

ARTIGO

Performatividade algorítmica de gênero: estudos queer e perspectiva interseccional na crítica da inteligência artificial generativa

João Vitor Rodrigues¹

¹ Universidade do Estado do Rio de Janeiro, Rio de Janeiro, Brasil. E-mail: joao.vitor.rodrigues@uerj.br.

Resumo

A discriminação de gênero nos sistemas de inteligência artificial generativa é frequentemente tratada como problema técnico corrigível, mas essa formulação deixa intactos os pressupostos epistemológicos que o fundamentam. Articulando a teoria da performatividade de Judith Butler com o funcionamento técnico dos modelos de linguagem de larga escala, o artigo argumenta que esses sistemas não representam identidades de gênero, mas as produzem pela reiteração de padrões extraídos de *corpora* constituídos a partir de uma ontologia do gênero que não é interrogada em suas premissas. A contribuição é de ordem epistemológica e se organiza em torno do conceito de performatividade algorítmica de gênero, desenvolvido a partir dos estudos queer e da perspectiva interseccional como instrumental para interrogar as categorias que esses sistemas pressupõem ao classificar. O deslocamento proposto tem implicações para a governança algorítmica, o direito antidiscriminatório e a proteção de dados.

Palavras-chave: Performatividade algorítmica de gênero. Inteligência artificial generativa. Estudos queer

Abstract

Gender discrimination in generative artificial intelligence systems is frequently treated as a correctable technical problem, but this framing leaves intact the epistemological presuppositions that underlie it. Drawing on Judith Butler's theory of performativity and the technical workings of large language models, the article argues that these systems do not represent gender identities but produce them, through the reiteration of patterns extracted from *corpora* constituted on the basis of a gender ontology whose premises have not been interrogated. The contribution is epistemological in nature and centers on the concept of algorithmic gender performativity, developed from queer studies and intersectional

perspectives as analytical tools for interrogating the categories these systems presuppose when classifying. The proposed shift has implications for algorithmic governance, anti-discrimination law, and data protection.

Keywords: Algorithmic gender performativity. Generative artificial intelligence. Queer studies

1. Introdução

Os sistemas de inteligência artificial generativa produzem enunciados sobre o mundo social a partir de pressupostos sobre categorias humanas – entre elas, o gênero – que, em grande parte dos casos, ainda carecem de exames mais críticos. Esses pressupostos atravessam toda a arquitetura dos sistemas, desde a composição dos dados de treinamento até as camadas de abstração que determinam o que pode ser computado, constituindo em cada etapa as condições sob as quais certas existências se tornam reconhecíveis e outras não. As pesquisas mobilizadas neste artigo atestam os efeitos dessas concepções em diversas dimensões, e entre elas a que interessa a este trabalho é a das identidades de gênero. Dos sistemas de reconhecimento automático de gênero aos grandes modelos de linguagem, até as interfaces conversacionais e de geração de imagens, o que se revela na infraestrutura da inteligência artificial generativa é um padrão formalizado de operacionalização do gênero como categoria binária.

Diante desse diagnóstico, a abordagem predominante interroga como corrigir vieses discriminatórios, violentos, opressivos e excludentes sobre as identidades de gênero nos enunciados daqueles sistemas. As alternativas incluem mais dados, categorias mais representativas, auditorias periódicas, governança responsável etc. Este artigo parte da perspectiva de que a questão relevante não é se os sistemas têm vieses, mas quais premissas sobre o gênero estão inscritas em seu funcionamento e o que ocorre com quem escapa a elas. Essa distinção desloca a análise do funcionamento dos sistemas para os fundamentos que tornam esse funcionamento possível, ou seja, os pressupostos sobre o que é gênero que nenhum ajuste técnico coloca em questão. O viés, como categoria analítica, convida à correção técnica e assume que há um parâmetro correto a alcançar e um desvio a eliminar (Keyes, 2018). Quando o problema deixa de ser o viés e passa a pressupostos estruturais, a questão se revela mais crítica, pois interessa menos o que o sistema produz e mais o que já estava decidido sobre o gênero antes de qualquer enunciado.

Para abordar essa interrogação com rigor, o artigo propõe o conceito de performatividade algorítmica de gênero, articulando a teoria da performatividade de Judith

Butler (2003) com o funcionamento técnico dos sistemas de inteligência artificial generativa conversacional. O argumento central é que modelos de linguagem de larga escala, responsáveis pela formulação dos enunciados nas interfaces conversacionais de inteligência artificial generativa, não representam identidades de gênero. Em vez disso, eles as produzem pela reiteração de padrões extraídos de *corpora* constituídos a partir de uma ontologia do gênero – entendida aqui como a “busca por uma essência universal que determine todos os sujeitos que pertençam à categoria ‘mulheres’ ou à categoria ‘homens’; perspectiva tradicional, segundo a qual, sexo e gênero estão inscritos de forma fixa em cada indivíduo de acordo com uma natureza pré-conhecida” (Rosa, 2012, p.47) – que não está sendo submetida a escrutínio crítico. Demonstrar esse argumento exige examinar tanto o mecanismo técnico pelo qual essa reiteração opera quanto o aparato teórico que permite nomeá-la como performatividade e não como viés.

Esse deslocamento é sustentado pela articulação entre os estudos queer, a perspectiva interseccional e a crítica dos sistemas algorítmicos. Os estudos queer fornecem o instrumental para interrogar as categorias que esses sistemas pressupõem — o que pode ser técnica e estatisticamente reconhecido por eles e o que é produzido como ilegível ou inexistente nos processos que atravessam toda sua arquitetura. O artigo percorre esse argumento em cinco etapas, examinando o panorama empírico da discriminação algorítmica de gênero, a cadeia técnica pela qual a normatividade é operada nos sistemas e as limitações das abordagens corretivas diante dos fundamentos que deveriam questionar. Em seguida, desenvolve a contribuição dos estudos queer e da perspectiva interseccional como base para uma crítica das categorias naturalizadas no funcionamento dos sistemas, finalizando com a proposição do conceito de performatividade algorítmica de gênero com suas implicações analíticas.

2. Discriminação algorítmica de gênero: evidências e padrão estrutural

É crescente o conjunto de estudos empíricos que tem documentado como interfaces conversacionais de inteligência artificial generativa (IA generativa) reproduzem, de forma estrutural, vieses e práticas discriminatórias que incidem sobre os indivíduos que com elas interagem (Keyes, 2018; Gross, 2023; Silva, 2025; AlDahoul; Rahwan; Zaki, 2025). Essas discriminações se revelam, entre outras manifestações, na atribuição de gênero nos enunciados gerados como respostas produzidas pela interação humana com essas interfaces, acarretando danos que não são residuais, nem acidentais. Esses danos decorrem das normas de gênero inscritas nos processos de treinamento dos sistemas conversacionais de IA generativa, materializados em enunciados que reiteram discursivamente uma matriz binária, essencialista

e biologicamente determinista, que opera o gênero como categoria fixa, mutuamente exclusiva e ancorada em reducionismos fisiológicos, corroborando a exclusão de pessoas transgêneras e não-binárias.

Keyes (2018) examinou cinquenta e oito artigos científicos sobre Reconhecimento Automático de Gênero (*Automated Gender Recognition* — AGR) e demonstrou que grande parte deles operacionaliza o gênero como categoria binária, imutável após atribuição e fisiologicamente determinada a partir de características corporais externas. Além do problema de dados enviesados, essa convergência revela a epistemologia constitutiva dos modelos de linguagem incorporados aos sistemas de inteligência artificial, nos quais o gênero é formulado, desde o *design* do sistema, como algo passível de atribuição externa a um corpo. Tal premissa é estruturalmente transexcludente, independentemente da representatividade de pessoas transgêneras nos conjuntos de dados de treinamento. Como argumenta Keyes (2018), enquanto a tecnologia pressupõe que o gênero pode ser atribuído externamente a um corpo, a experiência trans parte do princípio oposto — de que o autoconhecimento, e não o reconhecimento externo, é o que define o gênero de uma pessoa.

O AGR, ao operar o gênero como dado fisiológico, não constitui um caso isolado na infraestrutura dos sistemas de inteligência artificial. A epistemologia que o organiza reaparece nos grandes modelos de linguagem como norma discursiva, conforme revelam os experimentos de Gross (2023). A autora demonstra que o ChatGPT, ao gerar texto a partir de padrões estatísticos extraídos de *corpora* produzidos em contextos heteronormativos, reitera e amplifica as normas binárias de gênero inscritas nesses dados. Em experimentos controlados, o sistema associou invariavelmente meninas a trajetórias profissionais artísticas e emocionais e meninos a carreiras científicas e tecnológicas. Em outra ocasião, análises de cartas de recomendação geradas pelo modelo revelaram tendência ao uso de linguagem de capacidade e liderança exclusivamente para candidatos classificados como homens (Gross, 2023).

No campo da geração de imagens, com base no trabalho de Buolamwini e Gebru (2018), análises do Stable Diffusion – modelo conversacional texto-imagem desenvolvido pela Stability AI – realizadas pela Bloomberg (Nicoletti; Bass, 2023) demonstraram que o sistema produz representações nas quais CEOs são brancos e masculinos e homens com pele escura são associados a contextos de criminalidade. Em outra frente, Ghosh e Caliskan (2023) verificaram que, ao ser solicitado a gerar imagens de 'uma pessoa', o Stable Diffusion produziu resultados que correspondiam predominantemente a homens brancos ocidentais, com baixíssima similaridade com pessoas de gênero não-binário e com populações de África, Ásia e povos indígenas da Oceania.

As evidências revelam que a discriminação algorítmica de gênero é muito mais um problema de formulação epistemológica do que de implementação mal executada ou de dados insuficientes. Os sistemas de IA generativa foram concebidos a partir de uma ontologia do gênero que pressupõe a binariedade como dado natural, a imutabilidade como condição técnica e a fisiologia como critério de atribuição. Essa epistemologia, constituída na ausência de quaisquer outras perspectivas das identidades de gênero, é ela mesma o mecanismo pelo qual a heteronormatividade é continuamente enunciada — e, portanto, produzida — em cada interação dos sistemas com seus usuários.

Os exemplos mobilizados até aqui apontam que desde o Reconhecimento Automático de Gênero (AGR) aos grandes modelos de linguagem dos sistemas conversacionais de IA generativa, passando pelas interfaces de geração de imagens, o que se documenta é um padrão estrutural. Nesse sentido, a binariedade de gênero é operada como dado natural e a heteronormatividade é sedimentada como norma discursiva e em favor de uma visão de mundo que reflete os contextos culturais e linguísticos dominantes nos dados de treinamento, com o apagamento, entre outros, de grupos da comunidade LGBTQIAPN+.

AlDahoul, Rahwan e Zaki (2025) demonstraram experimentalmente que o tipo de representação produzida por esses sistemas tem efeitos mensuráveis sobre quem as visualiza — imagens com estereótipos raciais e de gênero tendem a reforçar preconceitos, enquanto imagens produzidas com critérios de inclusão contribuem para atenuá-los. O mecanismo performativo não opera apenas no plano simbólico, ele produz efeitos mensuráveis sobre subjetividades. A enunciação reiterada de representações binárias de gênero tanto reflete normas preexistentes, como as reforça ativamente sobre quem interage com os sistemas conversacionais de inteligência artificial generativa. Se, para Butler (2003), o gênero é o efeito produzido pela reiteração de atos discursivos, estaríamos diante não apenas de um reflexo algorítmico das normas de gênero, mas da produção ativa dessas normas na reiteração discursiva. É precisamente essa a dimensão que o conceito de performatividade algorítmica de gênero propõe nomear e examinar.

3. A normatividade inscrita na cadeia técnica

Os mecanismos técnicos pelos quais os sistemas de inteligência artificial produzem enunciados sobre o mundo social não são neutros (Hora, 2025; Catalano, 2025). Eles resultam de uma cadeia operacional sequencial em que cada etapa condiciona e constrange as seguintes: os dados definem o que é representável; as estruturas de dados determinam como essa

representação será formalizada e quais de seus aspectos serão descartados; os algoritmos de aprendizado inferem padrões a partir dessas representações; e os modelos de linguagem de larga escala — os LLMs¹ que fundamentam sistemas como o ChatGPT, o Gemini, o Claude.AI, entre outros — generalizam esses padrões para produzir enunciados que se apresentam como respostas ao mundo, mas que são, na origem, projeções estatísticas do corpus que os constituiu (Catalano, 2025). Trata-se, portanto, de uma arquitetura em que o viés percorre toda a cadeia, amplificando-se a cada camada de abstração, sem que haja um ponto isolado onde possa ser corrigido. Dessa maneira, antes de avaliar a hipótese da performatividade algorítmica de gênero, é necessário compreender de que forma a normatividade é inscrita na própria estrutura que define o que pode ser processado e em quais condições.

Nos sistemas algorítmicos determinísticos, o programador escrevia cada regra de forma explícita, sendo a decisão integralmente humana, com a execução do algoritmo limitada. São exemplos desses sistemas o trabalho do programador que, a partir de uma lista de palavras-chave, configura as caixas de email para uma triagem das mensagens que são lixo eletrônico; ou ainda o ajuste dos semáforos nas vias de trânsito de veículos para que permaneçam em cada estágio de cor por um determinado período. Nos dois casos, existe uma entrada (*input*) e uma saída (*output*), ou seja, cada regra é executada conforme demanda, sem qualquer envolvimento com o contexto do fato. Nesse sentido, o algoritmo determinístico é “a tradução literal da vontade do programador (ou do legislador) em uma sequência de instruções imutáveis. Ele não improvisa. Ele obedece” (Hora, 2025, p.15)

No entanto, essa formulação, aparentemente descritiva, oculta uma decisão com implicações políticas que não podem ser negligenciadas. O algoritmo determinístico já operava sobre a lógica booleana², na qual toda a complexidade do universo é reduzida a dois estados, verdadeiro ou falso, 1 ou 0 (Hora, 2025). Ocorre que as disputas no campo social e na vida de cada indivíduo raramente são binárias, e é precisamente nesse ponto que a redução a dois estados passa a operar como norma de gênero, reconhecendo como existentes apenas aqueles sujeitos cujas identidades cabem nas categorias que o sistema foi projetado para aceitar. Quando o campo “gênero” em um formulário admite apenas masculino ou feminino, não se trata de uma

¹ A sigla LLM, do inglês *Large Language Model*, designa modelos de linguagem de grande escala treinados em volumes massivos de texto. Esses modelos operam por distribuição de probabilidade sobre sequências de palavras, gerando respostas que reproduzem padrões linguísticos extraídos dos dados de treinamento. Para uma descrição técnica acessível desse funcionamento, ver Hora (2025)

² A lógica booleana, desenvolvida pelo matemático George Boole no século XIX, é o fundamento formal da computação digital. Nela, qualquer problema deve ser reduzido a dois estados mutuamente exclusivos: verdadeiro ou falso, representados pelos valores binários 1 e 0. Toda operação computacional, independentemente de sua complexidade aparente, é executada a partir dessa estrutura binária elementar. Para uma descrição do funcionamento dessa lógica no contexto dos sistemas algorítmicos, ver Hora (2025).

limitação técnica contornável, mas uma decisão de design que inscreve, na arquitetura do sistema, quais sujeitos serão reconhecíveis e quais serão admitidos como inexistentes (Hora, 2025). Uma vez que a exclusão ocorre logo no início do processo de coleta e filtragem de quais tipos de dados são aceitos no sistema, esse apagamento não é efeito colateral da lógica booleana, mas, antes, sua consequência estrutural. Trata-se de um “erro de tradução” (Hora, 2025, p.16) que se evidencia quando a complexidade das experiências sociais é comprimida em uma estrutura projetada para não a comportar.

Toda operação de formalização implica perdas, uma vez que nuances, ambiguidades e especificidades da experiência social são suprimidas no processo de conversão para categorias computáveis. No caso dos sistemas algorítmicos e suas implicações no reconhecimento de identidades de gênero, contudo, essas perdas não são distribuídas aleatoriamente, pois incidem de forma sistemática sobre tudo aquilo que não cabe na matriz binária que o sistema foi projetado para reconhecer.

No estágio seguinte de desenvolvimento da IA, o *machine learning* e, de maneira ainda mais pronunciada, o *deep learning*³, que impulsionou a segunda onda da IA a partir dos anos 2000, operaram uma mudança estrutural em relação ao paradigma anterior. Se na primeira geração os sistemas eram programados com todo o conhecimento necessário, na nova abordagem essa lógica foi abandonada em favor do treinamento com exemplos. O sistema deixa de receber regras e passa a inferi-las por tentativa e erro, distinguindo respostas corretas e incorretas a partir dos padrões identificados nos dados, caracterizando a transição do aprendizado supervisionado para o não supervisionado (Catalano, 2025). São os padrões assim inferidos que subsidiam as generalizações dos modelos de linguagem das interfaces conversacionais de IA generativa disponibilizados hoje pelas grandes corporações tecnológicas.

A partir desse ponto, a interação humana com a máquina determina o abandono do processo de escrever a norma e passa a ser a de fornecer exemplos, a fim de que o sistema opere com generalização, encontre padrões e produza representações matemáticas do mundo. No aprendizado de máquina, uma vez que ao sistema é delegada a tarefa de encontrar padrões nos dados, a consequência é que o modelo de linguagem resultante do processo apreende não apenas correlações estatísticas, mas a ordem social inscrita nesses dados, produzindo inferências que a apresentam como resultado objetivo. O que se qualifica como eficiência é, nesse processo, o

³ *Machine learning* (aprendizado de máquina) designa sistemas que inferem padrões a partir de dados, sem serem explicitamente programados com regras para cada situação. *Deep learning* (aprendizado profundo) é uma vertente do *machine learning* baseada em redes neurais com múltiplas camadas de processamento, capaz de identificar padrões progressivamente mais abstratos nos dados. Foi o avanço do *deep learning* que viabilizou o desenvolvimento dos grandes modelos de linguagem a partir dos anos 2000. Para uma descrição desse processo, ver Catalano (2025, p. 196-199).

padrão estatístico cuja variável de sucesso é a reiteração do que já existia — e não a adequação às complexidades do mundo social. Se os dados de treinamento foram produzidos em um mundo no qual identidades transgêneras são constantemente sub-representadas, mal nomeadas ou classificadas por terceiros segundo as normas da cisnormatividade — a presunção de que todas as pessoas são cisgêneras e de que a correspondência entre o gênero e o sexo atribuído ao nascimento constitui o padrão natural e esperado (Vergueiro, 2015) —, o modelo que emerge desse treinamento não corrige essa distorção. Pelo contrário, aquelas identidades são imediatamente expurgadas por não serem admitidas nos padrões ditos bem-sucedidos, nem técnica, nem semanticamente para produzir os *outputs*.

Quando o resultado probabilístico de um modelo é convertido em uma decisão concreta, o sistema apresenta como fato objetivo o que é, na origem, uma generalização a partir de dados historicamente situados. É nessa conversão que reside o problema epistemológico central: a eficiência do modelo condiciona o apagamento da incerteza estatística quando aplicada a categorias sociais complexas, transformando uma dúvida em uma certeza administrativa que gera ações reais (Hora, 2025). Os modelos, tal como apropriados nos sistemas de inteligência artificial generativa, não admitem enunciar incerteza, e o corpus a partir do qual foram treinados contém categorias de partida que jamais foram submetidas a escrutínio crítico.

Toda estrutura de dados é, antes de ser técnica, uma operação política que recorta o real — seleciona o que será tornado computável e, ao fazê-lo, produz ausências tão significativas quanto as presenças que registra, por meio de escolhas que antecedem qualquer cálculo. Essas estruturas convertem-se em decisões políticas que definem quais aspectos da realidade serão aceitos e quais serão descartados (Hora, 2025). Aplicada ao gênero, essa operação tem consequências epistemológicas. Quando a categoria "gênero" é inscrita em um conjunto de dados como variável binária, estável e fisiologicamente determinável, o sistema que opera a partir desses dados não codifica apenas um modelo estatístico, mas sim uma ontologia social. A cisnormatividade não é, portanto, um viés introduzido no momento da classificação, trata-se de escolha de representação anterior ao treinamento, muitas vezes opaca aos próprios desenvolvedores, que define os limites do que o sistema será capaz de reconhecer como existente. O que não foi representado não será inferido; será, simplesmente, inexistente para o sistema.

A fase que Catalano (2025) chama de segunda primavera da IA, iniciada a partir do início da década de 2010 e intensificada ao longo dos anos seguintes, jogou luz sobre esse problema estrutural de forma ainda mais urgente ao tornar os dados mais abundantes. O avanço dos sistemas de aprendizado de máquina a partir de 2011 foi possível, entre outros fatores, pela

disponibilidade de conjuntos massivos de dados produzidos e coletados por corporações como Google, Amazon e Facebook (Catalano, 2025). Esses dados são, em sua maior parte, o registro digital de práticas sociais históricas, incluindo textos produzidos e organizados segundo categorias que espelham as hierarquias do mundo que os gerou. O GPT-3, modelo de linguagem que fundamenta o ChatGPT, foi treinado com mais de 75 *terabytes* de dados extraídos da internet (Chatterjee; Dethlefs, 2023) — um arquivo digital que é, simultaneamente, um arquivo da normatividade de gênero. Que esse corpus reproduza o binarismo cisgênero é o resultado estatisticamente esperado de um processo de coleta que não incorporou qualquer crítica às categorias com que operava.

É nesse ponto que a descrição técnica e a análise teórica convergem. Segundo Wolfram (2023), o propósito central de um LLM como o ChatGPT é gerar uma continuação textual em consonância com o contexto já estabelecido, produzindo, em cada enunciado, o texto "naturalmente" esperado por quem tivesse examinado o corpus de treinamento. Essa formulação técnica é, do ponto de vista butleriano, a descrição do mecanismo da performatividade: a reiteração de atos que, por sua repetição, produz o efeito de naturalidade e inevitabilidade da norma. Quando um modelo generativo produz associações estereotipadas de gênero — vinculando mulheres a carreiras do cuidado, homens a posições de autoridade, silenciando identidades não-binárias —, está fazendo aquilo para o qual foi treinado, ou seja, continuar o texto do mundo tal como o mundo foi registrado. A performatividade algorítmica de gênero é o funcionamento ordinário de sistemas concebidos para maximizar a coerência com um corpus que não foi interrogado quanto às suas premissas sobre o que a categoria gênero representa relacional, histórica e culturalmente.

4. Os limites das abordagens corretivas: viés como categoria analítica insuficiente

Diante dos vieses de gênero identificados nos sistemas de IA generativa — aqui considerados em sentido amplo, do reconhecimento automático de gênero às interfaces conversacionais e aos geradores de imagem — uma resposta recorrente se organiza em torno da seguinte premissa: o problema reside em dados insuficientes ou mal curados, logo, a solução estaria em identificar, monitorar e corrigir esses vieses. Essa lógica de correção que pressupõe o viés como anomalia técnica solucionável e que, como demonstra a proposta de Gross (2023), estrutura parte significativa das respostas ao problema do viés de gênero na IA generativa é precisamente o ponto onde o argumento deste artigo se distancia dessas abordagens.

Gross (2023) oferece uma síntese qualificada dessa perspectiva corretiva. Diante dos vieses de gênero demonstrados no ChatGPT, a autora propõe que os produtores dos sistemas de IA podem comprometer-se com mudanças, indicando seu potencial de "desfazer o gênero" (*undoing gender*) — expressão tomada de Butler (2004) — mediante um conjunto articulado de medidas: que os dados de treinamento incorporem a diversidade existente na sociedade; que as metodologias, fontes e limitações dos modelos sejam plenamente transparentes; que as empresas tecnológicas monitorem continuamente seus sistemas e respondam às comunidades afetadas; e que o desenvolvimento da IA seja tornado acessível e inclusivo para todos os grupos de usuários, incluindo pessoas não-binárias e de gênero diverso. A essas medidas técnicas e organizacionais, a autora adiciona uma dimensão ética e regulatória, apontando a necessidade de governança, auditorias independentes e enquadramentos legais como condições para que a IA generativa deixe de amplificar desigualdades e passe a contribuir para sua superação (Gross, 2023).

Essas propostas são, em seus próprios termos, pertinentes. Todavia, a razão que a própria autora oferece para os limites de sua abordagem é reveladora: os modelos de linguagem, em sua leitura, não fariam mais do que reproduzir os valores, normas e relações de poder inscritos no mundo social que os gerou (Gross, 2023). Gross poderia sustentar que intervenções sobre os dados, mesmo incapazes de dissolver a matriz normativa, produzem efeitos reais sobre quem sofre os danos — e isso merece ser reconhecido. O que essa resposta não resolve é a contradição que o próprio diagnóstico da autora expõe: se o sistema replica estruturas, a curadoria dos dados que o alimentam opera na superfície do problema, deixando intacta a lógica que o produz.

Keyes (2018) evidencia esse limite de forma ainda mais direta ao examinar a literatura sobre Reconhecimento Automático de Gênero. A proposta sobre a viabilidade de um sistema de AGR tecnicamente inclusivo para identidades transgêneras dissolve-se diante do próprio pressuposto que organiza a tecnologia: independentemente da abordagem adotada para distinguir entre gêneros e da representatividade de pessoas trans nos dados de treinamento, o AGR fundamenta-se na premissa de que o gênero é uma propriedade atribuível externamente a um corpo (Keyes, 2018). A experiência trans implica o reconhecimento de que é o autoconhecimento, e não a classificação por terceiros, que detém primazia na definição do gênero. A violência estrutural permanece intacta sob qualquer regime de curadoria de dados.

Os estudos queer, articulados às teorias críticas de raça e feministas, ocupam nesse quadro um papel analítico e político, pois perturbam as pressuposições sobre categorias naturais e estáveis de gênero que os sistemas de IA incorporam sem exame (Ciston, 2019). Essa perturbação não incide apenas sobre os resultados que os sistemas produzem, mas sobre os

pressupostos que tornam esses resultados possíveis. Categorias como "homem" e "mulher", tal como inscritas na arquitetura dos sistemas, não são dados que o modelo processa — são condições sem as quais ele não saberia o que classificar. O que os estudos queer propõem não é incluir mais categorias nessa estrutura, mas questionar a própria lógica que determina quais categorias podem existir dentro dela.

A interseccionalidade como instrumento de análise das estruturas de poder institucionais que produzem e organizam esses dados é admitida não apenas para diversificar categorias, mas para interrogá-las quanto às condições políticas de sua produção (Ciston, 2019), desestabilizando a premissa de que as tecnologias são instrumentos neutros a serviço de fins determináveis. É precisamente essa dimensão que as abordagens corretivas deixam fora de alcance, uma vez que o viés de gênero na IA generativa é, em sua raiz, um problema que diz respeito à ordem exterior que organiza o que pode ser sabido, nomeado e classificado pelos sistemas. É nesse plano que uma perspectiva queer e interseccional precisa intervir — e é também aí que sua contribuição se torna irreduzível a qualquer agenda de correção técnica.

5. Estudos queer e perspectiva interseccional como crítica das categorias algorítmicas

As abordagens corretivas ao viés de gênero na IA generativa falham porque operam dentro dos limites epistemológicos que deveriam questionar — propõem-se a corrigir dados, ampliar categorias, auditar parâmetros, mas deixam intacta a lógica classificatória que estrutura o problema. Dessa forma, que instrumental teórico permitiria compreender as categorias de gênero não como variáveis a corrigir, mas como efeitos de regimes de poder que os sistemas produzem e reiteram? Os estudos queer e a perspectiva interseccional oferecem, em conjunto, o instrumental teórico para responder a essa pergunta.

Os estudos queer constituem um campo de investigação cujas vertentes partilham um conjunto de orientações analíticas fundamentais que Colling (2018) sintetiza em quatro aspectos convergentes: a crítica às normas de gênero e sexualidade enquanto construções históricas naturalizadas; o exame das condições que tornam possível a proliferação de identidades múltiplas e não estáveis; a recusa de perspectivas patologizantes sobre sexualidades e gêneros; e a problematização da heterossexualidade como norma política que organiza e hierarquiza o campo do inteligível, e não como orientação entre outras. Esse conjunto converge em uma operação analítica comum que é interrogar como as categorias de gênero e sexualidade são produzidas, naturalizadas e sustentadas por regimes de poder. Tal dimensão confere aos

estudos queer relevância direta para o debate sobre IA generativa, dado que sua contribuição para esse campo se situa no questionamento das pressuposições sobre o gênero enquanto categoria social — sobre o que ele é, como é produzido e sob quais condições pode ser conhecido, nomeado e classificado pelos sistemas. Quando o AGR opera o gênero como propriedade fisiológica atribuível externamente, quando o ChatGPT associa mulheres a trajetórias emocionais e homens a posições de autoridade, quando o Stable Diffusion apaga identidades não-binárias e indígenas, o que se documenta não é um conjunto de erros corrigíveis, mas o funcionamento de sistemas que assumem, ao classificar, uma ontologia do gênero que os estudos queer interrogam em sua raiz.

A proposição de interrogar as categorias ganha ainda mais força quando articulada à perspectiva interseccional, que amplia o escopo da crítica ao examinar como sistemas de poder — racismo, capitalismo e cisheteropatriarcado — se combinam para produzir formas específicas de exclusão. Akotirene (2020) define a interseccionalidade como instrumento que visa a oferecer instrumentalidade teórico-metodológica à inseparabilidade desses três sistemas, produtores de "avenidas identitárias" (Akotirene, 2020, p.20) em que mulheres negras são repetidas vezes atingidas pelo cruzamento e sobreposição de gênero, raça e classe. Trata-se, portanto, de um marco analítico voltado para revelar a colisão dessas forças e a interação simultânea dos mecanismos de opressão, não para catalogar identidades individuais.

Ciston (2019) reforça essa dimensão ao apontar que a interseccionalidade é reduzida, em sua recepção dominante, à representação de identidades individuais descritas por sequências de categorias sobrepostas, quando seu objeto próprio é o exame e a crítica dos regimes de poder e dos modos pelos quais eles produzem impactos desiguais sobre grupos e indivíduos. Dessa forma, a implicação metodológica torna-se explícita: no contexto da infraestrutura da inteligência artificial generativa, adicionar dados sobre populações sub-representadas não dissolve o problema subjacente, podendo inclusive aprofundá-lo, na medida em que a fragmentação de usuários por categorias identitárias constitui, ela própria, um mecanismo de capitalização de dados (Ciston, 2019).

Os estudos queer interrogam a estabilidade das próprias categorias que os sistemas de poder mobilizam, operação analítica que complementa, sem substituir, a perspectiva interseccional. Se a interseccionalidade examina como estruturas de poder produzem impactos desiguais sobre sujeitos situados em posições sociais distintas (Akotirene, 2020), os estudos queer voltam sua atenção para a constituição dessas posições e questionam por que certas categorias de gênero são tratadas como naturais, estáveis e universalmente aplicáveis, e por quais mecanismos formas de existência que escapam a essas categorias são tornadas invisíveis

ou impensáveis. Essa articulação revela que as categorias de gênero inscritas nesses sistemas não são apenas insuficientemente representativas — são o produto de pressuposições sobre o que o gênero é e sobre quais formas de existência são reconhecíveis (Ciston, 2019). Questionar essas categorias significa questionar as pressuposições que fundamentam as próprias tecnologias, e não apenas os parâmetros com que operam.

Velasquez (2024) situa esse problema em sua dimensão mais ampla. O autor argumenta que a própria definição de "inteligência" operacionalizada pelos sistemas de IA corresponde historicamente ao modelo de conhecimento do homem branco ocidental. Para o autor, as formas de inteligência classificadas como “duras” — lógica e racionalidade — são mais facilmente codificáveis em estrutura tecnológica, ao passo que formas de conhecimento que a ordem generificada associou histórica e hierarquicamente a mulheres e a populações marginalizadas — como empatia, negociação e resolução criativa de problemas — resistem à codificação por razões que são antes políticas do que técnicas, permanecendo subvalorizadas no design dos sistemas. Convergente com o diagnóstico interseccional de Akotirene (2020) sobre a inseparabilidade do racismo e do cisheteropatriarcado, essa leitura situa a cisnormatividade e a discriminação algorítmica de gênero como expressões de uma epistemologia generificada e racializada que define o que conta como conhecimento válido antes mesmo que qualquer dado seja coletado — uma condição constitutiva dos sistemas, e não desvio em relação a uma neutralidade original que nunca existiu.

Entre suas contribuições, Velasquez (2024) propõe que qualquer sistema de IA que aspire a ser justo, responsável e ético deve incorporar referenciais dos estudos queer, das teorias críticas de raça e dos investimentos epistemológicos decoloniais desde as etapas iniciais de design, desenvolvimento, implantação e auditoria de vieses, as quatro fases do ciclo de vida da IA, e não como correção posterior. Isso significa intervir antes que os dados sejam definidos e antes que as categorias sejam fixadas, pois é no momento em que se pergunta o que o sistema deve reconhecer que a epistemologia opera, e é nesse momento que as perspectivas queer e interseccional precisam estar presentes.

Ciston (2019) acrescenta a essa reflexão mais uma dimensão, argumentando que comunidades cujas identidades não são geralmente categorizadas no modo de operação binária dos sistemas "podem também ajudar a engajar e subverter práticas algorítmicas normativas, atuando em múltiplas vertentes do poder infraestrutural e da privação de direitos interseccional" ["may also help engage and subvert normative algorithmic practices, operating on multiple valences of infrastructural power and intersectional disenfranchisement"] (Ciston, 2019, tradução nossa). A autora usa o termo "*passing*" para descrever esse fenômeno: a capacidade de

circular dentro de sistemas normativos sem ser completamente legível por eles. O argumento de Ciston é que essa experiência de operar nas bordas das categorias — de conhecer seus limites a partir de dentro — constitui um recurso analítico e político para questionar e subverter as lógicas classificatórias dos algoritmos. Em outras palavras, quem vive a inadequação categorial tem um conhecimento situado sobre como as categorias funcionam, onde falham e o que excluem.

Ao mesmo tempo em que não deriva desse argumento uma metodologia operacional acabada, a autora aponta quem deve ser interlocutor privilegiado no processo de design, e não apenas usuário final, o que é bastante pertinente. A controvérsia, por outro lado, é que é necessário reconhecer a tensão que esse argumento carrega: o “*passing*” não é uma prática livremente escolhida, mas uma estratégia de sobrevivência imposta pela ilegibilidade estrutural dos sistemas a pessoas cujas identidades escapam às categorias que esses sistemas reconhecem. O conhecimento situado que o “*passing*” produz emerge de uma experiência de violência e opressão, e mobilizá-lo como recurso analítico exige que se reconheça, ao mesmo tempo, que sua existência é o sintoma do problema que se quer resolver, não uma solução para ele. Essa observação ganha ainda mais peso quando se considera que os sistemas de IA generativa não oferecem, estruturalmente, o mesmo espaço de desvio que a performatividade butleriana pressupõe na experiência humana — questão desenvolvida na seção seguinte.

O conjunto dessas contribuições converge para um deslocamento analítico que organiza o argumento central deste artigo: o problema do gênero nos sistemas de IA generativa é mais do que uma questão de representação, é um problema de pressuposição. O que está em questão não é o que os sistemas ainda não reconhecem, mas o que assumem ao reconhecer. O AGR não falha por falta de dados sobre pessoas trans, mas porque pressupõe que o gênero é atribuído externamente a um corpo. O ChatGPT não associa mulheres a trajetórias emocionais por insuficiência de exemplos contrafactuais, e sim porque reitera padrões de um corpus constituído a partir de uma ontologia do gênero que precisa ser inquirida. O Stable Diffusion não apaga identidades não-binárias por acidente estatístico, mas porque opera com uma definição de pessoa que as exclui como condição de possibilidade do próprio reconhecimento. Compreender o problema do gênero na IA como questão de pressuposição, e não de representação, exige examinar a dimensão concreta desses efeitos e o mecanismo pelo qual os sistemas os produzem.

6. Performatividade algorítmica de gênero: proposta conceitual e implicações analíticas

Os sistemas de IA generativa fazem mais do que espelhar normas de gênero inscritas nos dados que os constituem — produzem-nas ativamente pela reiteração a cada enunciado gerado. Esse mecanismo encontra formulação teórica no conceito de performatividade algorítmica de gênero. Desenvolver o que esse conceito implica e o que ele permite ver exige situá-lo em relação ao aparato teórico que o fundamenta.

Para Butler (2003), o gênero não é uma identidade estável que preexiste às suas manifestações e que os sujeitos simplesmente expressam — é o efeito produzido pela reiteração de atos discursivos que, por sua repetição, criam o efeito retroativo de uma essência que nunca existiu. O que sustenta a norma não é sua verdade, mas sua reiteração, e é porque precisa ser reiterada que ela permanece vulnerável. No entanto, onde há reiteração, há também a possibilidade do desvio, da falha, da subversão. "Os vários atos de gênero criam a ideia de gênero, e sem esses atos não haveria gênero algum" (Butler, 2003).

Essa formulação encontra correspondência técnica no funcionamento dos modelos de linguagem de larga escala. O propósito central de um LLM é gerar, a cada enunciado, a continuação textualmente mais provável a partir do corpus que o constituiu (Wolfram, 2023). Trata-se, estruturalmente, de um processo de reiteração, dado que o modelo não inventa sentidos, ele os reproduz com tal consistência estatística que adquirem o efeito de naturalidade e inevitabilidade que Butler (2003) atribui à norma performativa. Quando sistemas generativos associam determinadas trajetórias profissionais e afetivas a categorias específicas de gênero, ou apagam identidades que escapam à binariedade ao produzir representações de pessoas, não estão descrevendo o mundo. Estão produzindo, a cada enunciado, o efeito de que uma ordem de gênero particular é natural e inevitável. A pergunta que o conceito de performatividade algorítmica de gênero permite formular não é se o modelo erra, mas que regime de verdade sobre identidade ele está produzindo e sob quais condições esse regime se torna cada vez mais difícil de contestar.

Há, contudo, uma diferença estrutural entre a performatividade butleriana e a performatividade algorítmica que o conceito precisa contemplar. Na obra de Butler (2003), a reiteração que sustenta a norma é também o espaço de sua subversão possível — porque o gênero é produzido por atos que precisam ser repetidos, há sempre a possibilidade do desvio, da citação deslocada, da paródia que expõe a contingência do que se apresenta como natural. Os modelos de linguagem dos sistemas de IA generativa operam na direção oposta, pois são concebidos para maximizar a coerência com o corpus e minimizar o desvio. O mecanismo que em Butler

(2003) abre para a resistência é, nos sistemas generativos, suprimido em favor da reprodução do estatisticamente esperado. A performatividade algorítmica de gênero é, nesse sentido, uma forma intensificada e tecnicamente blindada de reiteração normativa, que opera sem o atrito que, na experiência humana, torna a subversão possível. Isso significa que a escala e a velocidade da reiteração algorítmica produzem um efeito de sedimentação normativa qualitativamente distinto do que opera na experiência humana, pois enquanto a norma butleriana depende da cumplicidade renovada dos sujeitos que a reiteram, a norma algorítmica se reproduz independentemente de qualquer adesão — ela não precisa convencer, apenas continuar operando.

Essa dimensão adquire consequências que transcendem o plano simbólico quando se reconhece que os sistemas de IA generativa não são instrumentos que os sujeitos utilizam para se representar, mas sim dispositivos que participam ativamente da produção do que é reconhecível como gênero legítimo e, por essa via, dos limites dentro dos quais a identidade pode ser nomeada e reconhecida. Um sistema que produz normatividade de gênero pela reiteração produz, ao mesmo tempo, os contornos do sujeito reconhecível e, por exclusão, os limites do que não será reconhecido. AIDahoul, Rahwan e Zaki (2025) documentam a dimensão empírica desse processo ao demonstrar que a exposição repetida a imagens geradas com representações estereotipadas intensifica preconceitos de gênero e raça nos sujeitos que as visualizam, ao passo que a exposição a representações inclusivas os atenua, independentemente de as imagens serem identificadas como produzidas por IA. Esses resultados indicam que o mecanismo performativo produz efeitos mensuráveis sobre percepções e atitudes — evidência de que os sistemas não apenas refletem o mundo que aprenderam, mas participam de sua reprodução.

A performatividade algorítmica de gênero designa, portanto, o funcionamento ordinário de sistemas concebidos para maximizar a coerência com um corpus que precisa ser mais interrogado quanto às suas premissas sobre o que a categoria gênero representa em suas dimensões relacionais, históricas e políticas. Nomear o problema como viés convida à correção técnica, pois pressupõe que há um parâmetro correto a alcançar, um conjunto de dados mais representativo a substituir, uma métrica de equidade a otimizar. Nomeá-lo como performatividade desloca a questão, indo da convicção de que não se trata de corrigir o que o sistema produz, mas de interrogar o que o sistema pressupõe ao produzir. A abordagem corretiva pergunta se o modelo erra; o conceito de performatividade algorítmica de gênero pergunta que sujeito o modelo reconhece como existente e a que custo para quem escapa a esse reconhecimento. Esse deslocamento é irreduzível a qualquer agenda técnica — e é ele que

fundamenta a contribuição dos estudos queer e da perspectiva interseccional para pensar a infraestrutura de IA generativa não como objeto de correção, mas como objeto de crítica epistemológica.

Considerações Finais

Este artigo propôs que o fenômeno usualmente designado como viés de gênero em sistemas de inteligência artificial generativa não pode ser adequadamente compreendido nos termos que a perspectiva corretiva lhe oferece. Nomear esse fenômeno como performatividade algorítmica de gênero abre um campo analítico distinto, cujas consequências teóricas se desdobram em cada dimensão examinada ao longo do artigo. O mecanismo central em questão é aquele pelo qual sistemas generativos produzem, por reiteração, a realidade normativa de gênero que frequentemente descrevem como mera representação — e reconhecer esse mecanismo muda o tipo de pergunta que cabe fazer sobre esses sistemas.

Esse mecanismo se manifesta de forma particularmente visível nas interfaces conversacionais de IA generativa. Quando um sistema como o ChatGPT responde a perguntas sobre profissões, descreve personalidades ou narra trajetórias de vida, não está recuperando informações neutras armazenadas em seus parâmetros — está formulando enunciados cuja coerência interna depende de padrões que organizam o mundo segundo categorias de gênero historicamente estabelecidas. Nos modelos de linguagem de grande escala, as associações estereotipadas entre gênero e ocupação e o tratamento reducionista da experiência trans decorrem da lógica de funcionamento de sistemas que operam por maximização de probabilidades sobre *corpora* que já sedimentaram essas normas. A cada enunciado produzido, essas normas são reiteradas, conferindo-lhes uma aparência de naturalidade que apaga seu caráter histórico e socialmente construído. O gênero é produzido a cada enunciação algorítmica, no sentido butleriano da performatividade como reiteração que cria o efeito de naturalidade daquilo que apresenta como dado — e essa produção se efetua sem o atrito que, na experiência humana, abre espaço para o desvio e para a subversão da norma.

A perspectiva interseccional mobilizada permite reconhecer que os efeitos dessa performatividade incidem com intensidades distintas sobre corpos que já ocupam posições assimétricas nas estruturas de poder e que uma análise de gênero que se separe da análise de raça e classe perde precisamente os casos em que o dano é mais severo e menos visível. A contribuição proposta neste artigo é de ordem epistemológica antes de ser metodológica. O conceito de performatividade algorítmica de gênero desloca a pergunta de como mensurar e

corrigir o viés para o que esses sistemas estão fazendo quando produzem gênero. Dessa forma, encontrar respostas exige instrumentos analíticos que a tradição técnica da IA não tem condições de produzir a partir de seus próprios pressupostos. As implicações desse deslocamento alcançam a governança algorítmica, onde marcos regulatórios centrados na mitigação de vieses mensuráveis deixam intacto o mecanismo gerador; o direito antidiscriminatório, cujos instrumentos foram construídos para identificar intenções discriminatórias verificáveis, mas se mostram insuficientes diante de sistemas que produzem hierarquias de gênero por reiteração estatística, sem que haja um agente responsável por uma decisão discriminatória específica; e o campo da proteção de dados, onde a performatividade algorítmica evidencia que danos de gênero podem emergir de operações sobre dados que individualmente não contêm qualquer marcador sensível. Esses são territórios em que o diálogo com os estudos de gênero ainda está em formação, logo, o conceito aqui proposto pretende contribuir para que esse diálogo se estabeleça sobre bases analíticas mais precisas.

REFERÊNCIAS

- AKOTIRENE, Carla. **Interseccionalidade**. São Paulo: Pólen Livros, 2020. (Coleção Feminismos Plurais).
- ALDAHOUL, Nouar; RAHWAN, Talal; ZAKI, Yasir. AI-generated faces influence gender stereotypes and racial homogenization. **Scientific Reports**, v. 15, n. 14449, 2025. DOI: <https://doi.org/10.1038/s41598-025-99623-3>
- BUOLAMWINI, Joy; GEBRU, Timnit. Gender Shades: Intersectional Accuracy Disparities in Commercial Gender Classification. In: CONFERENCE ON FAIRNESS, ACCOUNTABILITY, AND TRANSPARENCY, 2018. **Proceedings of Machine Learning Research**, v. 81, p. 1-15, 2018. Disponível em: <https://proceedings.mlr.press/v81/buolamwini18a/buolamwini18a.pdf>. Acesso em: 01 fev. 2026
- BUTLER, Judith. **Problemas de gênero: feminismo e subversão da identidade**. Tradução: Renato Aguiar. Rio de Janeiro: Civilização Brasileira, 2003.
- BUTLER, Judith. **Undoing Gender**. New York; London: Routledge, 2004. (Gender Studies: Philosophy Series).
- CATALANO, José Victor Rodrigues. Trajetória da Inteligência Artificial: uma análise panorâmica de 1943 a 2023. In: IASULAITIS, Sylvia; SILVEIRA, Sérgio Amadeu da (org.). **Estudos sociopolíticos da Inteligência Artificial**. Campina Grande: EDUEPB, 2025. p. 175-220.

CHATTERJEE, J.; DETHLEFS, N. This new conversational AI model can be your friend, philosopher, and guide ... and even your worst enemy. **Patterns**, v. 4, n. 100676, ed. 1, 13 jan. 2023. DOI: 10.1016/j.patter.2022.100676. Acesso em: 10 mar. 2026.

CISTON, Sarah. *Intersectional Artificial Intelligence Is Essential: Polyvocal, Multimodal, Experimental Methods to Save AI*. **CITAR Journal**, v. 11, n. 2, Special Issue: xCoAx 2019, 2019.

COLLING, Leandro. **Gênero e sexualidade na atualidade**. Salvador: UFBA, Instituto de Humanidades, Artes e Ciências; Superintendência de Educação a Distância, 2018. 69 p.

COLLING, Leandro. Ataques recentes às perspectivas das interseccionalidades. **Periódicus**, Salvador, n. 17, v. 2, p. 51-62, jan./jun. 2022.

GHOSH, Sourojit; CALISKAN, Aylin. 'Person' == Light-skinned, Western Man, and Sexualization of Women of Color: Stereotypes in Stable Diffusion. In: **Findings of the Association for Computational Linguistics: EMNLP 2023**, Singapura, dez. 2023. p. 6971-6985. DOI: 10.18653/v1/2023.findings-emnlp.465. Acesso em: 01 fev. 2026

GROSS, Nicole. What ChatGPT Tells Us about Gender: A Cautionary Tale about Performativity and Gender Biases in AI. **Social Sciences**, v. 12, n. 435, 2023. DOI: <https://doi.org/10.3390/socsci12080435>

HORA, Nina da. **A lógica dos algoritmos: como o código molda decisões públicas**. Organização Instituto da Hora. Rio de Janeiro: Instituto da Hora, 2025. (Cadernos da Hora. A camada lógica, v. 1). E-book.

KEYES, Os. The Misgendering Machines: Trans/HCI Implications of Automatic Gender Recognition. **Proceedings of the ACM on Human-Computer Interaction**, v. 2, n. CSCW, Artigo 88, nov. 2018. DOI: <https://doi.org/10.1145/3274357>

NICOLETTI, Leonardo; BASS, Dina. **Humans are biased. Generative AI is even worse: Stable Diffusion's text-to-image model amplifies stereotypes about race and gender — here's why that matters**. Bloomberg, 9 jun. 2023. Disponível em: <https://www.bloomberg.com/graphics/2023-generative-ai-bias/>. Acesso em: 01 fev. 2026

ROSA, Patricia. Gênero: performativo ou ontológico? **Revista PERI**, Florianópolis, v. 4, n. 1, p. 46–56, 2012.

SILVA, Tarcízio (ed.) et al. **Mapeamento de Danos e Discriminação Algorítmica**. Desvelar, 2025. Disponível em: <https://desvelar.org/casos-de-discriminacao-algoritmica/>. Acesso em: 25 fev. 2026

VELASQUEZ, Umut Pajaro. Queering AI: uma epistemologia queer para a IA com uma perspectiva de maioria global. **Internet & Sociedade**, v. 5, n. 1, p. 56-70, jul. 2024.

VERGUEIRO, Viviane. **Por inflexões decoloniais de corpos e identidades de gênero inconformes: uma análise autoetnográfica da cisgeneridade como normatividade**. 2015. Dissertação (Mestrado) — Instituto de Humanidades, Artes e Ciências Professor Milton Santos, Universidade Federal da Bahia, Salvador, 2015. Disponível em: <https://repositorio.ufba.br/handle/ri/19685>. Acesso em: 31 mar. 2026.

WOLFRAM, S. **What Is ChatGPT Doing ... and Why Does It Work?** 1. ed. Champaign, IL: Wolfram Media Inc, 2023. 102 p.