

## Inteligência Artificial e as pesquisas científicas e tecnológicas

### *Artificial Intelligence and technological and scientific research*

**Maria Elisabete SALVADOR<sup>1</sup>**

Lattes: 2940944860729134;  
ORCID: 0000-0001-8692-5968

**Dulce Aparecida BARBOSA<sup>2</sup>**

Lattes: 0068497734511867  
ORCID:0000-0002-9912-4446

<sup>1</sup> Universidade Federal de São Paulo – Unifesp, Escola Paulista de Medicina – EPM, Departamento de Informática. São Paulo, SP, Brasil.

<sup>2</sup> Universidade Federal de São Paulo – Unifesp, Escola Paulista de Enfermagem – EPE. São Paulo, SP, Brasil.



AUTOR CORRESPONDENTE  
Dulce Aparecida Barbosa  
E-mail: dulce.barbosa@unifesp.br

**Financiamento:** não se aplica.

**Conflito de interesses:** Os/As autores/autoras declaram não haver conflito de interesses.

#### Como citar este artigo (Vancouver):

Salvador ME, Barbosa DA. Inteligência Artificial e as pesquisas científicas e tecnológicas. Ext Rev. 2025;15:e003. <https://doi.org/10.59666/extensaoemrevista.2025.v15.4655>

A Inteligência Artificial (IA) transformou sobremaneira a pesquisa em saúde, oferecendo benefícios sem precedentes.<sup>1</sup> Compreender os diferentes tipos de aprendizado de máquina empregados na pesquisa científica e tecnológica, bem como suas especificidades e riscos, é essencial para o uso responsável e eficaz. O modelo **supervisionado** utiliza dados previamente validados por especialistas e tem sido amplamente aplicado em diagnósticos automatizados e predição de desfechos clínicos, por exemplo. O **não supervisionado** é utilizado para detectar padrões e estruturas em dados brutos, sendo útil para explorar relações desconhecidas ou gerar hipóteses inovadoras, enquanto o **aprendizado de máquina** por reforço simula processos de decisão interativos, com potencial em áreas como otimização de tratamentos personalizados.

Enquanto grande parte das aplicações da IA na pesquisa científica está voltada à análise de dados estruturados, como estudos clínicos, epidemiológicos e laboratoriais, outro campo relevante envolve os chamados modelos de linguagem de larga escala (*Large Language Models* – LLM), como o ChatGPT ou o *Claude* (da *Anthropic*). Tais modelos operam com bilhões de parâmetros treinados em extensos conjuntos de dados textuais e são exemplos de aprendizado de máquina **auto-supervisionado**, em que o próprio texto serve de entrada e saída durante o treinamento. Isto é, o modelo aprende a prever a próxima palavra ou sequência de palavras com base no contexto anterior, sem necessidade de validação humana (classificações atribuídas manualmente por especialistas para indicar a resposta correta, como ocorre no aprendizado supervisionado). Embora tal abordagem permita a construção de sistemas altamente versáteis, ela também gera desafios, como a produção de informações equivocadas ou irreais, fenômeno conhecido como alucinação. O uso desses

sistemas requer análise crítica, verificação humana e compreensão dos seus limites. Para usuários mais atentos, esse tipo de limitação pode se transformar em oportunidade: exige verificação minuciosa de fontes e informações, estimulando a busca ativa por conhecimento e evidências, desenvolvendo habilidades críticas baseadas na confiabilidade e no rigor científico.

Os modelos supervisionados utilizam dados previamente validados, e sua precisão depende da qualidade e diversidade dessas informações. Os modelos não supervisionados, por sua natureza exploratória, revelam padrões que exigem validação por especialistas para garantir robustez científica. A escolha do tipo de IA deve considerar o objetivo da pesquisa, a qualidade dos dados e o grau de validação exigido, reforçando a importância de bases auditadas e validadas por especialistas para que os modelos se mantenham confiáveis e aplicáveis à prática clínica.

Entre muitas aplicabilidades na pesquisa científica, destacam-se as ferramentas de IA que auxiliam a elaboração de protocolos, revisão de literatura, identificação de lacunas no conhecimento científico e até mesmo no desenho de experimentos, como a verificação de novas hipóteses. Como exemplo, os algoritmos podem analisar grandes bancos de dados genômicos, de imagens médicas ou rápidas correlações entre tratamentos, diagnósticos, custos e prognósticos provenientes de prontuários eletrônicos.<sup>1</sup> Essa capacidade é estratégica para acelerar, por exemplo, a descoberta de biomarcadores, a identificação de alvos terapêuticos e a análise de padrões epidemiológicos. Além disso, amplia as oportunidades para jovens pesquisadores, especialmente aqueles de regiões com menor infraestrutura, que podem acessar ambientes computacionais em nuvem ou modelos pré-treinados, inserindo-se de forma produtiva na pesquisa científica desde o início de suas carreiras, contribuindo para a diversidade nos espaços de produção do conhecimento.

Outra vantagem é a análise de grandes volumes de dados (*big data*) pela IA, com processamento em larga escala e velocidade, o que permite superar antigos desafios, desde identificar interações complexas em ensaios com milhares de indivíduos até monitorar tendências em tempo real. Em contextos como pandemia, genética e saúde populacional, essa capacidade permite respostas rápidas e precisas.

Tais avanços, entretanto, não estão isentos de desafios e riscos significativos e que precisam ser

reconhecidos, como, por exemplo, a falta de sustentabilidade energética. O processamento de modelos complexos, como os LLM ou redes de aprendizagem profunda, demandam enorme consumo de energia, com elevada emissão de carbono, um problema especialmente preocupante em países emergentes, onde os custos podem inviabilizar sua adoção em larga escala. Outro ponto crítico é o aspecto cognitivo e formativo dos pesquisadores, como acomodação mental, particularmente entre jovens cientistas, ao depender excessivamente da IA. Isto é, abreviar o gradativo processo de aprendizado ao pular etapas fundamentais, como a leitura crítica e aprofundada, a reflexão sobre evidências e o confronto de diferentes perspectivas, pode comprometer a formação de competências analíticas sólidas, reduzindo a capacidade do pesquisador de avaliar informações com rigor e de construir interpretações fundamentadas. Apressar o processo de amadurecimento intelectual e empobrecer a capacidade de pensamento crítico são consequências prováveis.

Para pesquisadores com pouca experiência e repertório acadêmico, a tendência de modelos generativos como os LLM, pelo fato de produzirem descrições superficiais ou imprecisas, representam um desafio adicional. Sem conhecimento sólido para identificar inconsistências, há o risco de absorver e reproduzir informações equivocadas, comprometendo a qualidade da produção científica.

Nessa perspectiva, Aaron French<sup>2</sup> questiona: “o ChatGPT está nos deixando burros?” O autor conclui que ao delegarmos tarefas cognitivas à IA, corremos o risco de enfraquecer nossa habilidade de pensar criticamente, resolver problemas complexos e se engajar profundamente com o conhecimento. O autor destaca o efeito Dunning-Kruger, onde um indivíduo tende a julgar-se capaz por não reconhecer suas limitações. Isso pode levar a uma falsa sensação de compreensão e, sem a devida reflexão, resulta em autoconfiança artificial, enquanto empobrece sua cognição. Por outro lado, Samantha Green,<sup>3</sup> no *Scholarly Kitchen*, afirma que o medo diante da IA pode impulsionar aprendizado e inovação, e que o ceticismo informado é uma oportunidade de liderar com ética e estratégia para moldar o futuro tecnológico.

De fato, o uso crítico e reflexivo da IA, sobretudo no âmbito das pesquisas científicas, pode potencializar a inteligência humana ao gerar

ideias, estimular curiosidade e aprofundar discussões, porém trata-se do **ponto de partida**, não o fim de um longo processo. A cultura de uso responsável e ético, com validação crítica dos resultados automatizados, exige argumentação sólida, livre de atalhos, evitando-se vieses algorítmicos, discriminação, ou acomodação intelectual.

O futuro da IA na pesquisa científica direciona para uma integração cada vez mais profunda entre ciência de dados, bioinformática e práticas clínicas.<sup>4</sup> Tendências emergentes incluem o uso de modelos multimodais capazes de correlacionar dados clínicos, genômicos e ambientais. O avanço da *Explainable AI* (IA Explicável), que busca aumentar a transparência e interpretabilidade dos algoritmos e o fortalecimento de *frameworks* éticos e regulatórios, para garantir segurança, privacidade e equidade no uso dessas tecnologias. À medida em que a IA se torna mais acessível e especializada, espera-se que não apenas acelere descobertas científicas, mas também personalize estratégias de prevenção e predição. Contudo, o sucesso dessa trajetória dependerá de investimentos em capacitação crítica dos pesquisadores, infraestrutura sustentável, e de uma governança global colaborativa, capaz de equilibrar inovação com responsabilidade social.

As inovações em IA também incluem o ajuste fino de modelos fundacionais com bases clínicas especializadas, promovendo assim: maior segurança e precisão nas respostas automatizadas, o uso de IA generativa para síntese rápida de evidências científicas, a integração com dispositivos vestíveis e sistemas de Internet das Coisas Médicas, possibilitando estudos com dados em tempo real, e a aplicação da IA na identificação e redução de desigualdades em saúde. Além disso, cresce o interesse por modelos híbridos, que combinam raciocínio simbólico e aprendizagem estatística, aproximando a IA do raciocínio clínico humano. Tais inovações reforçam que o futuro da IA na ciência será tanto técnico quanto ético, exigindo compromisso com qualidade, justiça e transparência.

Nas tendências emergentes, destaca-se a visão de Eric Topol, em palestra para o *National Institutes of Health*,<sup>5</sup> ao defender que a IA não atua apenas na análise de dados, mas abre caminho para resgatar a humanidade na medicina, liberando os profissionais de tarefas administrativas, reduzindo o *burnout* e

favorecendo a conexão clínica com os pacientes, transformando o cuidado em saúde. Segundo Topol,<sup>5</sup> o avanço da IA também desafia os paradigmas metodológicos tradicionais, exigindo abordagens capazes de integrar dados não estruturados e formas dinâmicas de coleta e análise, ao mesmo tempo em que redefine as formas de investigar, sistematizar e aplicar o conhecimento científico.<sup>5</sup>

Cada vez mais, algoritmos de aprendizado profundo são empregados para revelar correlações e padrões complexos em bancos de dados heterogêneos, possibilitando a formulação de hipóteses inovadoras a partir de evidências empíricas robustas. Além disso, ao ampliar o acesso às ferramentas analíticas de ponta, a IA contribui para a democratização da pesquisa translacional, permitindo que instituições com menor infraestrutura tecnológica participem de estudos colaborativos e multicêntricos. Nesse contexto, o papel da IA vai além da aceleração da análise, ao redefinir as formas de investigar, sistematizar e aplicar o conhecimento científico, desde que acompanhada de um compromisso ético com a qualidade, transparência e equidade na produção de saberes em saúde.<sup>5</sup>

Outro movimento relevante é a ênfase na transparência e rastreabilidade no desenvolvimento de modelos de IA, com registro detalhado de dados de treinamento, versões utilizadas e critérios de validação, práticas conhecidas como *model cards* e *transparency statements*, que fortalecem a reprodutibilidade científica.<sup>6</sup> Ademais, cresce o reconhecimento da necessidade de governança multissetorial, envolvendo desde especialistas técnicos, profissionais de saúde até pacientes, reguladores e formuladores de políticas, para garantir que as soluções em IA respondam às demandas reais, mantenham a confiança pública e preservem relevância ética e prática.<sup>6</sup>

Por fim, a IA tem um potencial extraordinário para acelerar e democratizar a produção de conhecimento, sendo a chave do sucesso a forma como tais ferramentas são utilizadas. Tratar respostas de IA como ponto de partida e não como ponto final exige disciplina intelectual, senso crítico e responsabilidade ética. Esse é o cerne para ampliar a inteligência humana, e não a substituir.

## Referências

1. National Health Service. Fit for the future: 10 year health plan for England [Internet]. London:



- UK Government; 2025. [citado 07 ago. 2025]. Disponível em: <https://www.gov.uk/government/publications/10-year-health-plan-for-england-fit-for-the-future>.
2. Ministério da Saúde (BR). Estratégia de saúde digital para o Brasil: 2020-2028 [Internet]. Brasília, DF: MS; 2020 [citado 07 ago. 2025]. Disponível em: [https://bvsms.saude.gov.br/bvs/publicacoes/estrategia\\_saude\\_digital\\_Brasil.pdf](https://bvsms.saude.gov.br/bvs/publicacoes/estrategia_saude_digital_Brasil.pdf).
3. Green S. Fear, learning, and luddites: opportunities to lead the AI revolution. The Scholarly Kitchen [Internet]. [place unknown]: SSP; 2025 Aug 05 [citado 07 ago 2025]. Disponível em: <https://scholarlykitchen.sspnet.org/2025/08/05/guest-post-fear-learning-and-luddites-opportunities-to-lead-the-ai-revolution/>.
4. French A. Is ChatGPT making us stupid?. The conversation [Internet]; 2025 July 24 [citado 07 ago. 2025]. Disponível em: <https://theconversation.com/is-chatgpt-making-us-stupid-255370>.
5. Bock E. [Eric] Topol discusses potential for AI to transform medicine. NIH Record [Internet]; 2024 [citado 07 ago. 2025]. Disponível em: <https://nihrecord.nih.gov/2024/11/22/topol-discusses-potential-ai-transform-medicine>.
6. Modise LM, Avanaki MA, Ameem S, Celi LA, Chen VXY, Cordes A, et al. Introducing the Team Card: a protocol for reflexivity and transparency in medical AI. PLOS Digit Health. 2025;4(3):e00000495. <https://doi.org/10.1371/journal.pdig.0000495>