Imunologia & Doenças Infecciosas e Parasitárias

EDIÇÃO XII

Capítulo 44

INTELIGÊNCIA ARTIFICIAL NA INFECTOLOGIA: DIAGNÓSTICO, DESFECHOS E VIGILÂNCIA







BARBARA SUELLEN GUIMARAES MARIN FERREIRA[1]
RAFAELA CRISTINA GUIMARAES MARIN FERREIRA[1]
JOAO RICARDO GARCIA[1]
ELY MATARAZZI FERREIRA TEIXEIRA DA SILVA[1]
GUILHERME OLIVEIRA BOLOGNESI[1]
ISAAC PEREIRA CRUZ[1]
BIANCA DOS SANTOS SILVESTRE[1]
CAIO BURRI MIRANDA[1]
ANA JULIA FERNANDES LEMKE[1]
EVELYN GERLACH[1]
BARBARA FERREIRA LIMA[1]
LETÍCIA FLORIANO[1]
YASMIN VIEIRA CAMPOS OLIVEIRA[1]
GIOVANA GOMES DE OLIVEIRA[1]

1. Discente – Doutor em Medicina pela Faculdade de Medicina da Universidade de São Paulo (FMUSP), Infectologista pelo programa de Residência do Hospital das Clínicas da FMUSP, Eduardo Guandelini da Silva.

Palavras-chave: *Inteligência Artificial; Doenças Infecciosas; Aprendizado de Máquina.*

DOI 10.59290/5861100224

EDITORA PASTEUR

INTRODUÇÃO

Nas últimas décadas, o avanço da capacidade computacional e a crescente disponibilidade de grandes volumes de dados têm ampliado a aplicação da inteligência artificial (IA) em diferentes áreas da saúde. Na infectologia, essa transformação assume particular relevância diante da diversidade de informações envolvidas na compreensão das doenças infecciosas, que abrangem desde dados clínicos e laboratoriais até informações microbiológicas, genômicas e epidemiológicas. Nesse contexto, ferramentas baseadas em IA têm sido progressivamente investigadas como estratégias capazes de processar e integrar essas diferentes fontes de informação, auxiliando tanto a abordagem individual do paciente quanto a compreensão da dinâmica das doenças em nível populacional.

Apesar desse potencial, a incorporação da IA à saúde exige uma análise crítica de suas limitações. A qualidade e a representatividade dos dados utilizados, a possibilidade de vieses algorítmicos, as limitações de generalização e a reduzida interpretabilidade de determinados modelos podem comprometer a confiabilidade de seus resultados. Dessa forma, sistemas de IA devem ser compreendidos como ferramentas de apoio à análise e à tomada de decisão, e não como substitutos da avaliação especializada, permanecendo necessária a supervisão humana para interpretação e contextualização das informações produzidas (GIACOBBE *et al.* 2023; VILLANUEVA-MIRANDA *et al.* 2025).

Diante desse cenário, este capítulo tem como objetivo discutir as perspectivas da IA aplicada à Infectologia, com ênfase em três principais eixos: diagnóstico, predição de desfechos e vigilância epidemiológica. Além de suas potenciais contribuições, serão discutidos os principais desafios relacionados à confiabilidade dos dados, à interpretabilidade dos modelos, à privacidade e à integração responsável dessas tecnologias à prática clínica e à saúde pública.

MÉTODO

Trata-se de uma revisão narrativa da literatura sobre as aplicações da inteligência artificial em doenças infecciosas, com ênfase no diagnóstico, na predição de desfechos e na vigilância epidemiológica. A busca bibliográfica foi realizada em setembro de 2026, na base PubMed/MEDLINE, utilizando combinações de termos relacionados a *Artificial Intelligence*, *Machine Learning*, *Deep Learning*, *Natural Language Processing*, *Communicable Diseases*, *Diagnosis*, *Prognosis* e *Epidemiological Surveillance*.

Foram priorizadas publicações recentes, principalmente entre 2020 e 2026, incluindo artigos de revisão e estudos originais relacionados aos eixos temáticos definidos para o capítulo. Foram considerados estudos sobre diagnóstico clínico e laboratorial, resistência antimicrobiana e apoio à decisão terapêutica, predição de desfechos clínicos e vigilância epidemiológica, além de trabalhos que abordassem qualidade e representatividade dos dados, validação dos modelos, interpretabilidade, privacidade e supervisão humana. Foram excluídas publicações que não apresentavam relação direta com as aplicações da IA em doenças infecciosas ou com os eixos temáticos propostos**.**

Os estudos selecionados foram analisados de forma narrativa e organizados de acordo com os eixos temáticos propostos, buscando integrar as evidências disponíveis às suas possíveis aplicações na prática clínica e na saúde pública.

RESULTADOS E DISCUSSÃO

Fundamentos da inteligência artificial aplicada à infectologia

A IA pode ser definida em linhas gerais, como a capacidade de sistemas computacionais realizarem tarefas associadas a processos cognitivos humanos, como reconhecimento de padrões, aprendizado e tomada de decisão. Entre as suas principais vertentes encontra-se o *machine learning* (ML), componente da IA que permite aos sistemas aprender padrões a partir de dados, sem que todas as regras necessárias para determinada tarefa sejam explicitamente programadas.

O desenvolvimento recente desse campo também inclui métodos de *deep learning* (DL), associados ao uso de redes neurais artificiais com múltiplas camadas para o processamento de informações complexas, e técnicas de *natural language processing* (NLP), destinadas ao processamento e à análise de informações expressas em linguagem natural.

A aplicação dessas tecnologias na infectologia é favorecida pela diversidade de dados disponíveis nesse campo. Informações clínicas provenientes de prontuários e sinais vitais podem ser combinadas a resultados laboratoriais e microbiológicos, dados genômicos, imagens médicas e informações epidemiológicas e ambientais. Além disso, fontes textuais não estruturadas, como registros clínicos, notícias e outras fontes digitais, podem ser processadas com técnicas de NLP. A possibilidade de integrar diferentes modalidades de dados amplia o potencial da IA para identificar padrões relevantes tanto no nível individual quanto populacional.

A relação entre essas tecnologias e alguns exemplos de suas aplicações no campo das doenças infecciosas estão sintetizados na **Figura 44.1**. A IA constitui o conceito mais abrangente, no qual se inserem diferentes abordagens computacionais. O ML possibilita a identificação de padrões e a realização de predições a partir de dados, enquanto o DL, como uma de suas subáreas, utiliza redes neurais com múltiplas camadas para aprender representações complexas. O NLP, por sua vez, possibilita a análise de dados textuais e pode incorporar técnicas de ML e DL.

Conforme ilustrado na **Figura 44.1**, essas tecnologias apresentam aplicações que abrangem o diagnóstico de doenças infecciosas, a predição de desfechos clínicos e a vigilância epidemiológica, correspondendo aos três eixos centrais discutidos neste capítulo.

Inteligência artificial no diagnóstico de doenças infecciosas: diagnóstico clínico e apoio à decisão

O diagnóstico das doenças infecciosas constitui um processo complexo, frequentemente dependente da integração de manifestações clínicas, dados epidemiológicos, exames laboratoriais, achados de imagem e resultados microbiológicos. Nesse contexto, técnicas de IA, especialmente de ML, vêm sendo investigadas como ferramentas de apoio capazes de reconhecer padrões em conjuntos heterogêneos de informações e estimar a probabilidade de determinados diagnósticos. Os sistemas de suporte à decisão clínica baseados em ML podem utilizar características individuais do paciente para fornecer estimativas ou recomendações que auxiliem o profissional durante o processo decisório, sem substituir a interpretação clínica especializada. Na revisão de Peiffer-Smadja *et al.* (2020), foram identificados 60 sistemas de suporte à decisão baseados em ML aplicados às doenças infecciosas, dos quais 20 (33%) tinham como finalidade o diagnóstico de infecções.

Dados clínicos foram utilizados por 87% dos sistemas avaliados e informações laboratoriais por 63%, demonstrando a importância da

integração dessas variáveis na construção dos modelos.

Uma aplicação relevante dessa abordagem ocorre diante de síndromes clínicas pouco específicas, nas quais diferentes agentes infecciosos podem produzir manifestações semelhantes. Ming *et al.* (2022) avaliaram o uso de ML supervisionado para auxiliar o diagnóstico de dengue em pacientes que apresentavam doença febril aguda. O modelo XGBoost integrou variáveis facilmente disponíveis na avaliação inicial – idade, sexo, hematócrito e contagens de plaquetas, leucócitos e linfócitos – para diferenciar dengue de outras doenças febris. Entre 8.100 pacientes avaliados, 2.240 apresentaram diagnóstico de dengue, e o modelo alcançou área sob a curva característica de operação do receptor (AUROC, do inglês *area under the receiver operating characteristic curve*) de 0,86, com desempenho semelhante no conjunto de teste independente do desenvolvimento do modelo. Esses resultados ilustram a possibilidade de utilização da IA como ferramenta complementar em cenários nos quais os achados clínicos iniciais são inespecíficos e o acesso imediato a métodos diagnósticos específicos pode ser limitado.

Figura 44.1 Principais tecnologias de inteligência artificial e suas aplicações na Infectologia

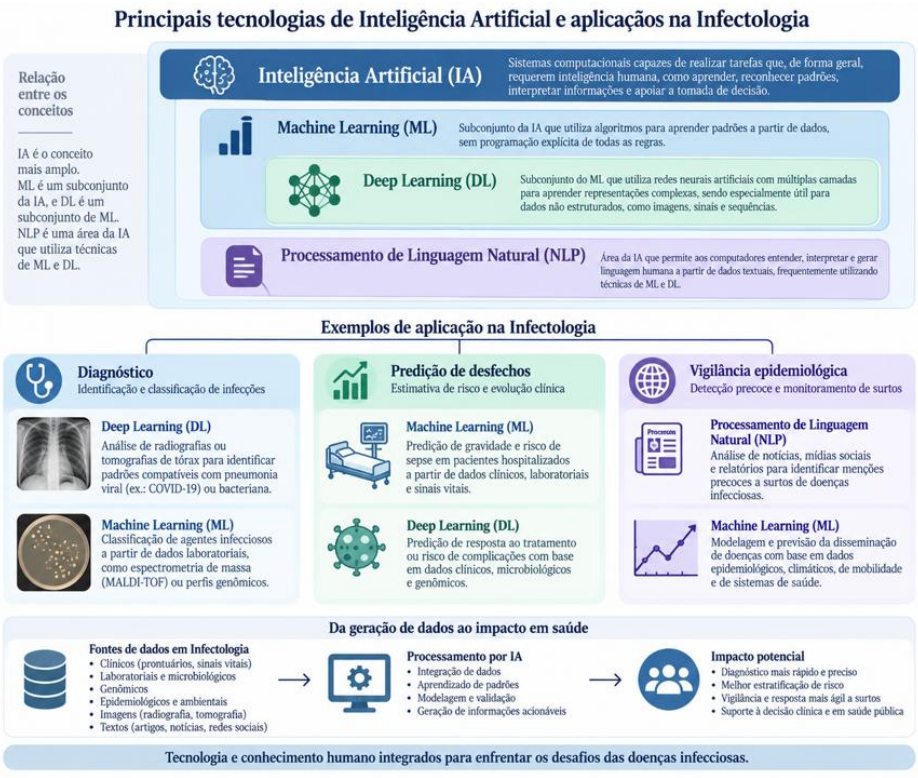

Nota: Representação esquemática da relação entre Inteligência Artificial (IA), *Machine Learning* (ML), *Deep Learning* (DL) e *Natural Language Processing* (NLP), com exemplos de suas aplicações no diagnóstico de doenças infecciosas, na predição de desfechos clínicos e na vigilância epidemiológica.

Entretanto, esse mesmo estudo evidencia uma característica fundamental dos modelos aplicados às doenças infecciosas: seu desempenho pode ser influenciado pelo contexto epidemiológico. A capacidade discriminatória do modelo para dengue variou ao longo do tempo em função da sazonalidade e de alterações na prevalência da doença. A incorporação de um limiar dinâmico, atualizado a partir dos casos

mais recentes, tornou o desempenho mais consistente ao longo do ano (MING *et al.* 2022). Nesse estudo específico, a variação sazonal do desempenho do modelo sugere que informações epidemiológicas podem constituir componentes relevantes para interpretação e atualização de modelos de IA. Entretanto, esse achado ainda necessita de confirmação em outras doenças e contextos antes de ser generalizado. Essa característica também ilustra por que um algoritmo desenvolvido em determinada população ou período não deve ser automaticamente aplicado a outros contextos sem validação adequada.

Além dos dados clínicos laboratoriais convencionais, técnicas de DL permitem explorar informações presentes em imagens médicas. Milad *et al.* (2024) investigaram modelos automatizados de DL para detecção de toxoplasmose ocular a partir de imagens de fundo de olho. Utilizando 304 imagens rotuladas, o modelo destinado a diferenciar toxoplasmose ocular de imagens normais apresentou sensibilidade de 100%, especificidade de 83% e acurácia de 93,5%. Em um conjunto diversificado de validação externa, todas as 15 imagens normais e as 15 imagens com toxoplasmose ocular foram corretamente classificadas. Os autores também desenvolveram um modelo capaz de localizar visualmente as lesões nas imagens (MILAD *et al.* 2024). Embora esses resultados sejam promissores, o número limitado de imagens utilizadas para o desenvolvimento e validação reforça a necessidade de estudos adicionais antes da extrapolação do desempenho para populações e cenários clínicos distintos.

Outra perspectiva consiste na integração da IA a dados moleculares e biomarcadores do hospedeiro. Na tuberculose pediátrica, condição em que o diagnóstico microbiológico apresenta dificuldades particulares devido à doença frequentemente paucibacilar e à dificuldade de obtenção de escarro em crianças, Fossati *et al.* (2025) combinaram proteômica plasmática de alta resolução e ML em uma coorte de 511 crianças provenientes de quatro países. A análise resultou em quatro biossinais compostos por três a seis proteínas, com valores de área sob a curva (AUC, do inglês *area under the curve*) entre 0,87 e 0,88, destinados à diferenciação da tuberculose de outras doenças respiratórias (FOSSATI *et al.* 2025). A inclusão de participantes da Gâmbia, Peru, África do Sul e Uganda é particularmente relevante, uma vez que estudos realizados em uma única região podem identificar biomarcadores relacionados a características ambientais ou comorbidades locais e apresentar menor capacidade de generalização para outras populações (FOSSATI *et al.* 2025).

O potencial diagnóstico da IA também vem sendo investigado a partir de assinaturas da resposta imunológica do hospedeiro. Zaslavsky *et al.* (2025) desenvolveram o *Machine Learning for Immunological Diagnosis* (Mal-ID), modelo que integra sequências de receptores de células B (*B- cell receptor,* BCR) e receptores de células T (*T-cell receptor,* TCR) para classificação de diferentes estados imunológicos. A análise de dados de 593 indivíduos demonstrou AUROC multiclasse de 0,986 e acurácia global de 85,3% na classificação, sendo que a combinação das informações de BCR e TCR apresentou desempenho superior ao uso isolado de cada tipo de receptor. Esses resultados demonstram o potencial do ML para identificar padrões complexos da resposta imune associados a diferentes condições; entretanto, os próprios autores ressaltam a necessidade de estudos adicionais para estabelecer parâmetros de sensibilidade e especificidade adequados a cada contexto clínico antes de sua aplicação diagnóstica.

Apesar dos resultados promissores, um bom desempenho algorítmico não equivale necessariamente a benefício clínico. Esse aspecto é particularmente importante na interpretação da literatura sobre IA aplicada à infectologia. Na revisão de Peiffer-Smadja *et al.* (2020), 95% dos sistemas identificados haviam sido avaliados por métricas de desempenho, como sensibilidade e especificidade, enquanto apenas 5% tinham sido avaliados em utilização clínica e nenhum apresentava avaliação de adoção na prática rotineira. Os autores destacam ainda a necessidade de validação prospectiva em populações e locais diferentes daqueles utilizados no desenvolvimento dos modelos, seguida por estudos de usabilidade e ensaios capazes de avaliar desfechos clínicos, melhoria de processos e custo-efetividade (PEIFFER-SMADJA *et al.* 2020).

Dessa forma, a principal contribuição da IA para o diagnóstico clínico das doenças infecciosas não deve ser compreendida como a substituição do raciocínio médico, mas como a possibilidade de ampliar a capacidade de integrar informações e reconhecer padrões relevantes para apoiar a decisão clínica. O valor de uma predição depende não apenas de sua acurácia estatística, mas também da qualidade e representatividade dos dados utilizados, da validação em diferentes populações e da adequação ao contexto epidemiológico no qual o paciente está inserido. Assim, a interpretação crítica pelo profissional permanece indispensável para confrontar a recomendação algorítmica com a história clínica, o exame físico, os exames complementares e o cenário epidemiológico individual.

Identificação de agentes infecciosos e microbiologia laboratorial

A aplicação da inteligência artificial à microbiologia laboratorial vem sendo investigada como estratégia para ampliar as possibilidades de análise e interpretação dos dados utilizados na identificação e caracterização de agentes infecciosos. Modelos de ML podem reconhecer padrões em informações fenotípicas, moleculares e genômicas, contribuindo para a classificação de microrganismos e para a identificação de características relevantes dos patógenos. Entre as aplicações descritas estão análises envolvendo diferentes agentes bacterianos, como *Streptococcus pneumoniae*, *Escherichia coli*, *Streptococcus pyogenes* e *Mycobacterium* tuberculosis (DE LA LASTRA *et al.* 2024). Entretanto, nos estudos aqui discutidos, ainda são limitadas as evidências comparativas que permitam determinar o desempenho dessas aplicações em relação aos métodos microbiológicos de referência em condições laboratoriais de rotina.

Nesse contexto, essas ferramentas têm sido propostas como complementares aos métodos microbiológicos convencionais, especialmente diante do crescente volume e complexidade dos dados produzidos pelos laboratórios. Seu principal benefício reside na capacidade de processar grandes conjuntos de dados e identificar padrões microbiológicos complexos, auxiliando na caracterização dos agentes infecciosos. Sua aplicação, contudo, depende da qualidade e da representatividade dos dados utilizados no desenvolvimento dos modelos, bem como de sua validação em diferentes populações e contextos. Assim, embora a IA amplie a capacidade de análise de dados microbiológicos complexos, as evidências disponíveis ainda não permitem estabelecer sua superioridade em relação aos métodos de referência nem justificar sua utilização isolada na identificação de agentes infecciosos. Sua incorporação ao laboratório deve, portanto, ocorrer de forma complementar aos métodos microbiológicos estabelecidos e à interpretação dos profissionais responsáveis pelo diagnóstico.

Resistência antimicrobiana e apoio à decisão terapêutica

A resistência antimicrobiana representa um importante desafio para o tratamento das doenças infecciosas, e ferramentas de IA vêm sendo investigadas para auxiliar na identificação de padrões de resistência e na escolha da terapia antimicrobiana. Modelos de ML podem integrar dados clínicos, microbiológicos e genômicos para estimar a suscetibilidade dos microrganismos e a probabilidade de resistência a determinados antimicrobianos, contribuindo para decisões terapêuticas mais direcionadas (DE LA LASTRA *et al.* 2024).

Essas ferramentas também apresentam aplicações no apoio à antibioticoterapia empírica e aos programas de *antimicrobial stewardship*. Ao considerar características individuais do paciente e padrões locais de resistência, modelos preditivos podem auxiliar na seleção do tratamento e na redução do uso desnecessário ou inadequado de antimicrobianos. Entretanto, Micek *et al.* (2025) destacam que muitos desses modelos foram desenvolvidos a partir de pacientes com culturas positivas e podem apresentar melhor desempenho após a identificação do microrganismo, limitando sua utilidade justamente no momento inicial da terapia empírica.

Além disso, a variabilidade dos padrões de resistência entre diferentes instituições e populações pode comprometer a generalização dos modelos. Dessa forma, sua aplicação clínica depende de validação externa, atualização de acordo com a epidemiologia local e integração com os resultados microbiológicos e a avaliação profissional. Assim, a IA apresenta potencial para apoiar o uso mais racional dos antimicrobianos, mas suas recomendações devem permanecer subordinadas à interpretação clínica e ao contexto epidemiológico no qual serão aplicadas (MICEK *et al.* 2025).

Inteligência artificial na predição de desfechos

Além das aplicações diagnósticas, a IA tem sido investigada para a predição de desfechos em pacientes com doenças infecciosas. Modelos de ML e DL podem integrar diferentes variáveis clínicas e laboratoriais para identificar padrões associados à evolução dos pacientes, permitindo estimar riscos como deterioração clínica, complicações e mortalidade. Essa abordagem pode contribuir para a estratificação de risco e para a identificação precoce de pacientes que necessitam de maior atenção.

Um exemplo dessa aplicação foi apresentado por Yong e Zhenzhou (2024), que desenvolveram um modelo de DL para predizer mortalidade hospitalar em pacientes com sepse. O estudo utilizou registros clínicos de 9.432 pacientes, incorporando informações como sinais vitais e parâmetros laboratoriais para estimar individualmente o risco de morte. O modelo proposto apresentou AUROC de 0,857, superior aos modelos de comparação, cujos valores variaram de 0,808 a 0,829, além de acurácia de 0,803. Esses resultados demonstram a capacidade de modelos de IA de integrar diferentes variáveis clínicas para auxiliar na identificação de pacientes com maior risco de evolução desfavorável (YONG; ZHENZHOU, 2024).

Entretanto, a capacidade preditiva de um modelo não garante sua aplicabilidade em diferentes cenários clínicos. Diferenças entre populações, qualidade dos registros e características das instituições podem interferir no desempenho dessas ferramentas. Dessa forma, modelos destinados à predição de desfechos devem ser adequadamente validados antes de sua incorporação à prática clínica e utilizados como suporte à estratificação de risco, mantendo a interpretação dos resultados integrada à avaliação do profissional de saúde.

Inteligência artificial na vigilância epidemiológica

Na vigilância epidemiológica, a IA pode ser aplicada à integração e análise de dados provenientes de diferentes fontes para identificar padrões relacionados à ocorrência e disseminação das doenças infecciosas. Informações epidemiológicas podem ser combinadas a variáveis ambientais, climáticas, populacionais e de mobilidade, permitindo a identificação de áreas de risco, a detecção precoce de surtos e a previsão de tendências. Dessa forma, as aplicações da IA ultrapassam o cuidado individual e podem contribuir para o planejamento e a resposta em saúde pública (ZENG *et al.* 2021).

Aplicações quantitativas dessas ferramentas já foram descritas em sistemas de vigilância de doenças transmitidas por vetores. Zeng *et al.* (2021) relatam o emprego de diferentes modelos de ML na estimativa de áreas e períodos de maior risco. Em Taiwan, um modelo de DL baseado em *transfer learning*, treinado com imagens de temperatura da superfície do mar e dados de precipitação, foi utilizado para identificar *hotspots* espaço-temporais de dengue e alcançou acurácia de 100% em validação cruzada de oito partes. Em Singapura, um modelo de *Random Forest* integrou dados epidemiológicos, populacionais, entomológicos e ambientais para estimar o risco de transmissão da dengue, com mais de 80% dos níveis de risco observados situados dentro do intervalo preditivo de 80%. Esses resultados exemplificam a capacidade da IA de integrar diferentes determinantes epidemiológicos e produzir estimativas quantitativas aplicáveis à vigilância (ZENG *et al.* 2021).

Além da análise de dados epidemiológicos convencionais, fatores ambientais assumem importância crescente na vigilância de doenças infecciosas emergentes. Liao *et al.* (2024) destacam que alterações de temperatura, precipitação e umidade associadas às mudanças climáticas podem modificar a distribuição de patógenos, reservatórios e vetores, favorecendo alterações nos padrões de transmissão. Nesse contexto, os autores ressaltam a necessidade de plataformas integradas de vigilância e modelagem que utilizem IA para acompanhar e antecipar possíveis mudanças no comportamento das doenças infecciosas (LIAO *et al.* 2024).

Entretanto, a aplicabilidade desses modelos depende da qualidade e representatividade dos dados, da disponibilidade de informações atualizadas e de validação em diferentes contextos epidemiológicos. Além disso, resultados obtidos em determinada região ou período não devem ser automaticamente generalizados para outras populações. Assim, a IA deve ser compreendida como ferramenta complementar à vigilância epidemiológica, cabendo aos profissionais interpretar suas estimativas em conjunto com o cenário epidemiológico e utilizá-las como subsídio para medidas de prevenção, controle e planejamento em saúde pública.

Limitações e desafios para a incorporação da inteligência artificial à infectologia

Apesar das possibilidades apresentadas, a incorporação da inteligência artificial à Infectologia ainda enfrenta limitações importantes. O desempenho dos modelos depende diretamente da qualidade e da representatividade dos dados utilizados em seu desenvolvimento, podendo ser comprometido por informações incompletas, vieses ou diferenças entre as populações de treinamento e aquelas nas quais a ferramenta será aplicada. Além disso, modelos de elevada complexidade podem apresentar baixa interpretabilidade, dificultando a compreensão dos fatores que influenciam determinada predição e, consequentemente, sua avaliação crítica pelo profissional de saúde.

Outro aspecto relevante envolve a privacidade e a segurança das informações utilizadas pelos sistemas de IA. Dados clínicos, laboratoriais e genômicos são particularmente sensíveis, tornando indispensáveis mecanismos adequados de proteção, governança e confidencialidade. Dessa forma, a incorporação dessas tecnologias deve ser acompanhada de validação externa, transparência e supervisão humana. A IA deve atuar como ferramenta complementar, cabendo ao profissional avaliar criticamente suas recomendações e confrontá-las com o contexto clínico e epidemiológico antes de incorporá-las à tomada de decisão.

Perspectivas futuras

O desenvolvimento de modelos capazes de integrar dados clínicos, microbiológicos, genômicos, de imagem e epidemiológicos tende a ampliar as possibilidades de aplicação da IA na Infectologia. A combinação dessas diferentes fontes poderá favorecer ferramentas mais individualizadas para diagnóstico e predição de desfechos, ao mesmo tempo em que modelos populacionais poderão contribuir para a identificação precoce de alterações no comportamento das doenças infecciosas e para o planejamento de estratégias de vigilância.

Entretanto, o avanço tecnológico deverá ser acompanhado pela adoção de modelos mais transparentes, validados em diferentes populações e integrados aos sistemas de saúde. Nesse cenário, a perspectiva mais consistente não é a substituição da atuação profissional, mas o estabelecimento de uma interação entre capacidade computacional e conhecimento especializado, na qual a IA amplie a capacidade de análise de grandes volumes de informações e o profissional permaneça responsável pela interpretação crítica e pela contextualização de seus resultados.

CONCLUSÃO

A inteligência artificial apresenta aplicações promissoras em diferentes dimensões da Infectologia, desde o diagnóstico e a caracterização de agentes infecciosos até a predição de desfechos, o apoio à decisão terapêutica e a vigilância epidemiológica. Sua capacidade de integrar grandes volumes de dados e identificar padrões complexos pode contribuir para decisões mais oportunas no cuidado individual e para ampliar a capacidade de resposta dos sistemas de saúde às doenças infecciosas.

Entretanto, desempenho algorítmico não deve ser interpretado isoladamente como benefício clínico ou epidemiológico. A incorporação segura dessas ferramentas depende da qualidade e representatividade dos dados, validação em diferentes populações, proteção da confidencialidade, transparência dos modelos e integração responsável à prática profissional. Assim, a IA deve ser compreendida como instrumento de apoio à inteligência e ao julgamento humanos, permanecendo indispensável a avaliação crítica dos profissionais para transformar resultados computacionais em decisões adequadas ao paciente e à população. Estudos futuros devem priorizar a validação prospectiva e externa desses modelos em diferentes populações e cenários assistenciais, bem como avaliar seu impacto sobre desfechos clínicos, epidemiológicos e sua incorporação à prática.

REFERÊNCIAS BIBLIOGRÁFICAS

DE LA LASTRA, J.M.P. *et al.* From data to decisions: leveraging artificial intelligence and machine learning in combating antimicrobial resistance: a comprehensive review. Journal of Medical Systems, v. 48, p. 71, 2024. doi: 10.1007/s10916-024-02089-5.

FOSSATI, A. *et al.* Plasma proteomics for biomarker discovery in childhood tuberculosis. Nature Communications, v. 16, p. 6657, 2025. doi: 10.1038/s41467-025-61515-5.

GIACOBBE, D.R. *et al.* Explainable artificial intelligence and machine learning: novel approaches to face infectious diseases challenges. Annals of Medicine, v. 55, 2023. doi: 10.1080/07853890.2023.2286336.

LIAO, H. *et al.* Climate change, its impact on emerging infectious diseases and new technologies to combat the challenge. Emerging Microbes & Infections, v. 13, p. 2356143, 2024. doi: 10.1080/22221751.2024.2356143.

MICEK, S.T. *et al.* Optimal antibiotic use in the intensive care unit. Critical Care, v. 29, p. 434, 2025. doi: 10.1186/s13054-025-05653-8.

MILAD, D. *et al.* Automated machine learning versus expert-designed models in ocular toxoplasmosis: detection and lesion localization using fundus images. Ocular Immunology and Inflammation, v. 32, p. 2061, 2024. doi: 10.1080/09273948.2024.2319281.

MING, D.K. *et al.* The diagnosis of dengue in patients presenting with acute febrile illness using supervised machine learning and impact of seasonality. Frontiers in Digital Health, v. 4, 2022. doi: 10.3389/fdgth.2022.849641.

PEIFFER-SMADJA, N. *et al.* Machine learning for clinical decision support in infectious diseases: a narrative review of current applications. Clinical Microbiology and Infection, v. 26, p. 584, 2020. doi: 10.1016/j.cmi.2019.09.009.

VILLANUEVA-MIRANDA, I. *et al.* Artificial intelligence in early warning systems for infectious disease surveillance: a systematic review. Frontiers in Public Health, v. 13, 2025. doi: 10.3389/fpubh.2025.1609615.

YONG, L.; ZHENZHOU, L. Deep learning-based prediction of in-hospital mortality for sepsis. Scientific Reports, v. 14, p. 372, 2024. doi: 10.1038/s41598-023-49890-9.

ZASLAVSKY, M.E. *et al.* Disease diagnostics using machine learning of B cell and T cell receptor sequences. Science, v. 387, 2025. doi: 10.1126/science.adp2407.

ZENG, D. *et al.* Artificial intelligence–enabled public health surveillance: from local detection to global epidemic monitoring and control. In: XING, L. *et al.*, editors. Artificial intelligence in medicine: technical basis and clinical applications. London: Academic Press, 2021.