

Original Article

Artificial Intelligence and Antimicrobial Resistance in Bacteria

Monireh Rahimkhani^{1*}, Maryam Gilani², Arya Daneshvar³

1. Department of Lab Medical Sciences, Faculty of Allied Medical Sciences, Tehran University of Medical Sciences, Tehran, Iran

2. Faculty of Allied Medical Sciences, Tehran University of Medical Sciences, Tehran, Iran

3. Department of Civil and Environmental Engineering, Amirkabir University of Technology, Tehran, Iran

Article history:

Received: December 22, 2024

Revised: January 07, 2026

Accepted: August 05, 2026

e-Published: September 06, 2026



***Corresponding author:** Monireh Rahimkhani, Department of Lab Medical Sciences, Faculty of Allied Medical Sciences, Tehran University of Medical Sciences, Tehran, Iran

E-mail: rrahimkhani@sina.tums.ac.ir

Abstract

Background and Aim: Antimicrobial resistance (AMR) represents a major global health challenge, requiring novel approaches to improve diagnosis, prediction, and clinical decision-making. In recent years, machine learning (ML), as a subset of artificial intelligence (AI), has been increasingly explored for predicting antibiotic resistance, accelerating AMR diagnostics, and supporting antibiotic prescribing decisions. This study aims to provide a critical review of current evidence on the application of ML in AMR, with a particular focus on algorithmic performance, clinical applicability, and practical limitations.

Materials and Methods: This narrative review was conducted utilizing a structured literature search of major scientific databases, including studies that applied ML-based approaches to resistance prediction, rapid AMR detection, or clinical decision support.

Results: The reviewed evidence indicates that while certain ML models demonstrate acceptable performance in specific, context-dependent settings, robust and consistent superiority over conventional statistical methods has not been established. Moreover, key limitations, such as limited generalizability, reliance on single-center data, the need for periodic model retraining, data quality and bias in electronic health records, and the inability of some models to prioritize narrow-spectrum antibiotics, remain substantial barriers to real-world clinical implementation.

Conclusion: Overall, current evidence suggests that ML should be viewed as a decision-support tool rather than a standalone solution in AMR management, and that its definitive impact on hard clinical outcomes will require further real-world evaluations and interventional studies.

Keywords: Antimicrobial resistance, Artificial intelligence, Machine learning

Please cite this article as follows: Rahimkhani M, Gilani M, Daneshvar A. Artificial Intelligence and Antimicrobial Resistance in Bacteria. SJKUMS. 2026;31(3):280-288. DOI:10.22034/31.3.280.

هوش مصنوعی و مقاومت آنتی‌بیوتیکی در باکتری‌ها

منیره رحیم‌خانی^{۱*}، مریم گیلانی^۲، آریا دانشور^۳

۱. دانشکده علوم پیراپزشکی، دانشگاه علوم پزشکی تهران، تهران، ایران

۲. دانشکده علوم پیراپزشکی، دانشگاه علوم پزشکی تهران، تهران، ایران

۳. دانشکده مهندسی عمران و محیط زیست، دانشگاه صنعتی امیرکبیر، تهران، ایران

چکیده

زمینه و هدف: مقاومت ضد میکروبی (Antimicrobial Resistance; AMR) به‌عنوان یکی از چالش‌های اصلی سلامت عمومی، نیازمند رویکردهای نوین برای بهبود تشخیص، پیش‌بینی و تصمیم‌گیری بالینی است. در سال‌های اخیر، یادگیری ماشینی (Machine Learning; ML) به‌عنوان زیرمجموعه‌ای از هوش مصنوعی (Artificial Intelligence; AI) به‌طور گسترده برای پیش‌بینی مقاومت آنتی‌بیوتیکی، تسریع تشخیص AMR و حمایت از نسخه‌نویسی آنتی‌بیوتیک بررسی شده است. هدف این مطالعه، مرور و تحلیل انتقادی شواهد موجود درباره کاربرد ML در زمینه AMR، با تمرکز بر عملکرد الگوریتم‌ها، قابلیت کاربرد بالینی و محدودیت‌های عملی آن‌هاست.

مواد و روش‌ها: این مقاله به‌صورت مرور روایی با جست‌وجوی ساختاریافته در پایگاه‌های داده علمی انجام شده و مطالعاتی که برای پیش‌بینی مقاومت، تشخیص سریع یا پشتیبانی از تصمیم‌گیری بالینی، از الگوریتم‌های ML استفاده کرده‌اند، بررسی شده‌اند.

یافته‌ها: نتایج نشان می‌دهد که اگرچه برخی مدل‌های ML در شرایط خاص و وابسته به زمینه، عملکرد قابل‌قبولی ارائه داده‌اند، شواهد موجود برتری پایدار و عمومی آن‌ها را در مقایسه با روش‌های آماری مرسوم تأیید نمی‌کند. علاوه بر این، محدودیت‌هایی مانند تعمیم‌پذیر نبودن، وابستگی به داده‌های تک‌مرکزی، نیاز به بازآموزی دوره‌ای، کیفیت و بایاس داده‌های پرونده سلامت الکترونیکی و ناتوانی برخی مدل‌ها در اولویت‌دهی به آنتی‌بیوتیک‌های با طیف باریک، چالش‌های اساسی در کاربرد عملی ML محسوب می‌شوند.

نتیجه‌گیری: در مجموع، یافته‌های این مرور نشان می‌دهد که یادگیری ماشینی در حال حاضر باید به‌عنوان ابزار پشتیبان تصمیم‌گیری، مکمل قضاوت بالینی و برنامه‌های نظارت ضد میکروبی در نظر گرفته شود و اثبات نقش قطعی آن در بهبود پیامدهای سخت بالینی نیازمند مطالعات دنیای واقعی و کارآزمایی‌های مداخله‌ای آینده است.

واژگان کلیدی: مقاومت ضد میکروبی، یادگیری ماشینی، هوش مصنوعی

تاریخچه مقاله:

دریافت: ۱۴۰۳/۱۰/۰۲

ویرایش: ۱۴۰۴/۱۰/۱۷

پذیرش: ۱۴۰۵/۰۵/۱۴

انتشار: ۱۴۰۵/۰۶/۱۵

تمامی حقوق نشر برای دانشگاه علوم پزشکی کردستان محفوظ است.

***نویسنده مسئول:** منیره رحیم‌خانی، دانشکده علوم پیراپزشکی، دانشگاه علوم پزشکی تهران، تهران، ایران

ایمیل: rrahimkhani@sina.tums.ac.i

استناد: رحیم‌خانی، منیره؛ گیلانی، مریم؛ دانشور، آریا. هوش مصنوعی و مقاومت آنتی‌بیوتیکی در باکتری‌ها. مجله علمی دانشگاه علوم پزشکی کردستان، مرداد و شهریور ۱۴۰۵، ۳۱(۳): ۲۸۸-۲۸۰.

مقدمه

بیماران آسیب‌پذیرترند و مصرف آنتی‌بیوتیک زیاد است. براساس برآوردهای اتحادیه اروپا و منطقه اقتصادی اروپا (EU/EEA)، هر سال بیش از ۶۷۰,۰۰۰ عفونت ناشی از باکتری‌های مقاوم به آنتی‌بیوتیک در این منطقه ثبت می‌شود که پیامد آن حدود ۳۳,۰۰۰ مورد مرگ است [۱].

افزایش مقاومت کلبسیلا پنومونیه و گونه‌های /سینتوباکتر به سفالوسپورین‌ها و کارباپنم‌های نسل

در سال‌های اخیر، افزایش مقاومت ضد میکروبی (AMR) به نگرانی جدی جهانی تبدیل شده است. پس از قرارگرفتن در معرض آنتی‌بیوتیک‌ها، باکتری‌ها به‌دلیل چرخه رشد کوتاه و مکانیسم‌های سازگاری مختلف، می‌توانند به سرعت مقاومت کنند. عفونت‌های ناشی از میکروارگانیسم‌های مقاوم به چند دارو معمولاً در محیط‌های بیمارستانی رخ می‌دهند و بیشترین شیوع آن‌ها در بخش‌های مراقبت‌های ویژه مشاهده می‌شود؛ جایی که

سوم و انتشار سریع ایزوله‌های مقاوم، انتخاب‌های ضد میکروبی را برای بیماران آلوده به این پاتوژن‌ها محدود می‌کند [۲]. شناختن عوامل خطر بیمار برای عفونت با پاتوژن مقاوم به آنتی‌بیوتیک، علت اصلی دریافت درمان نامناسب و در نهایت، حصول نتایج نامطلوب است. عوامل متعددی، از جمله کمبود منابع تحقیقاتی دولتی به دلیل مشکلات مالی و رویه‌های نظارتی گسترده برای داروهای جدید، توسعه آنتی‌بیوتیک‌های نسل نو را کند می‌کند [۲]. مهم‌تر از آن، توسعه آنتی‌بیوتیک دیگر به عنوان سرمایه‌گذاری اقتصادی مقرون به صرفه در صنعت داروسازی در نظر گرفته نمی‌شود؛ زیرا آنتی‌بیوتیک‌ها، برخلاف داروهایی که برای درمان بیماری‌های مزمن استفاده می‌شوند، برای مدت‌زمان نسبتاً کوتاهی استفاده می‌شوند. بنابراین، در سال‌های اخیر، مشکلات زیادی در خصوص توسعه و در دسترس بودن آنتی‌بیوتیک‌های جدید برای رسیدگی به موقعیت‌های مقاومت در حال ظهور وجود داشته است [۳].

برای مقابله با گسترش سریع مقاومت ضد میکروبی، اجرای مداخله چند رشته‌ای تحت عنوان برنامه‌های نظارت ضد میکروبی (Antimicrobial Stewardship Programs; ASPs) ضروری است. هدف این برنامه‌ها بهینه‌سازی تجویز آنتی‌بیوتیک بر پایه شواهد بالینی و در نتیجه، کاهش فشار انتخابی مؤثر در ظهور و انتشار AMR است. باین‌حال، نگرانی‌های جدی درباره تأثیر همه‌گیری COVID-19 در تضعیف اجرای ASPها و تشدید مقاومت ضد میکروبی مطرح شده است. فشار بیش از حد بر سیستم‌های سلامت، افزایش حجم کاری پزشکان و پرستاران و محدود شدن منابع ساختاری، از جمله عواملی هستند که می‌توانند کنترل عفونت و مدیریت منطقی آنتی‌بیوتیک را در بیمارستان‌ها مختل کنند. در این شرایط، تجویز گسترده و اغلب غیر ضروری آنتی‌بیوتیک‌های وسیع‌الطیف در بیماران بستری مبتلا به COVID-19 به‌طور شایع گزارش شده است؛ روندی که می‌تواند هم بیماران و هم جامعه را در معرض افزایش خطر عفونت‌های ناشی از میکروارگانیسم‌های مقاوم به چند دارو قرار دهد [۴]. در حقیقت، ارگانیسم‌های مقاوم به آنتی‌بیوتیک به سه گروه طبقه‌بندی می‌شوند: سویه‌های مقاوم به چند دارو (MDR)، سویه‌های مقاوم به تعداد زیادی از داروها (XDR) و سویه‌های مقاوم به تمام داروها (PDR).

از طرفی، افزایش جهانی در استفاده از پرونده الکترونیک سلامت (EHR) به مقادیر انبوهی از داده‌های الکترونیکی بیمار و میکروبیولوژیکی در دسترس معمول منجر شده است که می‌تواند برای حمایت از نظارت فردی ضد میکروبی استفاده شود. در سال‌های گذشته، بخش زیادی از داده‌های بالینی و آزمایشگاهی نادیده گرفته شده یا اصلاً جمع‌آوری نشده است. عوامل متعددی در ایجاد این محدودیت نقش داشته‌اند، از جمله اندازه و پیچیدگی داده‌ها و همچنین نبود تکنیک برای جمع‌آوری و ذخیره آن‌ها. یادگیری ماشینی، از طریق فرایندهای

پیچیده، استفاده بهینه از این داده‌ها را برای تصمیم‌گیری مبتنی بر شواهد تسهیل می‌کند. از تعداد زیادی داده‌های بالینی و آزمایشگاهی، یادگیری ماشینی می‌تواند به طور خودکار قوانین معنی‌داری را استخراج کند که همراه با پیشرفت‌های گسترده در قدرت پردازش رایانه، توسعه ابزارهای پیش‌بینی را ممکن می‌کند [۵].

هوش مصنوعی (Artificial Intelligence; AI) مفهومی کلی است که به مجموعه‌ای از روش‌ها و سامانه‌ها اطلاق می‌شود و هدف آن‌ها شبیه‌سازی یا پشتیبانی از جنبه‌هایی از تصمیم‌گیری و استدلال انسانی است، درحالی‌که یادگیری ماشینی (Machine Learning; ML) به عنوان زیرمجموعه‌ای از AI، بر توسعه الگوریتم‌هایی تمرکز دارد که می‌توانند الگوها را مستقیماً از داده‌ها بیاموزند و بدون برنامه‌نویسی صریح، عملکرد خود را بهبود دهند. بیشتر کاربردهای گزارش شده در زمینه مقاومت ضد میکروبی بر روش‌های یادگیری ماشینی متکی هستند، نه بر کل طیف فناوری‌های AI. الگوریتم‌های ML به‌طور کلی به سه دسته اصلی تقسیم می‌شوند: یادگیری نظارت شده که در آن مدل‌ها با استفاده از داده‌های برچسب‌گذاری شده برای پیش‌بینی خروجی‌هایی مانند مقاومت یا حساسیت آنتی‌بیوتیکی آموزش داده می‌شوند؛ یادگیری بدون نظارت که برای شناسایی الگوهای پنهان یا خوشه‌بندی داده‌های میکروبی و بالینی بدون برچسب مشخص به کار می‌رود؛ یادگیری تقویتی که در آن الگوریتم‌ها با دریافت بازخورد از محیط، سیاست‌های تصمیم‌گیری را به صورت تدریجی بهبود می‌دهند. در مطالعات بالینی AMR، روش‌های یادگیری نظارت شده، از جمله رگرسیون لجستیک، درخت تصمیم، جنگل تصادفی و شبکه‌های عصبی، بیشترین کاربرد را داشته‌اند، درحالی‌که شاخه‌های دیگر AI نقش محدودتری در این حوزه ایفا کرده‌اند [۶].

روش کار


این مطالعه به صورت مقاله مروری روایی با جست‌وجوی ساختاریافته (Structured narrative review) انجام شده است و هدف آن مرور و تحلیل کاربردهای هوش مصنوعی و یادگیری ماشینی در پیش‌بینی مقاومت آنتی‌بیوتیکی، تشخیص AMR و حمایت از تصمیم‌گیری بالینی در نسخه‌نویسی آنتی‌بیوتیک بوده است. تمرکز اصلی مطالعه بر شناسایی رویکردهای رایج، عملکرد گزارش‌شده الگوریتم‌ها، محدودیت‌های عملی و شکاف‌های موجود در شواهد بالینی بوده است. جست‌وجوی منابع علمی در پایگاه‌های داده PubMed، Scopus و Web of Science انجام شد. کلیدواژه‌های استفاده‌شده شامل ترکیبی از عبارات ذیل و معادل‌های مرتبط آن‌ها بود: Clinical decision support, Artificial, Antibiotic stewardship, Machine learning, intelligence, Antimicrobial resistance. جست‌وجو به مقالات منتشرشده به زبان انگلیسی

محدودیت‌ها و قابلیت کاربرد عملی، بررسی شدند.

نتایج

روش‌های تشخیص AMR

در حال حاضر، AMR اساساً با استفاده از دو تکنیک در میکروبیولوژی بالینی تشخیص داده می‌شود: یکی تست حساسیت ضد میکروبی مبتنی بر کشت کلاسیک (AST) و دیگری توالی‌یابی کل ژنوم برای آزمایش حساسیت ضد میکروبی (WGS-AST). اگرچه روش اول برای استفاده ساده‌تر و آسان‌تر است، معمولاً به یک روز یا بیشتر نیاز دارد تا نتایج حاصل شود که به‌طور قابل‌توجهی رژیم آنتی‌بیوتیکی تجربی را طولانی می‌کند و احتمال شکست درمان را، به‌دلیل درمان ناکارآمد یا تهدید گسترده‌شدن مقاومت ضد میکروبی، افزایش می‌دهد.



شکل ۱. روش‌های مختلف تشخیص AMR

آزمایش‌های تشخیصی سریع، دقیق و کم‌هزینه نیاز است [۸].

کاربردهای یادگیری ماشین در زمینه AMR

شواهد روبه‌رشدی هست که باوجود افزایش مقاومت به آنتی‌بیوتیک‌ها، یادگیری ماشینی می‌تواند به پزشکان کمک کند تا درمان ضدباکتری مناسب را براساس علائم بیمار و تاریخچه بالینی گذشته انتخاب کنند. در طول پنج سال گذشته، استفاده از برنامه‌های کاربردی هوش مصنوعی در چندین حوزه مراقبت‌های بهداشتی به‌طور قابل‌توجهی افزایش یافته است. از آنجاکه روش‌های محاسباتی مرسوم دیگر برای پردازش و تجزیه و تحلیل داده‌های بزرگ مناسب نیستند، بهره‌برداری از پایگاه‌های داده پزشکی بزرگ موجود با استفاده از ML ارزش آن‌ها را برجسته کرده است. بنابراین، آن‌ها شروع به تکثیر کرده‌اند. اکثر سیستم‌های ML در زمینه مقاومت ضد میکروبی بر تحقیق، توسعه دارو یا میکروبیولوژی بالینی تأکید دارند. به‌طور خاص، روش‌های ML برای تجزیه و تحلیل ژنوم باکتری‌ها، پیش‌بینی حساسیت دارویی، تشخیص الگوهای همه‌گیری برای

محدود شد. همچنین، مطالعاتی به این مرور وارد شدند که یکی از شرایط ذیل را داشتند: ۱. استفاده از الگوریتم‌های یادگیری ماشینی یا هوش مصنوعی برای پیش‌بینی مقاومت ضد میکروبی؛ ۲. تمرکز بر تشخیص AMR یا تسریع تست حساسیت آنتی‌بیوتیکی؛ ۳. کاربرد ابزارهای ML در حمایت از تصمیم‌گیری بالینی یا نسخه‌نویسی آنتی‌بیوتیک. مطالعات صرفاً آزمایشگاهی بدون ارتباط بالینی، گزارش‌های موردی و مقالات غیرمرتبط حذف شدند.

اطلاعات کلیدی هر مطالعه، شامل سال انتشار، تنظیمات پزشکی، نوع داده‌های ورودی، الگوریتم‌های مورد استفاده، شاخص‌های عملکرد گزارش‌شده و زمینه کاربرد بالینی استخراج شد. به‌دلیل ناهمگنی قابل‌توجه مطالعات از نظر طراحی، داده‌ها و شاخص‌های ارزیابی، فراسنجش کمی انجام نشد و نتایج به‌صورت کیفی و تحلیلی، با تمرکز بر مقایسه عملکرد،

کمیته اروپایی تست حساسیت ضد میکروبی (EUCAST) و مؤسسه استانداردهای بالینی و آزمایشگاهی (CLSI) برای تعیین مقاومت ضد میکروبی، آنتی‌بیوگرام‌های انتشار دیسک Kirby-Bauer و microdilution را به‌عنوان روش‌های مرجع توصیه می‌کنند. نتایج معمولاً کیفی هستند و به دسته‌های حساس یا مقاوم طبقه‌بندی می‌شوند. همچنین، این طبقه‌بندی بسته به نقطه شکست کالیبره‌شده با EUCAST، یا به‌صورت حداقل غلظت‌های بازدارنده (MICs) بیان می‌شوند.

اگرچه این روش‌های مرسوم مؤثرند، دست‌وپاگیر و زمان‌برند و انتخاب سریع یک درمان ضد عفونی هدفمند مؤثر را امکان‌پذیر نمی‌کنند. از آنجاکه نتایج را نمی‌توان زودتر از ۴۸ ساعت پس از دریافت نمونه به دست آورد، ممکن است به استفاده طولانی‌مدت یا استفاده بیش از حد از آنتی‌بیوتیک‌های طیف وسیع منجر شود. برای برخی از پاتوژن‌ها، به زمان انکوباسیون حتی طولانی‌تر (۷۲ ساعت یا بیشتر) نیاز است. از این‌رو، برای بهینه‌سازی استفاده از آنتی‌بیوتیک و به‌حداقل رساندن فشارهای انتخابی بالقوه، به

اهداف نظارتی، یا پیشنهاد درمان‌ها یا واکسن‌های ضدباکتری جدید توسعه داده شده‌اند. علاوه بر توسعه آنتی‌بیوتیک‌های جدید، بهینه‌سازی استفاده از داروهای فعلی به منظور استفاده صحیح با میزان مورد نیاز بیمار و رعایت طول درمان نیز اولویت کلیدی در توقف گسترش AMR بوده است؛ زیرا یکی از محرک‌های اصلی AMR استفاده نامناسب از آنتی‌بیوتیک‌هاست [۱].

چندین مطالعه بر استفاده از یادگیری ماشین برای بهبود تصمیم‌گیری بالینی و انتخاب آنتی‌بیوتیک، به‌ویژه در زمینه انتخاب درمان تجربی تمرکز کرده‌اند. روش‌های یادگیری ماشین ابتدا روی سوابق متعدد بیمار و اقدامات مقاومت آنتی‌بیوتیکی آموزش داده می‌شوند. یک مدل پیامد آموزش‌دیده می‌تواند پروفایل مقاومت را براساس داده‌های بالینی و میکروبیولوژیکی بیمار پیش‌بینی کند و برای انتخاب مناسب‌ترین رژیم آنتی‌بیوتیکی برای درمان عفونت، از نتایج استفاده می‌شود. گروه جداگانه‌ای از داده‌های بیمار برای ارزیابی دقت این مدل آموزش‌دیده، مقایسه نتایج مقاومت پیش‌بینی‌شده و مشاهده‌شده استفاده می‌شود [۷].

همانطور که در شکل ۱ دیده می‌شود، اجرای روش‌های ML به‌طور قابل‌ملاحظه‌ای زمان تشکیل پروفایل حساسیت ضد میکروبی را به کمتر از سه ساعت برای روش فلوسیتومتری AST (FAST) و تنها سی دقیقه برای طیف‌سنجی مادون قرمز (IR) کاهش داده‌اند. درحالی‌که این تشخیص‌ها به کمک ML می‌توانند تست حساسیت ضد میکروبی را تسریع کنند، برای انجام به زیرساخت‌های پرهزینه و پرسنل متخصص نیاز دارند [۵].

در مجموع، مطالعات مرور شده نشان می‌دهند که هوش مصنوعی و یادگیری ماشین می‌توانند پروفایل حساسیت ضد میکروبی را زودتر و دقیق‌تر از تصمیم‌گیری صرفاً تجربی حدس بزنند و در نتیجه، به انتخاب آنتی‌بیوتیک مناسب‌تر کمک کنند. از نظر بالینی، این موضوع به‌صورت نظری باید باعث کاهش درمان نامؤثر اولیه، کاهش مصرف آنتی‌بیوتیک‌های وسیع‌الطیف غیرضروری و بهبود درمان هدفمند شود؛ عواملی که در نهایت می‌توانند به کاهش فشار انتخابی و محدود شدن AMR کمک کنند [۱]. بااین‌حال، نکته مهم این است که در بسیاری از مطالعات، مفهوم «موفقیت» با شاخص‌های پیش‌بینی (مثل AUC) سنجیده شده‌اند و این موضوع با پیامدهای قطعی، مانند کاهش مرگ‌ومیر یا کاهش طول بستری، انجام نگرفته است. بنابراین، باید بین بهبود پیش‌بینی مدل یادگیری ماشین و بهبود واقعی بیمار تفاوت قائل شد [۱۷، ۱۸].

از نظر نوع شواهد، مطالعات مرور شده را می‌توان به‌طور کلی در دو دسته قرار داد: نخست، مدل‌های پیش‌بینی مقاومت یا ریسک که خروجی آن‌ها به پزشک در انتخاب درمان مناسب کمک می‌کند. دوم، مدل‌هایی که مستقیماً در تصمیم‌نویسی کمک می‌کنند و هدف اصلی آن‌ها کاهش تجویز نامناسب یا آنتی‌بیوتیک‌های وسیع‌الطیف است. در دسته اول،

چندین مطالعه نشان داده‌اند که مدل‌های مبتنی بر درخت تصمیم و روش‌های مشابه می‌توانند برای پیش‌بینی مقاومت در عفونت‌های مهم کاربرد داشته باشند. برای مثال، گودمن و همکاران با استفاده از پارتیشن‌بندی بازگشتی، یک درخت تصمیم برای پیش‌بینی تولید ESBL در *شرشیا کلی* و *کلبسیلا* توسعه دادند [۹]. به‌طور مشابه، گیلامت و همکاران روش‌هایی برای پیش‌بینی مقاومت به *پیپراسیلین-تازوباکتام*، *سفیم* و *مروپنم* در بیماران مبتلا به عفونت جریان خون گرم منفی ارائه و نشان دادند که از نظر دقت پیش‌بینی، توافق کلی مناسبی بین خروجی‌های مدل‌های رگرسیون لجستیک چندمتغیره و درخت‌های تصمیم بالینی وجود دارد [۱۰]. جمع‌بندی این نتایج نشان می‌دهد که مدل‌های ساده‌تر و قابل‌توضیح، مانند درخت تصمیم، در برخی سناریوهای بالینی می‌توانند به عملکرد قابل‌قبولی برسند و از نظر پیاده‌سازی عملی، این مزیت را داشته باشند که پزشکان به راحتی آن‌ها را بفهمند. بااین‌حال، باید توجه کرد که اغلب این مطالعات پیامدهای بالینی مانند کاهش مرگ‌ومیر یا کوتاه‌شدن طول درمان را به‌طور مستقیم ارزیابی نکرده‌اند و شواهد موجود بیشتر به بهبود دقت پیش‌بینی محدود می‌شود [۱۷، ۱۸].

در همین زمینه، موران و همکاران عملکرد نوعی الگوریتم منبع‌باز به نام XGBoost را برای پیش‌بینی مقاومت ضد میکروبی در سه گونه گرم منفی (براساس ایزوله‌های خون و ادرار بیماران طی ۴۸ ساعت پذیرش) بررسی کردند و گزارش دادند که عملکرد ML از کادر پزشکی و ابزار ساده ارزیابی ریسک بهتر بوده است [۷]. جمع‌بندی این مطالعه این است که ML می‌تواند کیفیت تصمیم اولیه را بهتر کند، به‌خصوص وقتی پزشک با عدم قطعیت زیاد روبه‌رو است، اما محدودیت اصلی، که خود مطالعه هم به آن اشاره می‌کند، محدود بودن دامنه آموزش مدل (چند ارگانیزم و چند آنتی‌بیوتیک خاص) و در نتیجه، محدودیت تعمیم‌پذیری است، یعنی ممکن است در بیمارستان یا جمعیت دیگر همان عملکرد تکرار نشود.

مشاهده مهم درباره کاربرد واقعی در زمان تصمیم‌گیری از مطالعه مک‌گوایر و همکاران دیده می‌شود که نشان دادند داده‌های EHR می‌تواند برای پیش‌بینی وجود مقاومت کاربایتم در زمان نمونه‌گیری کشت استفاده شود. در این مطالعه، حساسیت مدل نسبتاً کم بود و PPV حدود ۳۰ درصد گزارش شد، اما NPV بالای ۹۹ درصد به دست آمد. این الگو از نتایج یک پیام کاربردی دارد: چنین مدلی شاید برای اثبات مقاومت ابزار قوی نباشد، اما برای رد کردن مقاومت می‌تواند بسیار مفید باشد و کمک کند پزشک با اطمینان بیشتری از تجویز کاربایتم غیرضروری پرهیز کند (بدون اینکه درمان مؤثر را از دست بدهد). بااین‌حال، این هم هنوز به معنی اثبات کاهش طول بستری یا نرخ مرگ‌ومیر نیست و بیشتر نشان‌دهنده مسیر منطقی برای کاهش مصرف بی‌مورد آنتی‌بیوتیک وسیع‌الطیف است [۱].

همچنین هندرسون و همکاران در گروه محدودی از بیماران HIV تلاش کردند پیش‌بینی‌کننده‌های عفونت MDR Enterobacterales را با مدل طبقه‌بندی ML تفکیک کنند که اهمیت آن بیشتر در گروه‌های پرخطر است، ولی باز هم برای نتیجه‌گیری قطعی دربارهٔ پیامدهای بالینی، به مطالعات مداخله‌ای نیاز است [۱۱، ۲۲].

کاربردهای یادگیری ماشین در زمینهٔ تجویز نسخهٔ آنتی‌بیوتیک

از دید بالینی، مهم‌ترین نقطه‌ای که ML می‌تواند در آن اثر بگذارد، مرحلهٔ درمان تجربی است؛ همان‌جایی که تأخیر یا انتخاب نامناسب می‌تواند خطرناک باشد. برای مثال، در بیماران بدحال با شوک سپتیک، تأخیر در شروع درمان مؤثر می‌تواند پیامدها را بدتر کند؛ در یک گزارش، افزایش قابل‌توجه مرگ‌ومیر با دریافت نکردن درمان فعال در ساعات اولیه مطرح شده است [۳]. بنابراین، اگر ML بتواند احتمال مقاومت را دقیق‌تر تخمین بزند، به‌صورت نظری می‌تواند به انتخاب سریع‌تر درمان مؤثر کمک کند، اما نکتهٔ کلیدی که بارها ذکر شد این است که بسیاری از مدل‌ها به‌جای اندازه‌گیری مستقیم مرگ‌ومیر یا طول بستری، روی پیامدهای واسطه‌ای مثل «انتخاب درست‌تر آنتی‌بیوتیک» تمرکز کرده‌اند [۱۷، ۱۸].

در سطح جامعه و عفونت‌های شایع مثل UTI، یلین و همکاران نشان دادند که توصیه‌های دارویی مبتنی بر رایانه می‌تواند نسبت نسخه‌های نامناسب را کاهش دهد (حدود ۵ درصد در برابر ۹ درصد؛ اگر همین کار را پزشکان انجام دهند). این نتیجه نشان می‌دهد ابزارهای یادگیری ماشین که به تصمیم‌گیری کمک می‌کنند، می‌توانند رفتار نسخه‌نویسی را بهبود دهند، ولی محدودیت مهم آن ناتوانی در انتخاب باریک‌ترین طیف ممکن، حتی در میان گزینه‌های کم‌مقاومت‌تر بوده است [۱۲]. بنابراین، جمع‌بندی منصفانه این است که ML می‌تواند کاهش خطای آشکار را انجام دهد، اما برای بهینه‌سازی دقیق طیف تشخیصی هنوز کافی نیست و باید با اصول تشخیص بالینی و راهنماها ترکیب شود [۱، ۱۲].

در همین زمینه، کنجیلال و همکاران با داده‌های EHR الگوریتمی ساختند که برای UTI بدون عارضه، حداقل آنتی‌بیوتیک وسیع‌الطیف لازم را پیشنهاد می‌داد و گزارش کردند که نسبت به پزشکان، تجویز آنتی‌بیوتیک‌های وسیع‌الطیف و غیرمؤثر کاهش یافته است [۱۳]. این نتیجه از نظر بالینی بسیار مهم است، چون دقیقاً به یکی از اهداف اصلی ASP، یعنی کاهش مصرف غیرضروری آنتی‌بیوتیک‌های وسیع‌الطیف نزدیک می‌شود [۱]. در مطالعهٔ تزلوز و همکاران نیز نشان داده شد که حتی با داده‌های ساده‌تر (مثل رنگ‌آمیزی گرم) می‌توان به دقت قابل‌قبول رسید (حدود ۷۷ درصد) و پس از شناسایی

میکروارگانیزم، دقت به حدود ۸۷ درصد نزدیک می‌شود [۱۴]. برداشت عملی از این دو مطالعه این است که ML می‌تواند با داده‌های کم‌هزینه‌تر هم کمک‌کننده باشد، اما کیفیت و نوع دادهٔ ورودی در عملکرد اثر مستقیم دارد و هرچه اطلاعات میکروبیولوژیک کامل‌تر شود، مدل بهتر تصمیم می‌دهد [۵، ۱۴]. از طرف دیگر، چند مطالعه نشان می‌دهند که بسیاری از مدل‌ها وابسته به محل هستند؛ یعنی چون الگوهای مقاومت و جمعیت بیماران بین بیمارستان‌ها فرق دارد، مدل‌ها ممکن است در محیط جدید افت عملکرد داشته باشند و به بازآموزی دوره‌ای نیاز پیدا کنند [۱]. همچنین، مطالعه‌ای که به آنتی‌بیوگرام‌های شخصی‌سازی‌شده و مبادلهٔ بین کاهش طیف و عملکرد اشاره می‌کند، نشان می‌دهد هدف فقط بیشترین دقت نیست، بلکه باید هم‌زمان ایمنی بیمار و کاهش فشار انتخابی دیده شود. در همین زمینه، ریچ و همکاران گزارش کردند که BLR توسعه‌داده‌شده توسط آن‌ها در مقایسه با درخت تصمیم و جنگل تصادفی عملکرد متمایز بالاتری داشته است، اما همچنان اجرای بالینی موفق نیازمند ادغام درست در جریان کار و پایش نتایج واقعی است [۱۵]. همچنین، اشاره به ظهور مقاومت با وجود درمان مطابق ریسک (به‌دلیل سویهٔ متفاوت)، نشان می‌دهد حتی بهترین مدل‌های پیش‌بینی هم همهٔ مسئله را حل نمی‌کنند و داده‌های سطح میکروبیوم و مصرف آنتی‌بیوتیک می‌تواند برای توصیه‌های بیمارمحور مفید باشد [۱۵].

باوجود نتایج امیدوارکنندهٔ گزارش‌شده در مطالعات مرور شده، یافتهٔ مشترک و تکرارشونده، وجود محدودیت‌های جدی در کاربرد عملی مدل‌های یادگیری ماشینی است. بخش قابل‌توجهی از این الگوریتم‌ها بر داده‌های تک‌منبعی، گذشته‌نگر و وابسته به الگوهای مقاومت محلی آموزش دیده‌اند و در نتیجه، تعمیم‌پذیری آن‌ها به محیط‌های بالینی دیگر محدود باقی می‌ماند [۱]. علاوه بر این، چندین مطالعه نشان داده‌اند که با تغییر الگوهای مصرف آنتی‌بیوتیک و پویایی مقاومت ضد میکروبی در طول زمان، عملکرد مدل‌ها می‌تواند کاهش یابد و نیاز به بازآموزی دوره‌ای وجود داشته باشد؛ موضوعی که خود مستلزم زیرساخت داده‌ای پایدار و نیروی انسانی متخصص است [۱، ۱۷].

درعین‌حال، مرور مطالعات نشان می‌دهد که ابزارهای ML در برخی محیط‌ها قادر بوده‌اند توصیه‌هایی با طیف محدودتر در مقایسه با نسخه‌های معمول ارائه دهند و به کاهش تجویز غیرضروری آنتی‌بیوتیک کمک کنند. برای مثال، استفاده از الگوریتم‌های پیش‌بینی مبتنی بر شرایط بیمار و ابزارهای کمک‌تصمیم در بخش اورژانس گزارش شده است [۱۶]. بااین‌حال، خلأ اساسی در شواهد موجود آن است که در بسیاری از موارد هنوز مشخص نیست اجرای واقعی این مدل‌ها روی بیماران چه تأثیری در پیامدهای بالینی سخت‌مانند طول بستری، عوارض، هزینه و مرگ‌ومیر دارد. بنابراین، اگرچه شواهد فعلی برای بهبود تصمیم نسخه‌نویسی و کاهش مصرف

غیرضروری آنتی‌بیوتیک‌ها نسبتاً امیدوارکننده است، شواهد عملی برای نتیجه‌گیری قطعی درباره کارایی پایدار و گسترده هوش مصنوعی در محیط‌های واقعی بالینی همچنان محدود و غیرقطعی و نیازمند مطالعات دنیای واقعی و کارآزمایی‌های

مداخله‌ای بیشتر است [۱۷، ۱۸، ۲۲، ۲۳]. جدول ۱ عملکرد الگوریتم‌های یادگیری ماشینی را برای کمک به تجویز آنتی‌بیوتیک در مطالعات مختلف خلاصه می‌کند.

جدول ۱. عملکرد تجویز آنتی‌بیوتیک به کمک یادگیری ماشینی در مطالعات مختلف

نویسنده	سال انتشار	تنظیمات پزشکی	تنظیمات جغرافیایی	داده‌های ورودی	الگوریتم‌های ML	سنجش عملکرد	گونه‌های باکتریایی
هبرت و همکاران	۲۰۲۰	بیماران داخل بیمارستانی	ایالات متحده آمریکا	جمعیت‌شناسی / کشت ادرار / نسخه‌های قبلی آنتی‌بیوتیک	PLR	AUC 0.65 تا 0.69	ایزوله‌های باکتری از کشت ادرار
تزلوز و همکاران	۲۰۲۲	بخش اورژانس/بخش اورولوژی	یونان	جمعیت‌شناسی / رنگ‌آمیزی گرم / گونه‌های باکتری / نوع نمونه / AST	MLR با برآوردگر برجستگی	AUC 0.768 (باکتری ناشناخته) AUC 0.874 (باکتری شناخته شده)	ایزوله‌های باکتری از کشت ادرار
کنجیلال و همکاران	۲۰۲۰	داخل بیمارستانی و سرپایی	ایالات متحده آمریکا	دموگرافیک/کشت ادرار/نسخه‌های قبلی آنتی‌بیوتیک	رگرسیون لجستیک، درخت تصمیم، جنگل تصادفی	AUC 0.56-0.64	ایزوله‌های باکتری از کشت ادرار
کولف اپشتاین و همکاران	۲۰۲۱	بیماران داخل بیمارستانی	ایالات متحده آمریکا	داده‌های پرونده الکترونیک سلامت/نتایج حساسیت به آنتی‌بیوتیک	رگرسیون لجستیک، شبکه LASSO، عصبی، GBDT، گروه [†]	AUC 0.73-0.79 (باکتری ناشناخته) AUC 0.8-0.88 (باکتری شناخته شده)	ایزوله‌های باکتری از خون/ادرار/دیگر کشت‌ها
رابان و همکاران	۲۰۲۲	بخش اورژانس	ایالات متحده آمریکا	داده‌های پرونده الکترونیک سلامت/نتایج حساسیت به آنتی‌بیوتیک	رگرسیون لجستیک، LASSO/Ridge، جنگل تصادفی و GBDT	AUC 0.64-0.74	ایزوله‌های باکتری از خون/ادرار/دیگر کشت‌ها
راسون و همکاران	۲۰۲۱	پذیرش در بیمارستان	انگلستان	اطلاعات بالینی، میکروبیولوژیکی، تجویزی	استدلال مبتنی بر مورد (CBR)	OR: 1.77; 95% فاصله اطمینان 1.212- (CI) 2.588; $p < 0.01$	عفونت‌های جریان خون/شرشیاکلی
ریچ و همکاران	۲۰۲۲	داخل بیمارستانی و سرپایی	ایالات متحده آمریکا	دموگرافیک، تشخیص‌های قبلی، نسخه‌ها و آزمایش‌های حساسیت آنتی‌بیوتیکی	درخت تصمیم، رگرسیون لجستیک، تقویت‌شده (BLR)، جنگل تصادفی	AUC 0.57-0.66	ایزوله‌های باکتری از کشت ادرار

[†] روش‌های آماری و الگوریتم‌های یادگیری ماشینی

بحث

باوجود رشد سریع کاربردهای هوش مصنوعی و یادگیری ماشینی در حوزه پیش‌بینی مقاومت آنتی‌بیوتیکی، نتایج این مرور نشان می‌دهد که ارزیابی نقش واقعی این ابزارها در عمل بالینی نیازمند نگاهی محتاطانه و مبتنی بر شواهد موجود است. اگرچه بسیاری از مطالعات عملکرد قابل‌قبولی را برای الگوریتم‌های ML گزارش کرده‌اند، شواهد فعلی تصویر ناهمگن و وابسته‌ای به زمینه مطالعه از کارایی این روش‌ها ارائه می‌دهد که باید به‌دقت تفسیر شود.

باوجود رشد سریع کاربردهای هوش مصنوعی و یادگیری ماشینی در حوزه پیش‌بینی مقاومت آنتی‌بیوتیکی، نتایج این مرور نشان می‌دهد که ارزیابی نقش واقعی این ابزارها در عمل بالینی نیازمند نگاهی محتاطانه و مبتنی بر شواهد موجود است. اگرچه

پیش‌بینی مقاومت یا حساسیت تمرکز دارند و معیار «باریک‌ترین طیف مناسب» را به‌طور صریح در فرایند تصمیم‌گیری لحاظ نمی‌کنند. این مسئله چالش مفهومی مهمی در ترجمه خروجی‌های ML به توصیه‌های بالینی مسئولیت‌پذیرانه ایجاد می‌کند و نشان می‌دهد که بدون ادغام صریح اصول مسئولیت‌پذیری در طراحی مدل‌ها، ارزش این ابزارها در حمایت واقعی از ASP می‌تواند محدود شود.

از سوی دیگر، اکثر مطالعات مرور شده به داده‌های استخراج‌شده از پرونده‌های سلامت الکترونیکی متکی بوده‌اند؛ داده‌هایی که اغلب با خطاهای ورودی، سوایق تکراری، داده‌های گمشده و بایاس‌های جمعیتی همراه هستند. این واقعیت که داده‌های ضعیف به مدل‌های ضعیف منجر می‌شوند، به‌طور مستقیم در عملکرد و تعمیم‌پذیری مدل‌های ML در AMR منعکس شده است. تفاوت‌های جمعیتی، اپیدمیولوژیک و ساختاری بین مراکز درمانی می‌تواند به بروز بایاس آماری و کاهش کارایی مدل‌ها در محیط‌های جدید منجر شود. بر این اساس، آینده کاربرد موفق ML در AMR نه‌فقط در توسعه الگوریتم‌های پیچیده‌تر، بلکه در بهبود کیفیت داده، اعتبارسنجی خارجی، بازآموزی منظم، و ادغام این ابزارها با راهنماهای بالینی و اصول نظارت آنتی‌بیوتیکی نهفته است.

به‌طور کلی نتایج این مرور نشان می‌دهد که الگوریتم‌های یادگیری ماشینی می‌توانند در بهبود و پیشرفت تصمیم‌گیری درمان بیماران و کاهش تجویز نامناسب یا غیرضروری آنتی‌بیوتیک‌ها نقش کمکی ایفا کنند، اما شواهد موجود برای اثبات کارایی پایدار و تأثیر نهایی آن‌ها بر مرگ‌ومیر، طول بستری یا هزینه درمان هنوز غیرقطعی است. بنابراین، رویکردی واقع‌بینانه ایجاب می‌کند که هوش مصنوعی در حال حاضر به‌عنوان ابزار پشتیبان و نه جایگزین قضاوت بالینی یا اصول ASP در نظر گرفته شود و کاربرد گسترده آن به نتایج مطالعات دنیای واقعی و کارآزمایی‌های مداخله‌ای آینده وابسته بماند.

نتیجه‌گیری

این مقاله مروری نشان می‌دهد که یادگیری ماشینی، به‌عنوان زیرمجموعه‌ای از هوش مصنوعی، در سال‌های اخیر توجه قابل توجهی را در زمینه مقاومت ضد میکروبی به خود جلب کرده و در حوزه‌هایی مانند پیش‌بینی مقاومت، تسریع تشخیص AMR و حمایت از تصمیم‌گیری در نسخه‌نویسی آنتی‌بیوتیک استفاده شده است. مرور شواهد موجود حاکی از آن است که اگرچه برخی مدل‌های ML توانسته‌اند عملکرد قابل قبولی در شرایط خاص و وابسته به زمینه ارائه دهند، برتری پایدار و عمومی آن‌ها در مقایسه با روش‌های آماری مرسوم به‌طور قاطع اثبات نشده است. مقادیر عملکرد گزارش‌شده، ناهمگنی بالای مطالعات و وابستگی شدید مدل‌ها به داده‌ها و تنظیمات محلی نشان می‌دهد که نقش فعلی ML بیشتر به‌عنوان ابزار پشتیبان تصمیم‌گیری قابل تفسیر

یکی از نکات مهمی که از مطالعات مرور شده و به‌ویژه از داده‌های خلاصه‌شده در جدول ۱ قابل‌برداشت است این است که عملکرد مدل‌های ML لزوماً به‌طور پایدار و قانع‌کننده‌ای برتر از روش‌های آماری مرسوم مانند رگرسیون لجستیک نیست. در بسیاری از مطالعات، مقادیر AUC گزارش‌شده برای الگوریتم‌های پیشرفته تفاوت چشمگیری با مدل‌های آماری کلاسیک نداشته‌اند. این یافته نشان می‌دهد که ارزش اصلی ML در این حوزه الزاماً در «برتری عددی مطلق» خلاصه نمی‌شود، بلکه بیشتر در توانایی پردازش هم‌زمان متغیرهای متعدد، داده‌های ناهمگون و پشتیبانی از تصمیم‌گیری در شرایط عدم قطعیت و محدودیت زمانی، به‌ویژه در محیط‌هایی مانند اورژانس یا پذیرش بیمارستانی، نهفته است. بنابراین، ادعای برتری ML در مقایسه با روش‌های سنتی باید به‌صورت موقعیتی و وابسته به سناریوی بالینی تفسیر شود، نه به‌عنوان مزیت عمومی و همیشگی.

همچنین، مرور مطالعات نشان می‌دهد که عملکرد الگوریتم‌های ML به‌شدت تحت‌تأثیر نوع داده‌های ورودی، تنظیمات پزشکی و زمینه بالینی قرار دارد. تفاوت در عملکرد مدل‌ها بین عفونت‌های ادراری، عفونت‌های جریان خون، بیماران بستری یا مراجعه‌کنندگان به اورژانس و نیز بین مواردی که گونه باکتریایی از پیش شناخته‌شده یا ناشناخته است، بیانگر این واقعیت است که ML در حوزه AMR ابزار وابسته به زمینه محسوب می‌شود. این ناهمگنی نشان می‌دهد که شکست یا موفقیت یک مدل در یک محیط خاص، الزاماً قابل تعمیم به محیط‌های دیگر نیست و نباید به‌عنوان قضاوت کلی درباره کارایی یا ناکارآمدی الگوریتم‌های یادگیری ماشینی تلقی شود.

یکی از مهم‌ترین یافته‌های مشترک مطالعات مرور شده، محدودیت جدی در تعمیم‌پذیری مدل‌های پیش‌بینی است. تقریباً تمامی مدل‌ها بر داده‌های تک‌منبعی یا محدود به یک کشور آموزش دیده‌اند و به الگوهای مقاومت محلی و رفتار تجویز خاص همان محیط وابسته‌اند. علاوه بر این، پویایی مقاومت باکتریایی و تغییر الگوهای مصرف آنتی‌بیوتیک در طول زمان باعث می‌شود عملکرد مدل‌ها به تدریج افت کند و نیاز به بازآموزی دوره‌ای داشته باشد. این مسئله نشان می‌دهد که مدل‌های ML در حال حاضر، ابزارهای آماده استفاده عمومی نیستند و اجرای موفق آن‌ها مستلزم زیرساخت داده‌ای پایدار، به‌روزرسانی مستمر و منابع انسانی متخصص است. از این منظر، تعمیم‌پذیر نبودن محدودیت حاشیه‌ای نیست، بلکه چالش ساختاری در کاربرد عملی هوش مصنوعی در AMR محسوب می‌شود.

یکی از ضعف‌های مهم که در برخی مطالعات نسخه‌نویسی آنتی‌بیوتیک به کمک ML مشاهده شده، ناتوانی الگوریتم‌ها در انتخاب آنتی‌بیوتیک با باریک‌ترین طیف ممکن از میان گزینه‌های کم‌مقاومت است. درحالی‌که هدف اصلی برنامه‌های نظارت ضد میکروبی استفاده از مؤثرترین دارو با محدودترین طیف برای کاهش فشار انتخابی است، بسیاری از مدل‌های ML صرفاً بر

پیچیده‌تر، بلکه به بهبود زیرساخت داده، اعتبارسنجی خارجی، ادغام اصول نظارت ضد میکروبی در طراحی مدل‌ها و انجام مطالعات دنیای واقعی و مداخله‌ای وابسته است. تا آن زمان، استفاده از ML باید با رویکردی محتاطانه، زمینه‌محور و مکمل راهنماهای بالینی موجود در نظر گرفته شود.

تضاد منافع

نویسندگان هیچ‌گونه تعارض منافع با یکدیگر ندارند.

است، نه راه‌حل مستقل یا جایگزین قضاوت بالینی. از سوی دیگر، این مرور به‌طور مشخص نشان می‌دهد که محدودیت‌هایی مانند تعمیم‌پذیر نبودن، نیاز به بازآموزی دوره‌ای، کیفیت و بایاس داده‌های EHR و ناتوانی برخی مدل‌ها در اولویت‌دهی به آنتی‌بیوتیک‌های با طیف باریک، چالش‌های اساسی در ترجمه الگوریتم‌های ML به کاربردهای بالینی مسئولانه محسوب می‌شوند. در نتیجه، موفقیت آینده یادگیری ماشینی در مدیریت AMR نه صرفاً به توسعه الگوریتم‌های

REFERENCES

- WHO Regional Office for Europe, European Centre for Disease Prevention and Control. Antimicrobial resistance surveillance in Europe 2022-2020 data. Copenhagen: WHO Regional Office for Europe; 2022. [\[Link\]](#)
- Aljeldah MM. Antimicrobial resistance and its spread is a global threat. *Antibiotics (Basel)*. 2022;11:1082. [\[DOI: 10.3390/antibiotics11081082\]](#)
- Kollef MH, Shorr AF, Bassetti M, Timsit JF, Micek ST, Michelson AP, et al. Timing of antibiotic therapy in the ICU. *Crit Care*. 2021;25:360. [\[DOI: 10.1186/s13054-021-03787-z\]](#)
- Rawson TM, Ming D, Ahmad R, Moore LSP, Holmes AH. Antimicrobial use, drug-resistant infections and COVID-19. *Nat Rev Microbiol*. 2020;18:409-410. [\[DOI: 10.1038/s41579-020-0395-y\]](#)
- Macesic N, Polubriaginof F, Tatonetti NP. Machine learning: novel bioinformatics approaches for combating antimicrobial resistance. *Curr Opin Infect Dis*. 2017;30:511-517. [\[DOI: 10.1097/qco.0000000000000406\]](#)
- Rajpurkar P, Chen E, Banerjee O, Topol EJ. AI in health and medicine. *Nat Med*. 2022;28:31-38. [\[DOI: 10.1038/s41591-021-01614-0\]](#)
- Moran E, Robinson E, Green C, Keeling M, Collyer B. Towards personalized guidelines: using machine-learning algorithms to guide antimicrobial selection. *J Antimicrob Chemother*. 2020;75:2677-2680. [\[DOI: 10.1093/jac/dkaa222\]](#)
- Benkova M, Soukup O, Marek J. Antimicrobial susceptibility testing: currently used methods and devices and the near future in clinical practice. *J Appl Microbiol*. 2020;129:806-822. [\[DOI: 10.1111/jam.14704\]](#)
- Goodman KE, Lessler J, Cosgrove SE, Harris AD, Lautenbach E, Han JH, et al. A clinical decision tree to predict whether a bacteremic patient is infected with an extended-spectrum β -lactamase-producing organism. *Clin Infect Dis*. 2016;63:896-903. [\[DOI: 10.1093/cid/ciw425\]](#)
- Vazquez-Guillamet MC, Vazquez R, Micek ST, Kollef MH. Predicting resistance to piperacillin-tazobactam, cefepime and meropenem in septic patients with bloodstream infection due to Gram-negative bacteria. *Clin Infect Dis*. 2017;65:1607-1614. [\[DOI: 10.1093/cid/cix612\]](#)
- Henderson HI, Napravnik S, Kosorok MR, Gower EW, Kinlaw AC, Aiello AE, et al. Predicting risk of multidrug-resistant Enterobacteriales infections among people with HIV. *Open Forum Infect Dis*. 2022;9:ofac487. [\[DOI: 10.1093/ofid/ofac487\]](#)
- Oonsivilai M, Mo Y, Luangasanatip N, Lubell Y, Miliya T, Tan P, et al. Using machine learning to guide targeted and locally-tailored empiric antibiotic prescribing in a children's hospital in Cambodia. *Wellcome Open Res*. 2018;3:131. [\[DOI: 10.12688/wellcomeopenres.14847.1\]](#)
- Kanjilal S, Oberst M, Boominathan S, Zhou H, Hooper DC, Sontag D. A decision algorithm to promote outpatient antimicrobial stewardship for uncomplicated urinary tract infection. *Sci Transl Med*. 2020;12:eaay5067. [\[DOI: 10.1126/scitranslmed.aay5067\]](#)
- Tzelves L, Lazarou L, Feretzakis G, Kalles D, Mourmouris P, Loupelis E, et al. Using machine learning techniques to predict antimicrobial resistance in stone disease patients. *World J Urol*. 2022;40:1731-1736. [\[DOI: 10.1007/s00345-022-04043-x\]](#)
- Rich SN, Jun I, Bian J, Boucher C, Cherabuddi K, Morris JG Jr, et al. Development of a prediction model for antibiotic-resistant urinary tract infections using integrated electronic health records from multiple clinics in North-Central Florida. *Infect Dis Ther*. 2022;11:1869-1882. [\[DOI: 10.1007/s40121-022-00677-x\]](#)
- Wong JG, Aung AH, Lian W, Lye DC, Ooi CK, Chow A. Risk prediction models to guide antibiotic prescribing: a study on adult patients with uncomplicated upper respiratory tract infections in an emergency department. *Antimicrob Resist Infect Control*. 2020;9:171. [\[DOI: 10.1186/s13756-020-00825-3\]](#)
- Wiens J, Shenoy ES. Machine learning for healthcare: on the verge of a major shift in healthcare epidemiology. *Clin Infect Dis*. 2018;66:149-153. [\[DOI: 10.1093/cid/cix731\]](#)
- Tang R, Luo R, Tang S, Song H, Chen X. Machine learning in predicting antimicrobial resistance: a systematic review and meta-analysis. *Int J Antimicrob Agents*. 2022;60:106684. [\[DOI: 10.1016/j.ijantimicag.2022.106684\]](#)
- Waring J, Lindvall C, Umerton R. Automated machine learning: review of the state-of-the-art and opportunities for healthcare. *Artif Intell Med*. 2020;104:101822. [\[DOI: 10.1016/j.artmed.2020.101822\]](#)
- Elmagarmid AK, Ipeirotis PG, Verykios VS. Duplicate record detection: a survey. *IEEE Trans Knowl Data Eng*. 2007;19:1-16. [\[Link\]](#)
- Sakagianni A, Koufopoulou C, Feretzakis G, Kalles D, Verykios VS, Myrianthefs P, et al. Using machine learning to predict antimicrobial resistance—a literature review. *Antibiotics (Basel)*. 2023;12(3):452. [\[DOI: 10.3390/antibiotics12030452\]](#)
- Rawson TM, Ahmad R, Toumazou C, Georgiou P, Holmes AH. Artificial intelligence can improve decision-making in infection management. *Nat Hum Behav*. 2019;3:543-545. [\[DOI: 10.1038/s41562-019-0583-9\]](#)
- Rabaan AA, Alhumaid S, Mutair AA, Garout M, Abulhamayel Y, Halwani MA, et al. Application of artificial intelligence in combating high antimicrobial resistance rates. *Antibiotics (Basel)*. 2022;11(6):784. [\[DOI: 10.3390/antibiotics11060784\]](#)