62. Kişisel Verilerin Korunması Kanunu (KVKK). Kanun No: 6698 [Internet]. In: Resmi Gazete; 07.04.2016. [cited December 7, 2025]. Available from: <https://www.resmigazete.gov.tr/eskiler/2016/04/20160407-8.pdf>
63. Regulation (EU) 2016/679 of the European Parliament and of the Council 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 (General Data Protection Regulation) [EU Regulation 2016/679 on personal data protection] [Internet]. In: Official Journal of the European Union; 2016;L119:1-88. [cited December 7, 2025]. Available from: <https://eur-lex.europa.eu/eli/reg/2016/679/oj>
64. Proposal for a regulation laying down harmonised rules on artificial intelligence [EU Artificial Intelligence Act Proposal] [Internet]. In: Official Journal of the European Union; 2021. [cited December 7, 2025]. Available from: <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:52021PC0206>
65. Han R, Acosta JN, Shakeri Z, Ioannidis JPA, Topol EJ, Rajpurkar P. Randomised controlled trials evaluating artificial intelligence in clinical practice: a scoping review. *Lancet Digit Health*. 2024;6(5):e367–73. [[CrossRef](#)]
66. Kelly CJ, Karthikesalingam A, Suleyman M, Corrado G, King D. Key challenges for delivering clinical impact with artificial intelligence. *BMC Med*. 2019;17(1):195. [[CrossRef](#)]
67. Giansanti D, Morelli S. Exploring the potential of digital twins in cancer treatment: A narrative review of reviews. *J Clin Med*. 2025;14(10):3574. [[CrossRef](#)]
68. Yang R, Ning Y, Keppo E, Liu M, Hong C, Bitterman DS, et al. Retrieval-augmented generation for generative artificial intelligence in health care. *NPJ Health Syst*. 2025;2(1):2. [[CrossRef](#)]