

## Do laboratório ao *data center*: reconfigurando a atividade científica por meio da inteligência artificial\*

Maiko Rafael Spiess<sup>1</sup>

Marcos Antonio Mattedi<sup>2</sup>

### RESUMO

O objetivo deste estudo foi examinar o papel da inteligência artificial (IA) na reconfiguração da atividade da pesquisa científica e tecnológica. A IA tem desempenhado um papel crescente na produção de textos científicos, com impactos sobre as noções de autoria e crédito. Além disso, traz implicações epistemológicas e sociológicas para a produção de dados e testes de hipóteses. Este estudo busca oferecer uma contextualização geral da IA e suas diferentes tecnologias relacionadas, a partir do referencial do campo dos estudos sociais da ciência e da tecnologia. A análise baseia-se em revisão bibliográfica, análise de notícias e em material técnico e de divulgação sobre IA. Argumentamos que o impacto da IA sobre a produção de dados e textos acadêmicos significa mudanças importantes no fazer científico. Espera-se que este trabalho incentive novas linhas de pesquisa e debates sobre a intersecção da IA com a ciência, tecnologia, inovação e sociedade.

**Termos para indexação:** estudos sociais de ciência e tecnologia, inovação, inteligência artificial, pesquisa científica e tecnológica, produção de textos acadêmicos.

### From the laboratory to the data center: reconfiguring scientific activity through artificial intelligence

### ABSTRACT

The objective of this study was to examine the role of artificial intelligence (AI) in the reconfiguration of scientific and technological research activity. AI has played an increasing role in the production of scientific texts, with impacts on the notions of authorship and credit. In addition, it brings epistemological and sociological implications for data production and hypothesis testing. This study seeks to provide a general contextualization of AI and its related, different technologies, based on the framework of the field of social studies of science and technology. This research is based on a comprehensive literature review and the analysis of news reports, as well as technical and promotional materials on AI. We argue that the impact of AI on the production of data and academic texts means important changes in the scientific practice. This work is expected to stimulate new lines of research and debates over the intersection of AI and science, technology, innovation, and society.

**Index terms:** artificial intelligence, scientific and technological research, production of academic texts, social studies of science and technology, innovation.

### Ideias centrais

- Papel crescente da inteligência artificial (IA) na pesquisa científica, alterando a produção de textos acadêmicos e a autoria.
- A IA impacta tanto a produção de dados quanto o teste de hipóteses, com implicações epistemológicas e sociológicas profundas.
- Contextualização da IA com foco na influência sobre as práticas científicas.
- Tecnologias de IA generativa, como o ChatGPT, podem transformar a forma como textos científicos são produzidos.
- A IA pode gerar mudanças significativas nas hierarquias e dinâmicas da comunidade científica, exigindo novos debates sobre o impacto da automação no trabalho acadêmico.

Recebido em  
25/06/2023

Aprovado em  
12/09/2024

Publicado em  
11/12/2024



This article is published in Open Access under the Creative Commons Attribution licence, which allows use, distribution, and reproduction in any medium, without restrictions, as long as the original work is correctly cited.

\* Este artigo faz parte da Chamada “CT&I no mundo em transformação: que atores, caminhos e motores se revelam?”

<sup>1</sup> Sociólogo, doutor em Política Científica e Tecnológica, professor do Departamento de Ciências Sociais e Filosofia da Universidade Regional de Blumenau. Blumenau, SC. E-mail: mspiess@furb.br

<sup>2</sup> Sociólogo, doutor em Ciências Sociais, professor do Departamento de Ciências Sociais e Filosofia da Universidade Regional de Blumenau. Blumenau, SC. E-mail: mam@furb.br

## INTRODUÇÃO

Sociedade, ciência e tecnologia estão sempre em estado de mudança, em um processo de influência recíproca. Recentemente, um tipo de inovação científica e tecnológica ganhou destaque, supostamente com grande potencial de mudar a sociedade, a forma de fazer pesquisa científica e a inserção da tecnologia em nossas vidas. Nos últimos meses, a inteligência artificial (IA) ganhou as manchetes ao redor do mundo, tornou-se assunto de conversas pessoais e, sobretudo, anunciou mudanças no mundo do trabalho que ainda não são completamente conhecidas ou compreendidas. A face mais visível desse conjunto de inovações é o ChatGPT, um dos produtos tecnológicos mais bem sucedidos da era da *internet* (Hu, 2023). Da produção de textos, passando pela busca de conteúdo *online*, soluções educacionais e chegando na programação de computadores, o ChatGPT parece oferecer perspectivas futuras simultaneamente otimistas e catastróficas, sem que essas conjecturas sejam criticamente analisadas.

Ocorre que a “revolução” da IA não se limita apenas ao ChatGPT. Na verdade, abrange um conjunto extremamente dinâmico e rapidamente crescente de inovações técnicas (algoritmos, serviços e produtos) para a produção sintética de imagens, vídeo, conversão de textos para áudio, design gráfico e até música. Na pesquisa científica básica produzida pela iniciativa privada, vale também destacar o avanço dos carros autônomos (Waymo, Tesla), os desenvolvimentos de tecnologias de aprendizagem profunda da empresa DeepMind (AlphaZero, AlphaGo e AlphaFold) e as inovações robóticas da companhia Boston Dynamics. Ou seja, para além de uma cobertura muitas vezes sensacionalista da mídia, de fato há indícios de uma série de inovações convergentes, decorrentes ou associadas ao campo da IA.

Compreensivelmente, essas inovações passam a ser analisadas criticamente. Por exemplo, estudando-se a dinâmica global sob uma perspectiva macroeconômica e geopolítica, é possível observar uma intensa competição tecnológica, particularmente entre os Estados Unidos e a China, na busca pela supremacia em tecnologias de IA. Segundo Lee (2018), essas duas nações, consideradas “superpotências de IA”, dominam o desenvolvimento e a aplicação dessas tecnologias avançadas. Crawford (2021) expande esta discussão, destacando como a infraestrutura e a operacionalização das tecnologias de IA estão redefinindo as estruturas de poder político e econômico. A autora caracteriza a indústria de IA como uma atividade de extração e exploração, que envolve a obtenção de minerais para a produção de *microchips*, geração de energia para a manutenção de *data centers* e extração de dados para o treinamento de algoritmos, estabelecendo assim novas relações políticas e de poder. Neste sentido, sua interpretação indica que a IA representa uma extensão da exploração capitalista, do trabalho local à dinâmica global.

Apesar disso, curiosamente, parece haver apenas um interesse marginal sobre o tema no *mainstream* dos estudos sociais da ciência e da tecnologia (ESCT) e de política científica e tecnológica. Uma busca preliminar em periódicos da área mostra algumas publicações seminais como, por exemplo: o trabalho de Woolgar (1985) sobre a possibilidade do estudo sociológico da IA; o estudo antropológico de Forsythe (1993) sobre a construção social do conhecimento em IA; o estudo da controvérsia científica sobre as redes neurais, nos anos 1950 e 1960, de Olazaran (1996); e a análise bibliométrica de cocitação de palavras e conceitos no campo de IA, conduzido por Courtial & Law (1989). Vale notar que, ainda que contenham *insights* interessantes, estes trabalhos são agora um tanto anacrônicos, pois abordavam um contexto sociotécnico da IA diferente do atual.

Desta etapa pioneira, é particularmente interessante o trabalho de Slezak (1989), sobre os aspectos epistemológicos das descobertas científicas realizadas por IA, e o subsequente debate envolvendo a posição crítica de Collins (1989) sobre o tema. Aliás, por meio de suas contribuições sobre o conhecimento e *expertise*, Collins vem tangenciando a questão da IA há décadas, com um ceticismo mais ou menos explícito sobre a possibilidade real de inteligências artificiais; em sentido geral, suas obras – “Artificial experts: Social knowledge and intelligent machines” (Collins, 1990) e “Artificial intelligence: Against humanity’s surrender to computers” (Collins, 2018) – argumentam que a inteligência das máquinas é uma espécie de ilusão (o argumento da “sala

chinesa”), sendo elas limitadas àquilo que foi programado e permitido por seus programadores humanos; desta forma, estes trabalhos aproximam-se das críticas atuais sobre as limitações das IAs, embora não tenham recebido a mesma atenção que suas produções anteriores sobre *expertise*.

Dentre as contribuições mais recentes, é possível destacar trabalhos sobre temas diversos, como as aplicações militares da IA (Suchman, 2022) e os veículos autônomos (Stilgoe, 2017), ou sobre a história dos algoritmos (Ensmenger, 2012). Todavia, eles não chegam a constituir uma abordagem abrangente e sistemática sobre o atual estado da IA. No contexto latino-americano e brasileiro, as pesquisas e textos que tratam da IA do ponto de vista dos ESCT ou da política de ciência e tecnologia são ainda mais raros. Um exemplo de interesse é o artigo “A economia política da inteligência artificial: o caso da Alemanha” (Mendes, 2022), mas, em sentido amplo, a temática parece ainda estar concentrada em outras áreas do conhecimento. Portanto, uma análise exploratória parece indicar que não existe um debate sistematizado, no contexto latino-americano, sobre os impactos da IA na ciência e tecnologia, em geral, e nos ESCT, de forma reflexiva.

Ao considerar este contexto analítico, a presente pesquisa busca apresentar algumas linhas para reflexão sobre a IA, a partir do referencial dos ESCT e da sociologia da ciência e da tecnologia, com foco específico em suas repercussões para os estudos sobre atividade científica, o desenvolvimento tecnológico e a inovação. Mais especificamente, ele visa oferecer as seguintes contribuições, em dois sentidos: a) apresentar uma contextualização geral e atualizada sobre IA e suas diferentes tecnologias relacionadas, evitando narrativas alarmistas ou excessivamente otimistas; b) evidenciar os impactos da IA sobre as práticas de publicação acadêmica, inclusive sobre as metodologias de pesquisa, em sentido reflexivo, para o próprio campo dos ESCT. Metodologicamente, este trabalho baseia-se em: revisão bibliográfica e análise de notícias; material técnico e de divulgação sobre IA; e em repositórios de códigos de programação.

Em síntese, este trabalho busca mostrar que as tecnologias de IA poderão impactar a atividade científica tanto em sua construção (desde o manejo dos recursos computacionais até os processos de construção e análise de dados) quanto em sua circulação (ao alterar a produção de inscrições científicas, sua divulgação e, desse modo, a estrutura de recompensas da comunidade científica). Assim, apresenta algumas possibilidades para incorporar o debate sobre IA ao contexto dos ESCT, tratando essas tecnologias simultaneamente como objetos legítimos, passíveis de análise pelos referenciais e métodos próprios do campo, e como uma ferramenta a ser reflexivamente adotada em todas as suas implicações metodológicas e epistemológicas. Como mostra dessas possibilidades analíticas, articula uma interpretação a respeito do impacto da IA sobre unidades analíticas como “artigo”, “autoria” e “epistemologia”.

Esperamos que esta abordagem se apresente tanto como uma introdução ao tema e instigue novas linhas de pesquisas e debates, possibilitando a apreensão de questões básicas sobre IA, quanto como exercício de reflexividade sobre a prática dos estudos sobre ciência, tecnologia, inovação e sociedade, sua atualidade e relevância em um cenário sociotécnico de mudanças rápidas e profundas.

## CONCEITOS BÁSICOS DE IA

A inteligência artificial (IA) é uma área da ciência da computação que, com influência de disciplinas como estatística, neurociência, linguística, entre outras, visa desenvolver sistemas capazes de executar tarefas que normalmente exigem inteligência humana como aprendizado, raciocínio, resolução de problemas, percepção e uso da linguagem. Em sentido geral, pode ser dividida em: IA restrita (*narrow AI*) – são sistemas projetados para realizar uma tarefa específica, tais como classificar uma imagem ou dirigir um carro; e IA geral (*artificial general intelligence*, AGI) – o sistemas com habilidades cognitivas gerais capazes de realizar qualquer tarefa intelectual que um humano possa fazer (Goertzel, 2014; Boden, 2020; Copeland, 2023). Atualmente, equipamentos eletrônicos, redes sociais, sistemas de recomendação de *streaming* e *sites* de compra empregam, de forma rotineira, uma variedade de IAs restritas. Por sua vez, a IA geral é um conceito ainda não realizado em termos práticos, apesar de avanços tecnológicos recentes (Jiang et al., 2023).

Uma terceira categoria é a IA “superinteligente”: um tipo hipotético de IA que iria além da imitação da inteligência humana, superando-a em todos os campos, inclusive os da criatividade científica, sabedoria geral e habilidades sociais (Bostrom, 2014). Embora a pesquisa em IA tenha feito progressos significativos, não há indícios de que estejamos próximos de alcançar a “superinteligência”. A criação de uma IA “superinteligente” apresenta muitos desafios técnicos e éticos e é um tópico de debate intenso entre os pesquisadores de IA. O surgimento de uma IA “superinteligente” é frequentemente visto como um evento que poderia desencadear a *singularidade*. A ideia é que uma vez que uma IA “superinteligente” seja criada, ela seria capaz de melhorar a si mesma ou criar outras IAs ainda mais inteligentes, levando a um suposto rápido crescimento exponencial nos avanços tecnológicos (Goertzel, 2007; Harari, 2016).

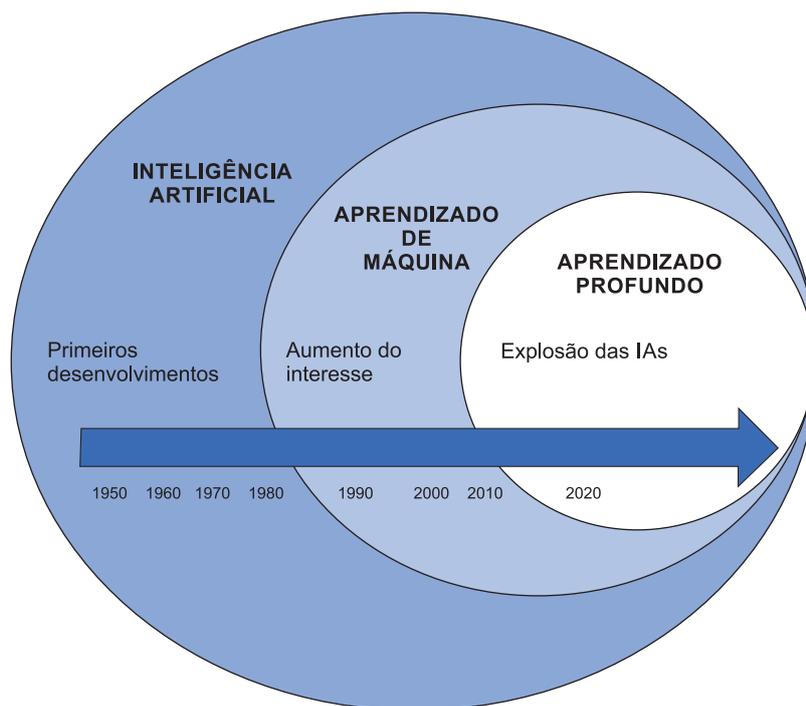
Do ponto de vista dos fundamentos da IA, é possível pensar em duas abordagens gerais: a *abordagem simbólica*, também conhecida como IA clássica, que envolve a manipulação de símbolos e regras para imitar o pensamento humano; e a *abordagem conectivista*, também conhecida como IA conexionista, que usa redes neurais computacionais que tentam simular o comportamento dos neurônios humanos para processar e aprender informações.

Por um lado, na *abordagem simbólica* mais precisamente, o conhecimento é representado por símbolos que podem ser manipulados por regras lógicas ou algoritmos. Esses símbolos podem representar objetos, conceitos, propriedades, relações, ou até mesmo inferências e raciocínios. A IA *simbólica* é frequentemente associada a sistemas baseados em regras, sistemas especialistas e lógica de programação. Ela tem sido usada com sucesso em uma variedade de aplicações, inclusive na resolução de problemas lógicos, raciocínio baseado em casos e compreensão de linguagem natural. Porém, a IA *simbólica* tende a ter baixa flexibilidade e maior dificuldade com tarefas que envolvem aprendizado a partir de dados (Boden, 2020).

Por outro lado, a *abordagem conectivista* ou IA conexionista é a base do aprendizado profundo (*deep learning*), que vem sendo empregado em várias inovações recentes no campo. As redes neurais computacionais são compostas por “nós” ou “neurônios” interconectados, organizados em camadas, que processam e transmitem informações de maneira semelhante aos neurônios biológicos. No entanto, é importante notar que esta semelhança é bastante simplificada: enquanto um neurônio biológico pode se conectar a milhares de outros neurônios e realizar cálculos complexos, um “neurônio” em uma rede neural computacional é uma unidade de processamento simples, que realiza um cálculo matemático sobre suas entradas e passa o resultado para os nós na próxima camada (Boden, 2020).

Em um sentido mais operacional, é possível pensar em diferentes níveis de complexidade e áreas de aplicação de IA. Por exemplo, *machine learning* (ML), ou aprendizado de máquina, é um subcampo da IA que se concentra no desenvolvimento de sistemas que podem aprender dos dados. *Deep learning* (DL), por sua vez, é um subcampo do ML que se concentra em algoritmos inspirados na estrutura e função do cérebro chamados de redes neurais artificiais (Sharifani & Amini, 2023). Em resumo, portanto, IA é o conceito mais amplo de máquinas capazes de realizar tarefas de maneira inteligente, enquanto ML e DL são subcampos específicos da IA (Figura 1).

Os avanços em IA e ML vêm sendo impulsionados por sua aplicação bem-sucedida a uma grande variedade de tarefas. Algoritmos de “regressão”, por exemplo, podem prever valores contínuos, como os preços em um mercado, com base em variáveis de entrada. Algoritmos de “classificação” preveem categorias, como identificar se um e-mail é *spam* ou não. A “clusterização” (*clustering*), uma forma de aprendizado não supervisionado, identifica grupos em um conjunto de dados útil para identificar padrões ou agrupamentos naturais (Grus, 2021). Por fim, os algoritmos “generativos” criam novos dados como, por exemplo, imagens ou textos inéditos baseados em exemplos de treinamento (Jovanović & Campbell, 2022). O ChatGPT é uma IA generativa baseada nos princípios do processamento de linguagem natural (*natural language processing*, NLP) (Tabela 1).



**Figura 1.** Evolução e domínios do campo da IA.

Fonte: adaptado de Cenán (2019).

**Tabela 1.** Principais tarefas de IA e ML.

Tarefa	Principais algoritmos	Exemplos de aplicação na pesquisa científica
Regressão	Regressão linear, regressão polinomial, regressão <i>ridge</i> , regressão LASSO ( <i>least absolute shrinkage and selection operator</i> ), regressão <i>elastic net</i>	Previsão de tendências climáticas, modelagem de crescimento populacional, previsão de demanda de energia
Classificação	Regressão logística, máquinas de vetores de suporte (SVM), árvores de decisão, florestas aleatórias, <i>Naïve Bayes</i> , redes neurais	Classificação de espécies em biologia, diagnóstico médico, detecção de padrões em dados astronômicos
Clusterização	<i>K-means</i> , <i>DBSCAN</i> , <i>agglomerative hierarchical clustering</i> , <i>spectral clustering</i> , <i>mean-shift</i>	Agrupamento de genes em genômica, identificação de comunidades em redes sociais, detecção de padrões em dados socioeconômicos
Tarefas generativas	Redes geradoras adversariais (GANs), <i>variational autoencoders</i> (VAEs), <i>PixelRNN/CNN</i>	Geração de imagens para treinamento de modelos, geração de sequências de DNA para pesquisa genômica, geração de moléculas para pesquisa química, geração de textos

Fonte: adaptado de Python Package Index (Pypi, 2023).

Os treinamentos de IA e ML podem ser realizados de diferentes maneiras, que incluem: “aprendizado supervisionado”, “não supervisionado”, “por reforço” e “com reforço humano” (Tabela 2). No “aprendizado supervisionado”, um modelo é treinado para aprender uma função que mapeie as entradas para as saídas, o que é útil quando os rótulos de saída são conhecidos. O “aprendizado não supervisionado” treina um modelo em exemplos de entrada sem saída correspondente, ou seja, é aplicável quando os rótulos de saída são desconhecidos. O “aprendizado por reforço” treina um agente computacional para tomar decisões em um ambiente, recebendo recompensas ou punições, o que é útil em ambientes complexos como jogos. O “aprendizado com reforço humano” treina um agente com *feedback* humano, potencializando e ajustando o aprendizado do agente (Badillo et al., 2020; Bai et al., 2022).

**Tabela 2.** Tipos de treinamento de IA, algoritmos e seus usos.

Tipo de Treinamento	Principais Algoritmos	Aplicações na Pesquisa Científica
Aprendizado supervisionado	Regressão linear, regressão logística, máquinas de vetores de suporte (SVM), árvores de decisão, florestas aleatórias, redes neurais	Classificação de imagens em astronomia, previsão de tendências climáticas, diagnóstico médico
Aprendizado não supervisionado	<i>K-means</i> , DBSCAN, <i>hierarchical clustering</i> , <i>autoencoders</i> , PCA	Deteção de anomalias em dados astronômicos, segmentação de células em imagens biomédicas, redução de dimensionalidade em genômica
Aprendizado por reforço	<i>Q-learning</i> , SARSA, <i>deep Q network</i> (DQN), <i>policy gradients</i> , <i>actor-critic methods</i>	Otimização de sistemas em engenharia, navegação de robôs em robótica, otimização de políticas em economia
Aprendizado com reforço humano	<i>Proximal policy optimization</i> (PPO), <i>deep deterministic policy gradient</i> (DDPG), <i>twin delayed DDPG</i> (TD3)	Treinamento de robôs, treinamento de sistemas de recomendação, treinamento de modelos de linguagem

Fonte: adaptado de Python Package Index (Pypi, 2023).

O DL tem aplicações em diversas áreas. Na visão computacional, o DL permite que sistemas identifiquem e classifiquem objetos e pessoas em imagens e vídeos. No processamento de linguagem natural, o DL é usado para tradução automática, análise de sentimentos e geração de textos, permitindo a criação de *chatbot* e assistentes virtuais mais eficientes. Na área da saúde, é aplicado para diagnóstico médico, análise de imagens médicas e previsão de doenças. No setor financeiro, é usado para detecção de fraudes e previsão do mercado de ações. Na ciência, o DL permite aos pesquisadores identificar combinações valiosas em cenários onde o conhecimento interage de maneiras altamente complexas (Bianchini et al., 2020). Apesar de seus sucessos, esses modelos são em grande medida caixas-pretas cujo funcionamento não é compreensível ou auditável por parte de seus usuários e criadores (Berghoff et al., 2022).

Os recentes modelos de linguagem de grande escala (*large language models*, LLMs) são formas avançadas de IA que utilizam DL e “aprendizado com reforço humano” para gerar textos coerentes e contextualmente relevantes. Treinados em vastos conjuntos de dados textuais, os LLMs podem realizar tarefas como tradução de idiomas e redação de ensaios. O GPT (*generative pre-trained transformers*, transformadores pré-treinados generativos) é uma arquitetura de LLM que utiliza transformadores (um tipo de rede neural) para gerar textos. O GPT-4, uma versão recente desta tecnologia, segue este padrão, embora o tamanho e a complexidade exatos de seus parâmetros não estejam disponíveis (OpenAI, 2023). Apesar da impressionante competência linguística destes modelos, existem preocupações éticas e de segurança, como o potencial de abuso e a garantia da precisão das informações geradas.

O ChatGPT é um *chatbot* desenvolvido pela OpenAI, uma organização de pesquisa em inteligência artificial, a partir do modelo GPT. O sistema foi treinado utilizando uma mistura de dados licenciados, dados criados por treinadores humanos e dados públicos. O ChatGPT foi lançado inicialmente como um serviço gratuito, mas, em 2021, a OpenAI introduziu o ChatGPT Plus, um serviço por assinatura que oferece benefícios como acesso prioritário durante períodos de alta demanda, tempos de resposta mais rápidos e acesso a novos recursos (*plugins*). A introdução deste modelo de negócios ajuda a apoiar a disponibilidade contínua do serviço gratuito para um maior número possível de usuários. Considerando-se os aspectos técnicos e mercadológicos, é compreensível que o ChatGPT seja um dos produtos tecnológicos com adoção mais rápida da história, pois acumulou mais de 100 milhões usuários em seus primeiros dois meses de funcionamento (Hu, 2023).

No artigo “On the dangers of stochastic parrots”, Bender et al. (2021) abordam os riscos associados aos grandes modelos de linguagem (LLMs) na área de processamento de linguagem. Os autores alertam sobre os custos ambientais e financeiros crescentes destes modelos, bem como

a codificação de preconceitos nos dados de treinamento. Também argumentam que, embora os LLMs tenham impulsionado avanços significativos em várias tarefas, eles não realizam uma verdadeira compreensão da linguagem humana – de fato, eles apenas são competentes em tarefas que podem ser abordadas manipulando-se estatisticamente as linguagens humanas (daí a referência ao “papagaio estocástico”). Além disso, os autores discutem os riscos de danos associados ao uso destes modelos, inclusive a possibilidade de encontrar linguagem depreciativa e experimentar discriminação, por conta de vieses nas bases de treinamento.

O ChatGPT é, possivelmente, a face mais conhecida da inovação tecnológica das IAs generativas. No entanto, como mencionado anteriormente, as IAs generativas podem ser empregadas para tarefas diversas, tais como: a geração de imagens, vídeos, hipóteses científicas, criação de modelos de simulação complexos, análise e interpretação de grandes volumes de dados e, obviamente, a produção de artigos científicos. Em sentido geral, a IA generativa tem o potencial de acelerar a descoberta científica, ao permitir que os pesquisadores explorem uma gama mais ampla de possibilidades experimentais. Por exemplo, a IBM Research tem explorado o uso de modelos generativos na descoberta, especificamente para o *design* de moléculas, com várias aplicações de descoberta de materiais (Smith & Manica, 2022). Analisados em conjunto, estes avanços podem ter impactos significativos sobre a prática científica e a de desenvolvimento tecnológico.

O efeito combinado do aumento da capacidade dos computadores, diminuição do custo computacional para o processamento e a estabilização das tecnologias e algoritmos de IA possibilitou uma onda recente de adoção e entusiasmo, com potenciais impactos na Ciência, Tecnologia e Inovação, desde a prática nos laboratórios até o desenho de políticas públicas. Ocorre que essas inovações acontecem em ritmo acelerado e são relativamente herméticas do ponto de vista técnico; por isso, a capacidade dos analistas (sociólogos de ciência e tecnologia, analistas de política etc.) não acompanha o ritmo das mudanças. Logo, no cenário atual se identificam lacunas e uma defasagem significativa no campo dos ESCT, cujas contribuições sobre as relações entre IA, comunidade acadêmica e processos de inovação é ainda embrionário. Portanto, torna-se cada vez mais importante a investigação sobre a economia política e os interesses sociais articulados à emergência das IAs. Por um lado, em sentido amplo, isso significa evidenciar como as IAs surgem, que tipos de recursos e atores elas mobilizam e como se inserem na agenda pública. Ou seja: quem se beneficia destas redes sociotécnicas e como elas se impõem? Quais seus possíveis impactos sociais? Por outro lado, do ponto de vista da especificidade do fazer científico, é possível explorar suas consequências e impactos para a dinâmica das relações e hierarquias da comunidade científica, bem como suas implicações epistemológicas e para a construção do conhecimento. Afinal, se a IA pode trazer mudanças estruturais profundas nos empregos e relações políticas, parece correto supor que terá consequências também para cientistas, universidades e organizações de pesquisa. Para explorar esta segunda dimensão vamos, a seguir, analisar alguns dos impactos destas inovações sobre a atividade científica.

## PUBLICAÇÃO ACADÊMICA, AUTORIA E IA GENERATIVA

Não é novidade que a atividade científica organiza-se, em grande medida, em torno da publicação de textos científicos como livros, capítulos em coletâneas, artigos em revistas, resenhas, registros de patentes, relatórios técnicos e material de popularização da ciência. Por isso, a atividade de produção, edição e distribuição de textos está no cerne do fazer científico: da socialização (aprender a coletar registros e relatar resultados), passando pela atribuição de mérito e reconhecimento (ser citado pelos pares), até a avaliação e o ranqueamento (processo de distribuição de recursos), os cientistas cotidianamente se orientam pelos imperativos da publicação acadêmica. De fato, existe toda uma maquinaria coletiva relacionada a um modelo editorial, composta por instituições e grupos editoriais, revistas especializadas, editores, cientistas envolvidos com a revisão por pares (*peer review*) e pessoal técnico encarregado das correções, diagramação e divulgação.

Este arranjo tem características ambivalentes. Por um lado, em sentido positivo, demarca a diferenciação entre o conhecimento científico e outras formas de saber. Ou seja: é por meio da circulação aberta das hipóteses e resultados de pesquisa que os cientistas submetem sua produção ao escrutínio intersubjetivo de toda uma comunidade. Isso garante o rigor metodológico, controla os vieses individuais dos pesquisadores e reforça o caráter cumulativo do conhecimento científico (Merton, 1968). Além disso, textos acadêmicos podem ser considerados uma associação heterogênea entre discurso e inscrições que permitem a simplificação dos enunciados científicos e sua circulação. Afinal, os artigos científicos são a face mais evidente e estabilizada das complexas redes sociotécnicas da pesquisa e, por isso, permitem que os fatos científicos circulem entre os cientistas e na sociedade, em sentido amplo (Latour & Woolgar, 1997; Latour, 2000).

Por outro lado, em um sentido negativo, a centralidade do artigo científico tem causado desvios e distorções na prática científica. Ocorre que o uso acrítico dos mecanismos atualmente existentes de recompensas internas e de reconhecimento externo vêm gradualmente tornando a publicação científica “um fim em si mesmo”. Em outras palavras, estabelece-se o fenômeno do “papirocentrismo” que reduz, na prática, a atividade científica a uma atividade produtivista (Mattedi & Spiess, 2017). De forma relacionada, evidenciam-se cada vez mais fenômenos como a consolidação de um oligopólio da publicação científica e do bloqueio de conteúdos por detrás de *paywalls*, a proliferação de “*predatory journals*”, plágio e outras distorções autorais e editoriais semelhantes (Ercegovac & Richardson, 2004; Larivière et al., 2015; Richtig et al., 2018).

Apesar disso, os dados evidenciam o contínuo crescimento da publicação acadêmica. Somente em 2020, foram publicados mais de 2,9 milhões de artigos, com mais de 90% do total proveniente de países com economias de alta renda e renda média alta (National Science Board, 2021). Nas últimas décadas, a quantidade de artigos científicos publicados tem aumentado cerca de 8% a 9% ao ano e, somente no campo biomédico, mais de 1 milhão de artigos são adicionados ao banco de dados PubMed anualmente (Landhuis, 2016). No entanto, a grande maioria desses estudos não é lida ou citada, o que pode ser atribuído à sobrecarga de informações enfrentada pelos pesquisadores e ao esvaziamento do sentido original da publicação. Além disso, a distribuição das citações segue a lei de Lotka e a distribuição de Pareto, com poucos artigos recebendo a maioria das citações (Mattedi & Spiess, 2017).

Com o aumento exponencial da produção de artigos científicos, podemos considerar uma hipótese baseada nos conceitos econômicos de oferta e valor relativo que diz que à medida que a oferta de artigos científicos aumenta, a quantidade de atenção que cada artigo individual pode receber de outros pesquisadores inevitavelmente diminui. Isto ocorre porque a quantidade de tempo e atenção que os pesquisadores podem dedicar à leitura de novos artigos é limitada. Assim, o valor relativo de cada artigo individual – em termos de sua capacidade de atrair a atenção e ser citado por outros pesquisadores – tende a diminuir, à medida que a oferta de novos artigos e publicações similares aumenta. Neste contexto, a produção de textos acadêmicos com suporte de IAs generativas (por exemplo, ChatGPT) pode intensificar ainda mais este processo, uma vez que com sua adoção o custo para produção textual (em tempo e esforço dos pesquisadores) pode cair significativamente.

Por tratar-se de um fenômeno recente, as evidências sobre a relação entre as IAs generativas e a produtividade acadêmica são ainda muito esparsas. Porém, a imediata vinculação entre geração de textos por IA e desvios produtivistas pode ser um indício importante. O caso exemplar é o do altamente produtivo pesquisador espanhol Rafael Luque que, entre outros supostos desvios de conduta, admitiu empregar o ChatGPT para melhorar e acelerar o processo de preparação de manuscritos. Com a ajuda da IA, Luque produziu, nos primeiros meses de 2023, uma média de um artigo a cada 37 horas (Ansede, 2023). Para além de evidências anedóticas, estudos experimentais pioneiros já indicam ganhos de produtividade em tarefas de escrita assistidas pelo ChatGPT (Noy & Zhang, 2023). Se o fenômeno se confirmar também no campo acadêmico, poderemos observar a confirmação da hipótese da queda do valor relativo dos artigos.

De forma adicional, é possível identificar também uma reação contrária à atribuição de coautoria ao ChatGPT, por parte dos atores que controlam os processos editoriais e os eventos acadêmicos. Apesar de alguns casos pioneiros de textos “assinados” pelo ChatGPT como coautor (Stokel-Walter, 2023), recentemente os grupos Springer-Nature e Elsevier proibiram a prática, sob a alegação de que a autoria implica responsabilidades e atribuições exclusivamente humanas (Elsevier, 2023; Nature, 2023). Curiosamente, postura similar foi adotada pelos organizadores da International Conference on Machine Learning, que baniram o uso dos LLMs a menos que o texto produzido fosse parte dos resultados de pesquisa apresentados (ICML, 2023). Aparentemente, estas reações se baseiam em um princípio de precaução, tal qual a recente carta-aberta pela moratória das pesquisas com LLMs (Future of Life Institute, 2023).

Nosso argumento, todavia, vai em outra direção e procura explorar as consequências sociológicas das noções de crédito e autoria. De forma ampla, a autoria seria o marcador da “excepcionalidade” da pesquisa científica como atividade social. Mais detalhadamente, propomos que o “binômio autoria-crédito” reflete alguns princípios da comunidade científica e da construção dos fatos científicos. Por isso, a “coautoria humano-IA” evidenciaria e, neste movimento, colocaria em questão alguns princípios centrais para a atividade científica (Tabela 3).

**Tabela 3.** Princípios da autoria e impactos das IAs generativas.

Princípio sociológico	Relação com a autoria	Efeito das IAs
Socialização	A prática da escrita acadêmica mostra a internalização do <i>ethos</i> científico (Merton, 1968).	Os imperativos perdem importância, favorecendo desvios normativos (produtivismo, plágio).
Recompensa	A autoria certifica a transação mérito x reconhecimento (Hagstrom, 1965).	O crédito não é mais personalizado, ameaçando os privilégios de autores estabelecidos.
Demarcação	A autoria pressupõe <i>expertise</i> contributiva (Collins & Evans, 2002).	Leigos ( <i>expertise</i> interacional) podem comandar a produção de textos, borrando as fronteiras de atribuições de autoria.

Nesse sentido, a reação negativa aos modelos de linguagem e *chatbots* de geração de texto pode ser entendida como um processo social de proteção dos mecanismos internos e latentes da prática científica. Em outras palavras, seria possível dizer que escamoteada na crítica aos “papagaios estocásticos” e suas limitações técnicas esteja uma espécie de “pânico moral”. Afinal, a geração automatizada de textos científicos embaralha as coordenadas normativas e as divisões de papéis da ciência. Seu uso pode nivelar autores centrais e periféricos em termos de sua capacidade de *output*, além de possivelmente acelerar ainda mais o “ciclo papirocentrico”. Assim, é possível propor a hipótese de que a adoção desregulada da colaboração “humano-IA” pode disseminar ainda mais o produtivismo e, com isso, depreciar ainda mais o valor das contribuições individuais. Isto implicaria, por exemplo, a necessidade de um inconveniente rearranjo das atuais políticas de avaliação de ciência e tecnologia e de redistribuição dos recursos para pesquisa.

Além disso, é razoável supor que diferentes áreas do conhecimento e disciplinas sejam atingidas de formas distintas por esses processos de automação, com impactos ainda pouco previsíveis. No entanto, se emularmos a distinção proposta em “The Two Cultures” (Snow, 1993), colocando em oposição uma cultura técnico-científica e outra de “intelectuais literários”, podemos conjecturar que a segunda “cultura” será mais afetada pelas IAs generativas. Explicando: para as “ciências duras”, nas quais os procedimentos metodológicos são mais rigorosos, e os relatos escritos são menos subjetivos, a geração automática de textos poderá encontrar maiores obstáculos para emular o desempenho humano; paradoxalmente, para as disciplinas de “artes e humanidades”, por sua dependência de técnicas discursivas e seu alto subjetivismo, as IAs generativas representam substitutos altamente competentes.

Este argumento evidencia-se quando recorremos aos casos limítrofes. Por um lado, aplicações –como o ChatGPT, apesar de poderem gerar textos coerentes e gramaticalmente corretos, também

podem produzir “alucinações” – informações falsas ou enganosas –, uma vez que não possuem uma compreensão real do mundo e dependem inteiramente dos dados em que foram treinados (Alkaissi & McFarlane, 2023). Por outro lado, textos do campo das ciências humanas e, notadamente, aqueles de inclinação pós-moderna, podem rejeitar a existência de uma realidade objetiva e sobrevalorizar a linguagem e a retórica, em detrimento das evidências e da lógica, conforme mostrado no famoso experimento de Sokal (1996). Ou seja: ambos os tipos de autores (humanos e IAs) podem produzir textos inteligíveis (“consistência interna”) e contextualmente alinhados ao cânone de um campo (“coerência externa”), mas desprovidos de evidências empíricas.

É como se o problema das “alucinações” das IAs refletisse as limitações do jargão pós-moderno e da centralidade do discurso nas ciências humanas e disciplinas relacionadas. Portanto, é possível pensar em ao menos dois cenários futuros possíveis: a) para preservar sua legitimidade, as disciplinas discursivas serão gradualmente pressionadas a convergir para uma postura mais técnica; ou b) os autores do campo das ciências humanas irão reforçar seu posicionamento contra as IAs, em um discurso neoludita politicamente ativo em favor da regulação ou banimento das tecnologias. Em ambos os cenários, todavia, persiste o risco de exposição dos limites das disciplinas marcadamente discursivas; sobretudo, os modelos generativos poderão levar à problematização da legitimidade deste tipo de ciência. Afinal, quando todos podem empregar o ChatGPT para falar sobre temas sociais, onde residirá a excepcionalidade dos cientistas?

## A PRÁTICA DE PESQUISA E A IA

A recente explosão da IA trouxe consigo não apenas modelos de geração automática de textos. De fato, podemos pensar na disseminação de uma série de aplicações tão importantes quanto o ChatGPT como, por exemplo, “simulações baseadas em agentes computacionais e IAs generativas” no contexto da produção de dados e teste de hipóteses científicas. Assim como os LLMs, esses algoritmos se tornaram possíveis por meio da estabilização de uma rede sociotécnica, surgida do efeito combinado do aumento da capacidade de processamento dos computadores, da queda no custo dos processamentos computacionais, e da consolidação de uma cultura de produção e uso de dados (*big data*). Seu crescente uso na produção e análise de dados implicarão mudanças significativas para os praticantes de pesquisa científica e tecnológica, desde a automação de tarefas rotineiras de laboratório, passando pela divisão do trabalho científico, até chegar às formas de produção de dados.

Um exemplo paradigmático da IA aplicada à ciência é o algoritmo AlphaFold. Ele é uma ferramenta de IA desenvolvida pela empresa britânica DeepMind, lançado em sua primeira versão em 2018, que prevê a estrutura tridimensional de uma proteína com base apenas em sua sequência genética. A estrutura de uma proteína é fundamental para entender sua função, e o AlphaFold pode acelerar significativamente a pesquisa, substituindo técnicas experimentais demoradas e caras. O sistema usa redes neurais profundas, para prever as distâncias entre pares de aminoácidos e os ângulos entre as ligações químicas que os conectam. Essas previsões são usadas para gerar estruturas de proteínas altamente precisas e, assim, solucionar o problema da previsão da estrutura de proteínas, um desafio que persistiu por quase 50 anos (Senior et al., 2020; Perrakis & Sixma, 2021). Por conta desses avanços, os pesquisadores John Jumper e Demis Hassabis, da Google DeepMind, foi laureados com o Prêmio Nobel de Química de 2024.

O AlphaFold é alimentado a partir de várias fontes, inclusive o UniProt e o Protein Data Bank (PDB), que são repositórios de dados sobre as estruturas de proteínas determinadas experimentalmente. O treinamento do AlphaFold é um processo de duas etapas: na primeira, o modelo é treinado para prever propriedades da estrutura da proteína, como os ângulos dos resíduos de aminoácidos e a distância entre os resíduos, com base na sequência da proteína. Este treinamento é realizado por meio de uma rede neural de aprendizado profundo. Na segunda etapa, o modelo é treinado para prever a estrutura tridimensional completa da proteína. Para isso, ele usa as previsões

feitas na primeira etapa e um algoritmo de otimização, para encontrar a estrutura que melhor se ajusta a essas previsões. Este processo é repetido várias vezes para melhorar a precisão do modelo (Thornton et al., 2021). Assim, o algoritmo foi capaz de prever as estruturas 3D de mais de 200 milhões de proteínas, cobrindo o que é descrito como o “universo inteiro das proteínas” (Callaway, 2022). Essas previsões foram disponibilizadas em um banco de dados público, em parceria com o Instituto Europeu de Bioinformática, em 2021. Em pouco tempo, o acesso aos modelos de estrutura de proteína de alta precisão teve um impacto significativo em vários campos científicos. Por exemplo, biólogos estruturais estão usando modelos do AlphaFold, para resolver estruturas por meio da combinação de dados experimentais e as coordenadas do modelo teórico. Pesquisadores de bioinformática estão realizando análises de alto rendimento, para descobrir padrões e características em uma escala anteriormente impossível. Empresas farmacêuticas estão empregando técnicas de descoberta de medicamentos baseadas em estrutura usando o modelo (Varadi & Velankar, 2023).

Outra linha de aplicação de IA na pesquisa científica são os modelos generativos profundos (*deep generative models*, DGM). Em geral, eles são redes neurais com muitas camadas ocultas, treinadas para aproximar distribuições de probabilidade complicadas e de alta dimensão que usam grandes quantidades de dados. Seu desenvolvimento tornou-se um dos campos mais pesquisados em IA nos últimos anos. Alguns avanços, como a geração de imagens, vozes ou filmes, já alcançaram o público em geral. No entanto, ainda existem desafios matemáticos e práticos que limitam o uso mais amplo dos DGMs, como a dificuldade de projetá-los e treiná-los para um conjunto de dados específico e entender por que um modelo específico é ou não eficaz (Ruthotto & Haber, 2021). Um obstáculo adicional pode relacionar-se à preparação de pesquisadores para o uso e desenvolvimento de IAs.

Mas como esses modelos funcionam? Suponhamos que temos um conjunto de dados sobre moléculas. Os modelos generativos podem aprender a partir desses dados e entender como eles são estruturados. Uma vez que um modelo aprendeu o suficiente, ele pode fazer duas coisas importantes. Primeiro, ele pode ajudar a comparar novos modelos, para ver qual deles entende melhor os dados. Isso é feito observando-se quão bem o modelo pode “adivinhar” novos dados que se parecem com o que já foi visto. Segundo, e talvez mais interessante, o modelo pode criar novos dados que se parecem com o que ele aprendeu. No caso de moléculas, isso significa que o modelo pode sugerir novas estruturas que possam ter propriedades desejáveis como, por exemplo, ser mais eficazes como medicamentos. Metaforicamente, é como se o modelo estivesse “sonhando” com novas moléculas com base no que aprendeu sobre as moléculas existentes (Jørgensen et al., 2018).

Essa lógica geral aplica-se – com algumas especificidades – aos principais modelos generativos em uso atualmente. Dentre eles podemos destacar: a) *Autoencoders* - redes neurais que codificam e decodificam dados, reduzindo a dimensionalidade e removendo ruídos (Zhai et al., 2018); b) *Generative adversarial networks* (GANs) - consistem em um gerador que cria dados realistas, e um discriminador que distingue entre dados reais e falsos, melhorando continuamente um ao outro (Goodfellow et al., 2014); c) Modelos de difusão - treinados em milhões de pares de texto-imagem, criam imagens sintéticas, com a possibilidade de gerar imagens de categorias não explicitamente representadas no treinamento (Croitoru et al., 2023). O emprego dessas tecnologias na pesquisa científica e desenvolvimento de produtos têm implicações profundas, ainda quase inexploradas.

No entanto, pesquisas em física, química e biologia molecular, farmacologia e ciência de materiais já apresentam sucessos promissores, assim como diferentes usos possíveis em *design*, arquitetura e aplicações similares (Turhan & Bilge, 2018). Por exemplo, em 2020, um modelo de aprendizado profundo foi empregado para identificar moléculas com propriedades antibacterianas. O modelo identificou um composto “candidato”, o *halicin*, que mostrou atividade antibacteriana contra uma ampla gama de patógenos, inclusive bactérias resistentes a múltiplos medicamentos (Stokes et al., 2020). Esta abordagem *in silico* permite a testagem de um grande espaço amostral e a geração de soluções que, apenas posteriormente, são complementadas por procedimentos de

investigação e testes mais convencionais, que representam maior segurança, otimização de tempo e menores custos de pesquisa.

Mesmo os LLMs debatidos anteriormente têm impactos sobre a produção de dados. De fato, já se cogita que os LLMs poderão superar os humanos nos processos de obtenção de dados em humanidades ou ciências sociais aplicadas, como na área de marketing. Estes modelos têm mostrado uma capacidade impressionante de gerar respostas realistas a pesquisas sobre comportamento do consumidor (Grossman, 2023). Isso significa que eles podem simular a maneira como os consumidores reais responderiam a perguntas ou cenários específicos. No entanto, o sucesso desta abordagem depende de vários fatores. Por exemplo, os dados usados para treinar o modelo devem ser representativos do comportamento do consumidor real. Se os dados de treinamento não forem precisos ou abrangentes, o modelo pode gerar respostas que não refletem o comportamento do consumidor real.

Uma terceira abordagem é a dos modelos baseados em agentes (*agent-based models*, ABMs). Eles são sistemas computacionais que simulam a interação entre diferentes agentes autônomos em um ambiente, cada um com suas próprias regras de comportamento. Esses agentes podem representar entidades como pessoas, células, produtos, entre outros. Assim, um modelo baseado em agentes pode ser usado para simular a propagação de doenças em uma população, permitindo a análise de diferentes estratégias de intervenção (Brandon et al., 2020), ou simular o comportamento humano em edifícios, considerando a resposta dos ocupantes à morfologia do espaço, operação ambiental do edifício e otimização do espaço (Yi, 2020). Esses modelos permitem uma análise mais precisa e adaptativa de sistemas complexos, o que contribuiria para melhores decisões de *design* ou estratégias de intervenção.

Como técnica de simulação científica de sistemas complexos, os ABMs existem desde antes da atual explosão das IAs (Axelrod, 1997). Na abordagem clássica dos ABMs, as regras que governam o comportamento dos agentes no ambiente simulado são programadas com base em hipóteses formuladas pelos pesquisadores. No entanto, com a aplicação de ML, os comportamentos dos agentes e os parâmetros das simulações podem ser derivados diretamente de dados experimentais, eliminando a necessidade de hipóteses pré-definidas ou programação de regras pelos pesquisadores (Sivakumar et al., 2022). Assim, duas abordagens se destacam: a) o uso de técnicas de aprendizado supervisionado para previsão e detecção de padrões; b) o emprego de aprendizado por reforço, para testar intervenções e otimizações no comportamento dos agentes no ambiente simulado (Zhang et al., 2023).

Em particular, o aprendizado por reforço (*reinforcement learning*, RL) tem-se mostrado uma ferramenta poderosa para aprimorar a eficácia dos ABMs. O RL permite que os agentes aprendam e se adaptem com base em suas próprias experiências dentro do ambiente simulado. Isso resulta em uma modelagem mais realista e precisa de sistemas complexos, uma vez que os agentes são capazes de responder de forma dinâmica às mudanças no ambiente. Além disso, essa capacidade de aprendizado e adaptação dos agentes por meio do RL não apenas aumenta a precisão dos ABMs, mas também permite a emergência de inovações. a partir da interação social entre os agentes, criando o que é conhecido como “autocurrículo”, um fenômeno em que a solução de uma tarefa social gera novas tarefas, promovendo a inovação e a complexidade ao longo do tempo (Leibo et al., 2019).

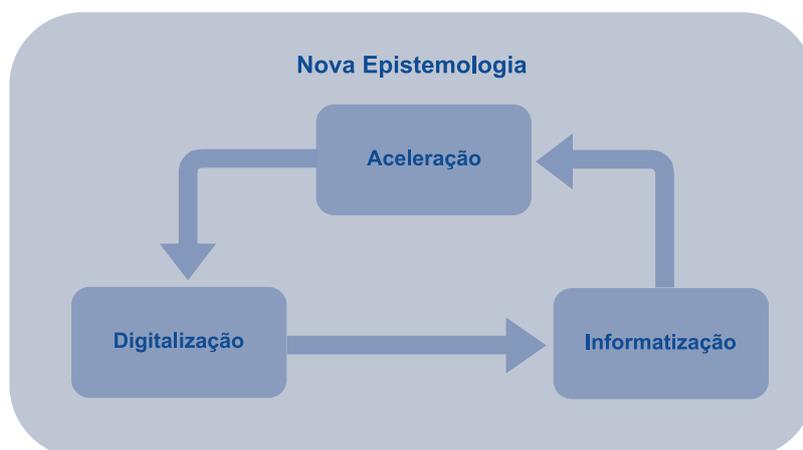
Analisadas em conjunto, as inovações descritas anteriormente (redes neurais, modelos generativos e modelos baseados em agentes) têm uma série de impactos sobre a pesquisa científica. Do ponto de vista epistemológico, os grandes dados passam a anteceder as hipóteses e as descobertas passam a ser produzidas pelas IAs. Por isso, alguns comentaristas já aventaram a possibilidade de uma “ciência pós-teoria” (Anderson, 2008; Dixon, 2022; Spinney, 2022). Isto é: os modelos de IA, muitas vezes opacos em suas operações internas, não fornecem explicações teóricas para seus resultados, desafiando a abordagem tradicional da ciência, que busca entender os “porquês” por trás dos fenômenos. Assim, a ciência “pós-teoria” levanta questões importantes sobre

o papel dos humanos na ciência, a necessidade de “interpretabilidade” nas previsões baseadas em IA e o valor da teoria na era da aprendizagem de máquina. Todavia, esta agenda segue amplamente inexplorada em sua construção e interesses associados.

O debate sobre as descobertas científicas por IA e a implicação disso para o princípio analítico, estabelecido originalmente pelo “Programa Forte” de Bloor (2009) e profundamente enraizado nos ESCT, de que a ciência é socialmente construída e reflete os interesses e valores dos cientistas é particularmente intrigante: se as descobertas emergem dos dados, é possível identificar os interesses sociais envolvidos? Ou existe uma realidade última que é evidenciada, sem intermediários, pelos algoritmos? IAs podem produzir descobertas ou apenas imitam os processos humanos? Nesse sentido, caberia uma reavaliação e atualização das proposições de Slezak (1989) e as refutações de Collins (1989, 1992, 2018), à luz dos avanços e descobertas atuais dos grandes dados às redes neurais profundas, e por meio de aproximações com outras áreas do conhecimento, como a neurociência, estudos de cognição, filosofia etc.

Outra linha de investigação possível reside na discussão sobre as IAs como caixas-pretas. A metáfora da “caixa-preta” ou dos “móveis imutáveis” consolidou-se nos ESCT, por meio da teoria ator-rede (Latour, 2000), e remete às redes sociotécnicas estabilizadas que possuem capacidade de agência e cujo funcionamento interno não é visível ou problematizado. No caso dos algoritmos de IA, essa questão se potencializa e problematiza em torno de sua natureza hermética e não explicável. Em outras palavras, o funcionamento interno de uma rede neural profunda é tão complexo que é desconhecido ou incompreendido até mesmo por seus produtores. Nesta direção, é possível problematizar a pesquisa apoiada por IA tanto do ponto de vista de sua ontologia, quanto das consequências de sua disseminação e circulação, numa direção semelhante à crítica contida em “Algoritmos de destruição em massa” (O’Neil, 2020). Portanto, é de particular interesse a investigação sobre os vieses algorítmicos e suas implicações sociais.

A emergência da ciência “pós-teoria” intuída por Anderson (2008) também tem outras implicações sociológicas possíveis. Primeiramente, a “aceleração” do processo de pesquisa é evidente, pois a IA permite a análise rápida de grandes volumes de dados, superando a capacidade tradicional de processamento e análise. Em segundo lugar, há uma crescente “informatização”, entendida aqui como a valorização das habilidades em computação e IA: os cientistas agora precisam ser proficientes não apenas em seus campos de estudo, mas também em técnicas de aprendizado de máquina e análise de big data. Por fim, o lócus da ciência está deslocando-se dos laboratórios tradicionais para os *data centers*, para a computação em nuvem e para a replicação digital dos modelos computacionais (“digitalização”). Isto é, a pesquisa agora é cada vez mais realizada em ambientes digitais, em que os dados são armazenados, processados e compartilhados de acordo com uma lógica própria (Figura 2).



**Figura 2.** Implicações sociológicas da IA na ciência.

As implicações epistemológicas destas transformações não podem ser ainda completamente extraídas, mas já é possível identificar algumas tendências. Um aspecto muito importante diz respeito ao papel crescente da informação e ao modo como a disponibilidade de grandes conjuntos de dados está desafiando o método científico tradicional. De fato, a abordagem tradicional de formular uma hipótese e testá-la por meio de experimentos controlados está tornando-se menos relevante em algumas áreas de pesquisa, especialmente nas ciências da computação e em campos que lidam com grandes quantidades de dados. Em razão da crescente disponibilidade de dados e do aperfeiçoamento dos algoritmos, ao invés de formular hipóteses iniciais, os pesquisadores podem agora coletar grandes conjuntos de dados e aplicar técnicas avançadas de análise para identificar padrões, correlações e *insights* úteis (Leonelli, 2016). Portanto, as novas formas de obtenção e validação do conhecimento questionam a autoridade científica.

O encurtamento progressivo do ciclo de produção da informação pode ter implicações sociológicas sobre o padrão de organização da comunidade científica. Por um lado, transforma os processos de produção e validação do conhecimento (aumento da produtividade); e, por outro, redefine os mecanismos de formação e a carreira científica. Por exemplo, a automatização das rotinas laboratoriais induzida pela IA pode forçar uma reestruturação dos cargos científicos, tanto em termos qualitativos (aquisição de habilidades complementares) quanto em termos quantitativos (redução de mão de obra). Consequentemente, as atividades de pesquisa tenderiam progressivamente a desacoplar-se do processo de formação de recursos humanos ou redefinir a abrangência da pós-graduação. Ou seja, em termos sociais é possível que a IA force os cientistas a se adaptarem, e a comunidade científica a se reestruturar. Porém, esses desdobramentos possíveis dependerão de acompanhamento empírico para sua correta descrição e mensuração.

Ao considerarmos reflexivamente os impactos destas mudanças, percebemos que o repertório conceitual recorrente nos ESCT – por exemplo, os termos “comunidade”, “laboratório”, “controvérsias” etc. – corre o risco de tornar-se obsoleto ou necessitar de profundas atualizações. Afinal, as diferentes técnicas de IA já existentes e, principalmente, aquelas que ainda virão, podem gradualmente modificar o fazer científico de formas inéditas. Ainda que a pesquisa convencional possa persistir, novas formas de pesquisa científica e tecnológica emergirão potencialmente da aplicação das IAs à produção e à análise de dados. Portanto, novos temas, objetos de pesquisa e metodologias fazem-se necessários no campo dos ESCT, para buscar-se uma adequação a esta nova realidade. Caso contrário, o campo e seus praticantes arriscam tornar-se menos relevantes em um contexto “pós-teórico”, em que a IA gana espaço diariamente.

## CONSIDERAÇÕES FINAIS

Conforme descrito anteriormente, as IAs, suas diferentes técnicas e possibilidades de aplicação têm potencial para causar mudanças significativas na forma de fazer pesquisa científica e tecnológica. A visibilidade recente dessas tecnologias é, na verdade, apenas a manifestação da maturidade do campo da IA e de suas potencialidades de uso para diferentes disciplinas e em várias etapas do processo de pesquisa. Mais sistematicamente, é possível afirmar que essas tecnologias podem operar tanto na “entrada” (obtenção, produção de dados e análise de dados) quanto na “saída” (redação, publicação textual e distribuição de crédito) do processo de pesquisa. Consequentemente, impactam a construção dos fatos científicos e dos artefatos tecnológicos, mas também sua estabilização interna (na comunidade científica) e circulação externa (na sociedade, em sentido amplo). No entanto, sua penetração, possivelmente, não ocorrerá de forma homogênea, mas sim refletindo as especificidades de diferentes disciplinas e áreas do conhecimento. Logo, a intensidade e profundidade do processo pode e deve ser explorada analiticamente.

Nesse sentido, é tentador recorrer a reducionismos em dois pontos opostos: a) IAs como o motor de uma mudança quantitativa e qualitativa positiva na ciência (visão otimista); b) IAs como

destruição da ordem vigente e introdução de incertezas (visão pessimista). Porém, se adotarmos uma postura de “simetria” tão central aos ESCT, não devemos tratar as IAs nestes termos, mas sim como algo que é simultaneamente bom e ruim, bem-sucedido ou fracassado. Em outras palavras, a relação entre IA e pesquisa não é um caso especial do ponto de vista sociológico. Pelo contrário, pode ser analisada pelos mesmos critérios pelos quais são analisados outros fenômenos científicos e tecnológicos. Assim, em um primeiro sentido, acreditamos que os ESCT devam ter uma “posição metodologicamente agnóstica” em relação às IAs. Ou seja: a IA não deve ser considerada como fora do alcance dos ESCT e nem julgada *a priori*.

Isso significa abordar todas as preocupações relacionadas à IA, tais como:

- Os aspectos éticos e de privacidade dos dados.
- O impacto da automação de tarefas e ocupações ou sua substituição por IAs.
- O problema da “caixa-preta” das IAs, cujos resultados em muitos casos não são explicáveis ou auditáveis.
- O problema da concentração da produção de IA em países líderes e seus efeitos geopolíticos etc.

Além disso, significa contemplar diferentes abordagens metodológicas e vertentes disciplinares na problematização das IAs. Mas isso também implica não ter uma resistência ao uso das IAs como ferramentas metodológicas e reconhecer sua importância para a atividade de desenvolvimento científico e tecnológico, seus impactos para a produtividade e otimização do trabalho científico, e os efeitos sociais destas tecnologias em sentido amplo. Se a “revolução das IAs” sobreviver ao *hype* e se concretizar, essas agendas de pesquisa serão impostas de qualquer maneira. Portanto, é melhor que essa conversão seja conduzida internamente pelos praticantes dos estudos sobre CT&I, de acordo com sua própria cultura epistêmica.

Em um segundo movimento simétrico, é possível pensar nas IAs tanto como objeto de estudo quanto como um recurso metodológico a ser internalizado. Em termos práticos, isso implica duas linhas de pesquisa: a) o uso das ferramentas dos ESCT, dos estudos sobre política científica, tecnológica e de inovação, ou da investigação sobre os processos de desenvolvimento social e econômico, para compreender o impacto das IAs na pesquisa e na sociedade; b) o uso prático da IA para mineração e análise de dados, criação de simulações ou geração de dados e para a produção de conteúdo textual sobre ciência, tecnologia e inovação. Considerando-se a novidade dos temas abordados, seu relativo hermetismo e o debate público ainda muito pouco isento sobre a questão, ambas as linhas de pesquisa e atuação prática mostram-se não apenas como oportunidades promissoras, mas quase como um imperativo moral.

As transformações em curso sobrecarregam o ecossistema de pesquisa e pressionam os padrões de organização da comunidade científica. O efeito combinado destes dois fenômenos tem implicações sociológicas profundas para o trabalho científico. Afinal, se os impactos da automação dos anos 1990 e início dos anos 2000 afetaram os trabalhadores não qualificados, agora com a IA ela tende a impactar os trabalhadores qualificados. O encurtamento do ciclo da informação redefine a atividade científica em dois níveis principais: 1) diminui a necessidade de mão de obra com qualificação média, o que implica a redução da importância de professores e técnicos de laboratório e pessoal de apoio; como consequência 2) pressiona o sistema de pós-graduação e reforça um progressivo desacoplamento da pesquisa científica do processo de formação de recursos humanos.

Diante destes desafios, acreditamos que a breve contextualização e revisão dos temas apresentados neste trabalho podem ser um ponto de entrada para essas e outras discussões, assim como para a apropriação de suas especificidades pela comunidade de estudiosos sobre ciência e tecnologia.

## REFERÊNCIAS

- ALKAISSI, H.; MCFARLANE, S.I. Artificial hallucinations in ChatGPT: implications in scientific writing. **Cureus**, v.15, e35179, 2023. DOI: <https://doi.org/10.7759/cureus.35179>.
- ANDERSON, C. **The end of theory**: the data deluge makes the scientific method obsolete. 2008. Disponível em: <<http://statlit.org/pdf/2008EndOfTheory-DataDelugeMakesScientificMethodObsolete-WiredMagazine.pdf>>. Acesso em: 23 jun. 2023.
- ANSEDE, M. One of the world's most cited scientists, Rafael Luque, suspended without pay for 13 years. **El País**, 2 abr. 2023. Disponível em: <<https://english.elpais.com/science-tech/2023-04-02/one-of-the-worlds-most-cited-scientists-rafael-luque-suspended-without-pay-for-13-years.html>>. Acesso em: 8 maio 2023.
- AXELROD, R. **The complexity of cooperation**: agent-based models of competition and collaboration. Princeton: Princeton University Press, 1997. 248p. DOI: <https://doi.org/10.1515/9781400822300>.
- BADILLO, S.; BANFAI, B.; BIRZELE, F.; DAVYDOV, I.I.; HUTCHINSON, L.; KAM-THONG, T.; SIEBOUG-POLSTER, J.; STEIERT, B.; ZHANG, J.D. An introduction to machine learning. **Clinical Pharmacology & Therapeutics**, v.107, p.871-885, 2020. DOI: <https://doi.org/10.1002/cpt.1796>.
- BAI, Y.; JONES, A.; NDOUSSE, K.; ASKELL, A.; CHEN, A.; DASSARMA, N.; DRAIN, D.; FORT, S.; GANGULI, D.; HENIGHAN, T.; JOSEPE, N.; KADAVATH, S.; KERNION, J.; CONERLY, T.; EL-SHOWK, S.; ELHAGE, N.; HATFIELD-DODDS, Z.; HERNANDEZ, D.; HUME, T.; JOHNSTON, S.; KRAVEC, S.; LOVITT, L.; NANDA, N.; OLSSON, C.; AMODEI, D.; BROWN, T.; CLARK, J.; MCCANDISH, S.; OLAH, C.; MANN, B.; KAPLAN, J. **Training a helpful and harmless assistant with reinforcement learning from human feedback**. 2022. Disponível em: <<https://arxiv.org/abs/2204.05862>>. Acesso em: 27 maio 2023.
- BENDER, E.M.; GEBRU, T.; MCMILLAN-MAJOR, A.; SHMITCHELL, S. On the dangers of stochastic parrots: can language models be too big? In: ACM Conference on Fairness, Accountability, and Transparency, 21., 2021, Canadá. **Proceedings**. New York: ACM, 2021. p.610-623. FACCT '21. DOI: <https://doi.org/10.1145/3442188.3445922>.
- BERGHOFF, C.; BÖDDINGHAUS, J.; DANOS, V.; DAVELAAR, G.; DOMS, T.; EHRICH, H.; FORRAI, A.; GROSU, R.; HAMON, R.; JUNKLEWITZ, H.; NEU, M.; ROMANSKI, S.; SAMEK, W.; SCHLESINGER, D.; STAVESAND, J.-E.; STEINBACH, S.; von TWICKEL, A.; WALTER, R.; WEISSENBÖCK, J.; WENZEL, M.; WIEGAND, T. Towards auditable AI systems: from principles to practice. In: INTERNATIONAL WORKSHOP "TOWARDS AUDITABLE AI SYSTEMS, 2., 2021, Berlin. **Whitepaper**. [Berlin]: Federal Office for Information Security Germany, TÜV-Verband e Fraunhofer HHI, 2022.
- BIANCHINI, S.; MÜLLER, M.; PELLETIER, P. **Deep Learning in Science**. 2020. Disponível em: <<https://arxiv.org/abs/2009.01575>>. Acesso em: 26 maio 2023.
- BLOOR, D. **Conhecimento e imaginário social**. São Paulo: Ed. da Unesp, 2009.
- BODEN, M.A. **Inteligência artificial**: uma brevíssima introdução. São Paulo: Ed. Unesp, 2020. 256p.
- BOSTROM, N. **Superintelligence**: paths, dangers, strategies. Oxford: Oxford University Press, 2014.
- BRANDON, N.; DIONISIO, K.L.; ISAACS, K.; TORNERO-VELEZ, R.; KAPRAUN, D.; WOODROW SETZER, R.; PRICE, P.S. Simulating exposure-related behaviors using agent-based models embedded with needs-based artificial intelligence. **Journal of Exposure Science & Environmental Epidemiology**, v.30, p.184-193, 2020. DOI: <https://doi.org/10.1038/s41370-018-0052-y>.
- CALLAWAY, E. 'The entire protein universe': AI predicts shape of nearly every known protein. **Nature**, v.608, p.15-16, 2022. DOI: <https://doi.org/10.1038/d41586-022-02083-2>.
- CENAN, H. What's the deal with AI, anyway? **Medium**, 2019. Disponível em: <<https://medium.com/zasti/whats-the-deal-with-ai-anyway-56a30177f438>>. Acesso em: 26 maio 2023.
- COLLINS, H.M. **Artificial experts**: social knowledge and intelligent machines. Cambridge: MIT Press, 1990. DOI: <https://doi.org/10.7551/mitpress/1416.001.0001>.
- COLLINS, H.M. **Artificial intelligence**: against humanity's surrender to computers. Cambridge: Polity Press, 2018.
- COLLINS, H.M. Computers and the Sociology of Scientific Knowledge. **Social Studies of Science**, v.19, p.613-624, 1989. DOI: <https://doi.org/10.1177/030631289019004003>.
- COLLINS, H.M.; EVANS, R.J. The Third Wave of Science Studies: studies of expertise and experience. **Social Studies of Sciences**, v.32, p.235-296, 2002. DOI: <https://doi.org/10.1177/0306312702032002003>.
- COPELAND, B.J. **Methods and goals in AI**. 2023. Disponível em: <<https://www.britannica.com/technology/artificial-intelligence/Methods-and-goals-in-AI>>. Acesso em: 26 maio 2023.
- COURTIAL, J.-P.; LAW, J. A co-word study of artificial intelligence. **Social Studies of Science**, v.19, p.301-311, 1989. DOI: <https://doi.org/10.1177/030631289019002005>.
- CRAWFORD, K. **Atlas of AI**: power, politics, and the planetary costs of artificial intelligence. New Haven: Yale University Press, 2021. DOI: <https://doi.org/10.12987/9780300252392>.

- CROITORU, F.-A.; HONDRU, V.; IONESCU, R.T.; SHAH, M. Diffusion models in vision: a survey. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v.45, p.10850-10869, 2023. Disponível em: <<https://ieeexplore.ieee.org/document/10081412/authors#authors>>. Acesso em: 1 set. 2023.
- DIXON, S. Post-Theory Science. **Lawrence University Philosophy Blog**, 2022. Disponível em: <<https://blogs.lawrence.edu/philosophy/2022/10/22/post-theory-science/>>. Acesso em: 12 nov. 2024.
- ELSEVIER. **The use of AI and AI-assisted writing technologies in scientific writing**, 2023. Disponível em: <<https://www.elsevier.com/about/policies/publishing-ethics/the-use-of-ai-and-ai-assisted-writing-technologies-in-scientific-writing>>. Acesso em: 28 maio 2023.
- ENSMENGER, N. Is chess the drosophila of artificial intelligence? A social history of an algorithm. **Social Studies of Science**, v.42, p.5-30, 2012. DOI: <https://doi.org/10.1177/0306312711424596>.
- ERCEGOVAC, Z.; RICHARDSON, J.V. Academic dishonesty, plagiarism included, in the digital age: a literature review. **College & Research Libraries**, v.65, p.301-318, 2004. DOI: <https://doi.org/10.5860/crl.65.4.301>.
- FORSYTHE, D.E. Engineering knowledge: the construction of knowledge in artificial intelligence. **Social Studies of Science**, v.23, p.445-477, 1993. DOI: <https://doi.org/10.1177/0306312793023003002>.
- FUTURE OF LIFE INSTITUTE. **Pause giant AI experiments: an open letter**, 2023. Disponível em: <<https://futureoflife.org/open-letter/pause-giant-ai-experiments/>>. Acesso em: 27 maio 2023.
- GOERTZEL, B. Artificial general intelligence: concept, state of the art, and future prospects. **Journal of Artificial General Intelligence**, v.5, p.1-48, 2014. DOI: <https://doi.org/10.2478/jagi-2014-0001>.
- GOERTZEL, B. Human-level artificial general intelligence and the possibility of a technological singularity: a reaction to Ray Kurzweil's The Singularity Is Near, and McDermott's critique of Kurzweil. **Artificial Intelligence**, v.171, p.1161-1173, 2007. DOI: <https://doi.org/10.1016/j.artint.2007.10.011>.
- GOODFELLOW, I.J.; POUGET-ABADIE, J.; MIRZA, M.; XU, B.; WARDE-FARLEY, D.; OZAIR, S.; COURVILLE, A.; BENGIO, Y. **Generative Adversarial Networks**, p.1-20, 2014. DOI: <https://doi.org/10.48550/arXiv.1406.2661>.
- GROSSMANN, I. **AI Surrogates and the Transformation of Social Science Research**, 2023. Disponível em: <<https://osf.io/h4e2a/>>. Acesso em: 27 maio 2023.
- GRUS, J. **Data science do zero: noções fundamentais com Python**. 2.ed. Rio de Janeiro: Alta Books, 2021. 336p.
- HAGSTROM, W.O. **The scientific community**. New York: Basic Books, 1965. 320p.
- HARARI, Y.N. **Homo Deus: uma breve história do amanhã**. São Paulo: Companhia das Letras, 2016. 448p.
- HU, K. ChatGPT sets record for fastest-growing user base - analyst note. **Reuters**, Feb. 2 2023. Disponível em: <<https://www.reuters.com/technology/chatgpt-sets-record-fastest-growing-user-base-analyst-note-2023-02-01/>>. Acesso em: 27 maio 2023.
- ICML. International Conference on Machine Learning. **Clarification on Large Language Model Policy LLM**, 2023. Disponível em: <<https://icml.cc/Conferences/2023/llm-policy>>. Acesso em: 28 maio 2023.
- JIANG, M.; ROCKTÄSCHEL, T.; GREFFENSTETTE, E. General intelligence requires rethinking exploration. **Royal Society Open Science**, v.10, art.230539, 2023. DOI: <https://doi.org/10.1098/rsos.230539>.
- JØRGENSEN, P.B.; SCHMIDT, M.N.; WINTHER, O. Deep generative models for molecular science. **Molecular Informatics**, v.37, art.1700133, 2018. DOI: <https://doi.org/10.1002/minf.201700133>.
- JOVANOVIĆ, M.; CAMPBELL, M. Generative artificial intelligence: trends and prospects. **Computer**, v.55, p.107-112, 2022. DOI: <https://doi.org/10.1109/MC.2022.3192720>.
- LANDHUIS, E. Scientific literature: information overload. **Nature**, v.535, p.457-458, 2016. DOI: <https://doi.org/10.1038/nj7612-457a>.
- LARIVIÈRE, V.; HAUSTEIN, S.; MONGEON, P. The Oligopoly of Academic Publishers in the Digital Era. **PLoS ONE**, v.10, e0127502, 2015. DOI: <https://doi.org/10.1371/journal.pone.0127502>.
- LATOUR, B. **Ciência em ação: como seguir cientistas e engenheiros sociedade afora**. São Paulo: Ed. da Unesp, 2000. 440p.
- LATOUR, B.; WOOLGAR, S. **A vida de laboratório: a produção dos fatos científicos**. Rio de Janeiro: Relume Dumara, 1997. 310p.
- LEE, K.-F. **AI superpowers: China, Silicon Valley, and the New World Order**. New York: Harper Business, 2018.
- LEIBO, J.Z.; HUGHES, E.; LANCTOT, M.; GRAEPEL, T. **Autocurricula and the emergence of innovation from social interaction: a manifesto for multi-agent intelligence research**, 2019. Disponível em: <<https://arxiv.org/abs/1903.00742>>. Acesso em: 27 maio 2023.
- LEONELLI, S. **Data-centric biology: a philosophical study**. Chicago: The University of Chicago Press, 2016. 275p. DOI: <https://doi.org/10.7208/chicago/9780226416502.001.0001>.

- MATTEDI, M.A.; SPIESS, M.R. A avaliação da produtividade científica. **História, Ciências, Saúde – Manguinhos**, v.24, p.623-643, 2017. DOI: <https://doi.org/10.1590/S0104-59702017000300005>.
- MENDES, V. A economia política da inteligência artificial: o caso da Alemanha, **Revista de Sociologia Política**, v.30, e003, 2022. DOI: <https://doi.org/10.1590/1678-98732230e003>.
- MERTON, R.K. **Social Theory and Social Structure**. New York: The Free Press, 1968. 702p.
- NATIONAL SCIENCE BOARD. **Publication Output by Country, Region, or Economy and Scientific Field**. 2021. Disponível em: <https://nces.nsf.gov/pubs/nsb20214/publication-output-by-country-region-or-economy-and-scientific-field>. Acesso em: 28 maio 2023.
- NATURE. Tools such as ChatGPT threaten transparent science; here are our ground rules for their use. **Nature**, v.613, p.612, 2023. DOI: <https://doi.org/10.1038/d41586-023-00191-1>.
- NOY, S.; ZHANG, W. **Experimental evidence on the productivity effects of generative artificial intelligence**, v.381, p.187-192, 2023. DOI: <https://doi.org/10.1126/science.adh2586>.
- O'NEIL, C. **Algoritmos de destruição em massa: como o big data aumenta a desigualdade e ameaça a democracia**. Santo André: Rua do Sabão, 2020.
- OLAZARAN, M. A sociological study of the official history of the perceptrons controversy. **Social Studies of Science**, v.26, p.611-659, 1996. DOI: <https://doi.org/10.1177/030631296026003005>.
- OPENAI. **GPT-4 Technical Report**. 2023. Disponível em: <https://arxiv.org/abs/2303.08774>. Acesso em: 27 maio 2023.
- PERRAKIS, A.; SIXMA, T.K. AI revolutions in biology: the joys and perils of AlphaFold. **EMBO Reports**, v.22, e54046, 2021. DOI: <https://doi.org/10.15252/embr.202154046>.
- PYPI. **Python Package Index**. Disponível em: <https://www.pypi.org>. Acesso em: 11 out. 2023.
- RICHTIG, G.; BERGER, M.; LANGE-ASSCHENFELDT, B.; ABERER, W.; RICHTIG, E. Problems and challenges of predatory journals. **Journal of the European Academy of Dermatology and Venereology**, v.32, p.1441-1449, 2018. DOI: <https://doi.org/10.1111/jdv.15039>.
- RUTHOTTO, L.; HABER, E. An introduction to deep generative modeling. **Gesellschaft für Angewandte Mathematik und Mechanik**, v.44, e202100008, 2021. DOI: <https://doi.org/10.1002/gamm.202100008>.
- SENIOR, A.; JUMPER, J.; HASSABIS, D.; KOHLI. **AlphaFold: using AI for scientific discovery**. 2020. Disponível em: <https://www.deepmind.com/blog/alphafold-using-ai-for-scientific-discovery-2020>. Acesso em: 1 jun. 2023.
- SHARIFANI, K.; AMINI, M. Machine learning and deep learning: a review of methods and applications. **World Information Technology and Engineering Journal**, v.10, p.3897-3904, 2023. Disponível em: [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=4458723](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4458723). Acesso em: 10 out. 2023.
- SIVAKUMAR, N.; MURA, C.; PEIRCE, S.M. Innovations in integrating machine learning and agent-based modeling of biomedical systems. **Frontiers in Systems Biology**, v.2, art.959665, 2022. DOI: <https://doi.org/10.3389/fsysb.2022.959665>.
- SLEZAK, P. Scientific discovery by computer as empirical refutation of the strong programme. **Social Studies of Science**, v.19, p.563-600, 1989. DOI: <https://doi.org/10.1177/030631289019004001>.
- SMITH, J.R.; MANICA, M. How generative AI models can fuel scientific discover. **IBM Research Blog**, 2022. Disponível em: <https://research.ibm.com/blog/generative-models-toolkit-for-scientific-discovery>. Acesso em: 27 maio 2023.
- SNOW, C.P. **The two cultures**. Cambridge: Cambridge University Press, 1993.
- SOKAL, A. A Physicist Experiments with Cultural Studies. **Lingua Franca**, v.4, 1996. Disponível em: [https://physics.nyu.edu/sokal/lingua\\_franca\\_v4/lingua\\_franca\\_v4.html](https://physics.nyu.edu/sokal/lingua_franca_v4/lingua_franca_v4.html). Acesso em: 10 maio 2023.
- SPINNEY, L. Are we witnessing the dawn of post-theory science? **The Guardian**, 2022. Disponível em: <https://www.theguardian.com/technology/2022/jan/09/are-we-witnessing-the-dawn-of-post-theory-science>. Acesso em: 12 nov. 2024.
- STILGOE, J. Seeing like a Tesla: how can we anticipate self-driving worlds? **Glocalism: Journal of Culture, Politics and Innovation**, v.3, p.1-20, 2017. DOI: <https://doi.org/10.12893/gjpci.2017.3.2>.
- STOKEL-WALKER, C. ChatGPT listed as author on research papers: many scientists disapprove. **Nature**, v.613, p.620-621, 2023. DOI: <https://doi.org/10.1038/d41586-023-00107-z>.
- STOKES, J.M.; YANG, K.; SWANSON, K.; JIN, W.; CUBILLOS-RUIZ, A.; DONGHIA, M.N.; MACNAIR, C.R.; FRENCH, S.; CARFRAE, L.A.; BLOOM-ACKERMANN, Z.; TRAN, V.M.; CHIAPPINO-PEPE, A.; BADRAN, A.H.; ANDREWS, I.W.; CHORY, E.J.; CHURCH, G.M.; BROWN, E.D.; JAAKKOLA, T.S.; BARZILAY, R.; COLLINS, J.J. A deep learning approach to antibiotic discovery. **Cell**, v.180, p.688-702, 2020. DOI: <https://doi.org/10.1016/j.cell.2020.01.021>.
- SUCHMAN, L. Imaginaries of omniscience: automating intelligence in the US Department of Defense. **Social Studies of Science**, v.53, p.761-786, 2023. DOI: <https://doi.org/10.1177/03063127221104938>.

THORNTON, J.M.; LASKOWSKI, R.A.; BORKAKOTI, N. AlphaFold heralds a data-driven revolution in biology and medicine. **Nature Medicine**, v.27, p.1666-1669, 2021. DOI: <https://doi.org/10.1038/s41591-021-01533-0>.

TURHAN, C.G.; BILGE, H.S. Recent trends in deep generative models: a review. In: INTERNATIONAL CONFERENCE ON COMPUTER SCIENCE AND ENGINEERING, 3., 2018, Sarajevo. **Proceedings**. Sarajevo: IEEE, 2018. p.574-579. UBMK 2018. DOI: <https://doi.org/10.1109/UBMK.2018.8566525>.

VARADI, M.; VELANKAR, S. The impact of AlphaFold Protein Structure Database on the fields of life sciences. **Proteomics**, v.23, e2200128, 2023. DOI: <https://doi.org/10.1002/pmic.202200128>.

WOOLGAR, S. Why not a sociology of machines? The case of sociology and artificial intelligence. **Sociology**, v.19, p.557-572, 1985. DOI: <https://doi.org/10.1177/0038038585019004>.

YI, H. Visualized co-simulation of adaptive human behavior and dynamic building performance: an agent-based model (ABM) and artificial intelligence (AI) approach for smart architectural design. **Sustainability**, v.12, art.6672, 2020. DOI: <https://doi.org/10.3390/su12166672>.

ZHAI, J.; ZHANG, S.; CHEN, J.; HE, Q. Autoencoder and its various variants. In: INTERNATIONAL CONFERENCE ON SYSTEMS, MAN, AND CYBERNETICS, 2018, Miyazaki. **Proceedings**. Miyazaki: IEEE, 2018. p.415-419. DOI: <https://doi.org/10.1109/SMC.2018.00080>.

ZHANG, Y.; ZHANG, R.; GU, Y.; LI, N. Multi-agent reinforcement learning with reward delays. In: ANNUAL CONFERENCE ON LEARNING FOR DYNAMICS AND CONTROL, 5., 2023, Philadelphia. **Proceedings**. [Philadelphia]: Machine Learning Research, 2023. v.211, p.1-49, 2023. Disponível em: <<https://proceedings.mlr.press/v211/zhang23c/zhang23c.pdf>>. Acesso em: 1 jun. 2023.

---