

# MACHINE LEARNING: EVIDÊNCIAS OU ALQUIMIA EM POLÍTICAS PÚBLICAS NO BRASIL?<sup>1</sup>

Fernando Filgueiras<sup>2</sup>

## SINOPSE

O uso de algoritmos de *machine learning* se torna crescentemente presente no ciclo das políticas públicas. Operando grandes bases de dados, estes algoritmos produzem novas formas de racionalização do processo decisório, do desenho, da implementação e da avaliação dessas políticas, otimizando diversas facetas do seu processo mais amplo. Um dos argumentos em que se assenta o uso desses algoritmos na condução das políticas é o fato de eles facilitarem o trabalho com evidências, uma vez que operam grandes bases de dados. Neste artigo nós argumentamos que a crescente aplicação de *machine learning* no ciclo das políticas públicas não é condição suficiente para ampliar práticas baseadas em evidências. Dada a natureza e os atributos das dinâmicas de desenho de algoritmos de *machine learning*, defendemos que eles não produzem evidências, mas figurações do mundo baseadas em dados. Assim, traçamos uma conclusão sobre que tipos de capacidades são requeridas para o trabalho com inteligência artificial e seus desdobramentos na gestão pública.

**Palavras-chave:** *machine learning*; evidências; capacidades analíticas; inteligência artificial; epistemologia.

## 1 INTRODUÇÃO

Processos de transformação digital são fortemente conduzidos com a presença de algoritmos de *machine learning*. Quando aplicados ao ciclo de políticas públicas, esses algoritmos provocam mudanças disruptivas no modo de fazer e pensar o processo de formulação, tomada de decisão, implementação e avaliação dessas políticas (Valle-Cruz *et al.*, 2020). Havendo máquinas inteligentes que interagem com humanos na condução das políticas, produzem-se mudanças epistêmicas entre *policymakers*, transformando a maneira como eles refletem e pensam o trabalho das políticas públicas e os parâmetros de ação governamental.

A discussão sobre inteligência artificial, entretanto, tem sido baseada em hipérboles (Car *et al.*, 2019), ou em uma perspectiva de riscos existenciais para a humanidade (Vold e Harris, 2021). Tal discussão apoia-se em retóricas, tanto no sentido da hipérbole de seu poder para beneficiar a humanidade, quanto dos riscos globais que ameaçam a própria existência humana. Entre esses argumentos retóricos, no campo das políticas públicas, afirma-se que o uso de inteligência artificial, especialmente a de algoritmos de *machine learning*, produz políticas públicas baseadas em evidências e, assim, amplifica as capacidades estatais.

1. DOI: <http://dx.doi.org/10.38116/bapi37art12>

2. Professor associado da Universidade Federal de Goiás (UFG) e professor do Programa de Pós-Graduação em Ciência Política e Relações Internacionais da UFG; professor do Programa de Doutorado Profissional em Políticas Públicas da Escola Nacional de Administração Pública (Enap); pesquisador afiliado no Ostrom Workshop in Political Theory and Policy Analysis, da Indiana University; pesquisador do Instituto Nacional de Ciência e Tecnologia (INCT) em Democracia Digital; bolsista de Produtividade do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq); doutor em ciência política pelo Instituto Universitário de Pesquisas do Rio de Janeiro (IUPERJ); e consultor no âmbito do Programa de Cooperação entre a Comissão Econômica para a América Latina e o Caribe (CEPAL) e o Instituto de Pesquisa Econômica Aplicada (Ipea). E-mail: fernandofilgueiras@ufg.br.

Circunstanciando a discussão sobre inteligência artificial entre a hipérbole e os riscos existenciais, o objetivo deste artigo é enfrentar a seguinte questão: os algoritmos de *machine learning* produzem decisões e ação governamental baseadas em evidências? Ou eles significam apenas uma figuração factual do mundo que transforma as bases epistêmicas das políticas públicas, mas sem mudanças que sejam realmente disruptivas? Iniciamos essa empreitada na seção 2 examinando os algoritmos de *machine learning*. Nas seções 3 e 4, discutimos as escolhas de arquitetura e os dilemas de desenho de algoritmos. Na seção 5, examinamos seu uso e aplicação no ciclo das políticas. Por fim, na seção 6, concluímos questionando alguns desafios para o desenho de algoritmos e sua aplicação no setor público.

## 2 FUNDAMENTOS DE MACHINE LEARNING E SEU ALCANCE NA SOCIEDADE

Algoritmos são um conceito fundamental da ciência da computação (Knuth, 1968). Eles podem ser descritos como sequências de instruções ou etapas definidas para resolver um determinado problema, tarefa ou cálculo. O estudo e o uso de algoritmos são multidisciplinares e têm despertado o interesse de pesquisadores de praticamente todas as áreas da ciência, desde ciência da computação, matemática e engenharia até ciências sociais. Os cientistas da computação e engenheiros tendem a focar seu trabalho no desenho e análise de algoritmos, determinando sua eficiência, correção e otimização de uma perspectiva técnica.

Nos últimos anos, um progresso notável ocorreu com os algoritmos (Russell e Norvig, 2010). O desenvolvimento de algoritmos avançados está associado à evolução da capacidade computacional e à proliferação de *big data*. *Big data* diz respeito ao grande volume de dados que são coletados em diferentes fontes, compreendendo números, imagens, fala e textos, e armazenados e processados de maneira veloz em função da expansão da internet (Ekbja *et al.*, 2014; Kitchin, 2013).

A emergência de *big data* possibilitou reconstruir a área de inteligência artificial e otimizar a presença de algoritmos de *machine learning* para resolver diferentes problemas. Em vez de especificar passo a passo regras e rotas que os algoritmos tradicionais seguem, os algoritmos de *machine learning* são *softwares* que aprendem com exemplos, dados e experiências (Samuel, 1959). Eles calculam funções de aprendizado e são capazes de aprender com os dados para classificar, hierarquizar ou agrupar diferentes objetos de interesse. Os algoritmos de *machine learning* fazem parte de uma família de métodos de inteligência artificial que incluem aprendizado profundo e aprendizado por reforço (Kelleher, 2019).

Essencialmente, um algoritmo de *machine learning* recebe dados como entrada e produz um modelo que representa os padrões que o algoritmo aprendeu com esses dados (Samuel, 1962). Com base na estatística e na teoria da probabilidade, esses algoritmos geram resultados com algum grau de incerteza sobre o que é útil ou ideal.

O aprendizado de máquina abrange duas etapas, a de treinamento e a de inferência, sendo o processo de treinamento organizado em três grupos. No caso de aprendizado de máquina supervisionado, um sistema é treinado com dados que foram previamente rotulados. O sistema então usa essas informações para prever as categorias de dados novos ou de teste (Kelleher, 2019). Quando nenhum dado é rotulado, o aprendizado não supervisionado tenta detectar funções que mapeiam exemplos semelhantes em *clusters*. O aprendizado por reforço, por seu turno, concentra-se em aprender com a experiência e situa-se entre o aprendizado não supervisionado e o supervisionado, fazendo com que

a estrutura do algoritmo trabalhe com *feedbacks* proporcionados pela interação entre humanos e máquinas. Algoritmos de *deep learning* – um subcampo de algoritmos de *machine learning* – são redes neurais artificiais inspiradas em *insights* extraídos da fisiologia e da neurociência (Kelleher, 2019).

A ciência da computação reconhece que os sistemas algorítmicos são agentes – em muitos casos, multiagentes – que executam várias ações em conjunto. Winston (1992), por exemplo, define algoritmos de inteligência artificial como o campo de estudo baseado em métodos que tornam possível perceber, raciocinar e construir conhecimento, de forma a modificar e racionalizar a ação. Russell (2019) define sistemas algorítmicos baseados em inteligência artificial como agentes que percebem um fluxo de entradas e produzem um fluxo de saídas para realizar um objetivo.

Essa condição de agência é atribuída aos algoritmos por meio de regras e procedimentos embutidos em seus códigos complexos. Além disso, a condição de agência deriva da capacidade dos algoritmos de gerar conhecimento sobre um determinado objeto. Eles são, portanto, agentes epistêmicos cuja ação depende dos dados para tomar uma decisão ou realizar uma tarefa (McCarthy, 1981). Porém, algoritmos de *machine learning* são agentes epistêmicos que realizam tarefas por meio de funções de aprendizado baseadas em recursos heurísticos. Dessa maneira, incertezas e informação incompleta são constitutivas de inteligência artificial, a qual busca a simplificação do conhecimento sobre questões complexas (Simon, 1995).

Algoritmos de recomendação, algoritmos de identificação de imagens, mecanismos de busca, algoritmos de roteamento e “agentes” digitais são exemplos de algoritmos que limitam ou eliminam a necessidade de envolvimento humano em algumas tarefas porque eles moldam decisões ou tarefas a partir dos dados de entrada e são capazes de automatizar a ação. Algoritmos são constituídos em instalações de fronteira, por exemplo, para substituir decisões humanas em operações de segurança (Amoore, 2021). Da mesma forma, algoritmos de *credit score* são usados para avaliar a adequação de um solicitante de empréstimo ou outras operações comerciais e de controle social usadas pelo Estado (Dai, 2020).

O fato é que algoritmos de inteligência artificial estão no centro das mudanças sociais vigentes, com diferentes consequências para a sociedade e para a democracia (Frischmann e Selinger, 2018). Isto ocorre porque algoritmos definem situações, *scripts* e *frames* para a ação social, instrumentalizando novas racionalidades que emergem das interações entre humanos e máquinas (Mendonça, Filgueiras e Almeida, 2023). Esta racionalidade está associada a mudanças epistêmicas que acontecem na dimensão social, tendo em vista novas dinâmicas de construção do conhecimento e novos mecanismos de mediação que surgem com algoritmos aplicados a diferentes campos da vida coletiva, em particular em governos.

No campo das políticas públicas, algoritmos de *machine learning* podem ter aplicações diversas, com potencial para aprimorar as capacidades analíticas relacionadas à construção de conhecimento e ao uso de evidências. Porém, existem limitações e impactos ainda não mensurados que surgem de uma aceitação acrítica de algoritmos de *machine learning* na construção de políticas públicas. Em muitas situações, esses algoritmos podem representar processos de alquimia na construção do conhecimento em políticas públicas, impactando em muitos aspectos a sociedade.

### 3 EVIDÊNCIAS E MACHINE LEARNING

A capacidade de resposta a problemas públicos melhora quando formuladores de políticas usam evidências para apoiar a tomada de decisão. O uso de evidências amplia as capacidades estatais de maneira que a capacidade analítica de formuladores de políticas públicas favorece soluções baseadas em problemas reais, com a qualidade de resposta informada e intervenções que surgem de maneira sincronizada com os problemas identificados, possibilitando simulação, antecipação e melhoria do processo decisório. Capacidades analíticas fortalecem as capacidades estatais mais amplas, possibilitando aos governos construir respostas mais sólidas para os problemas públicos (Koga *et al.*, 2023; Carney, 2016). Capacidades analíticas, por sua vez, requerem de formuladores habilidades para o trabalho com evidências em políticas públicas.

Políticas públicas baseadas em evidências compreendem um movimento a respeito da importância do uso de evidências para apoiar a produção de políticas públicas. Há um pressuposto de racionalidade instrumental, a partir do qual uma noção restrita de evidência é instrumento para a tomada de decisão, desconsiderando o processo político embutido na seleção de quais evidências, enquadramento e narrativa são empregados para atingir um fim (Carney, 2016; Parkhurst, 2017). O pressuposto inscrito nessa concepção instrumental é de que formuladores, ao usarem evidências, constroem uma epistemologia científica das políticas públicas, tal como imaginada por Lasswell (1971).

Uma mirada mais política e baseada em processos de racionalização, que estão além de uma visão instrumental, considera que o trabalho das políticas públicas utiliza evidências em uma concepção mais larga, amparada em diferentes fontes e usos que estão além de uma racionalidade instrumental. Evidências não se baseiam apenas em dados crus, mas compreendem textos, falas em contextos deliberativos, imagens e processos administrativos (Koga *et al.*, 2022a). Esta concepção surge de uma perspectiva mais pragmática e construtivista das políticas públicas, assentada no fato de que a resolução de problemas públicos é orientada pelo envolvimento, discurso e trocas entre os diferentes atores no processo de produção dessas políticas.

Ou seja, o conceito de evidências não é consensual no campo de conhecimento das políticas públicas. Embora haja esse dissenso, a discussão sobre políticas públicas baseadas em evidências ganha um novo personagem no processo de instrumentalização da tomada de decisão. O imaginário de Lasswell de uma epistemologia científica das políticas públicas ganhou um enorme reforço com o surgimento de *big data* e o uso crescente de inteligência artificial, especialmente de algoritmos de *machine learning* (El-Taliawi, Goyal e Howlett, 2021). O uso de dados em políticas públicas para alimentar sistemas de inteligência artificial baseados em *machine learning* cria uma nova epistemologia que sustenta o trabalho de *policymakers*. Essa nova epistemologia compreende a ideia de que o emprego desses sistemas amplifica as capacidades analíticas do setor público e, por sua vez, a sustentação do processo decisório em evidências (Dunleavy e Margetts, 2013). *Policymakers*, tendo o trabalho otimizado para produzir políticas públicas, atuam em um imaginário positivista como *engenheiros sociais*, criando intervenções informadas por sistemas de conhecimento baseados em algoritmos de *machine learning*.

A motivação deste texto é exatamente discutir esse corolário do uso de evidências com algoritmos de *machine learning*. A emergência e difusão da inteligência artificial no setor público

criou o imaginário de que todo o processo decisório de políticas públicas é sustentado em uma concepção larga de evidências.

#### 4 CIÊNCIA OU ALQUIMIA?

Uma visão puramente positivista das políticas públicas pode compreender a ideia de que o desenho de uma política pública envolve o conhecimento de um problema, o conhecimento de uma solução e a construção de intervenções governamentais na sociedade, as quais são implementadas institucionalmente para realizar um objetivo. Tanto a formulação quanto a implementação de uma política pública dependem de um sistema de conhecimento, em que evidências contribuem em todas as fases do ciclo de políticas públicas. Neste corolário, capacidades analíticas dos formuladores são fundamentais tanto para conhecer os problemas quanto para formular e implementar uma política (Koga *et al.*, 2023).

Algoritmos de *machine learning* têm o potencial de aprimorar essas capacidades analíticas e, assim, podem ser incorporados em todas as fases do ciclo de políticas públicas (Valle-Cruz *et al.*, 2020; Porciello *et al.*, 2020). Na identificação dos problemas e da agenda, eles permitem que governos analisem dados provenientes de mídias sociais e construam perspectivas sobre a atenção dada pelos cidadãos a problemas (Giest, 2017). No que diz respeito à formulação, algoritmos de *machine learning* podem, de forma a incorporar todo o desenho da política, realizar diferentes tarefas e apoiar a tomada de decisão. Na implementação de políticas públicas, podem executar tarefas diferentes relacionadas ao estado de bem-estar social (Coles-Kemp *et al.*, 2020) e implementar ações de policiamento preditivo e diversas tarefas da política de segurança (Meijer e Wessels, 2019), por exemplo.

Nessas diversas situações podemos argumentar que algoritmos de *machine learning* aprimoram as capacidades analíticas do Estado porque incorporam, antes de qualquer coisa, um sistema de conhecimento e aprendizagem automatizado que molda todo o ciclo das políticas públicas. São algoritmos que entregam atividades analíticas baseadas em dados de forma mais rápida e eficiente (Giest, 2017), além de criarem uma perspectiva científica das políticas públicas, supostamente realizando o imaginário de Lasswell. Eles produzem, ainda, novos *frames* para a institucionalização governamental e ação de formuladores de políticas públicas em contextos variados (Mendonça, Filgueiras e Almeida, 2023). Em outras palavras, algoritmos de *machine learning* têm o potencial para criar uma mudança epistemológica das políticas públicas, mudando toda a estrutura de conhecimento e aprendizado utilizada por formuladores e implementadores de políticas (El-Taliawi, Goyal e Howlett, 2021). Argumenta-se que algoritmos estão transformando diversos aspectos organizacionais do Estado, criando um processo de “algoritmização” da burocracia (Meijer, Lorenz e Wessels, 2021).

Essa mudança epistemológica decorre do fato de que a inteligência artificial é uma ferramenta potente para conhecer e agir, funcionando como mecanismo de racionalização que facilita a eficiência e eficácia do serviço público, associado à maior velocidade de produção da informação. Além disso, essa mudança decorre de várias políticas difundidas por organizações internacionais que influenciam o conhecimento dentro das burocracias estatais, com destaque para a OECD (2014). Nesse contexto de mudança epistêmica, criou-se um imaginário otimista de que o método de *machine learning* amplifica o uso de evidências. Entretanto, esse processo em políticas públicas não seria, na verdade, uma alquimia?

Ali Rahimi, um pesquisador de inteligência artificial da Google, afirmou em uma conferência que algoritmos de *machine learning* representam não uma atividade puramente científica, mas uma forma de alquimia. Alquimia é uma pseudociência da antiguidade que buscava a fusão de metais em ouro, o elixir da vida e a pedra filosofal. Segundo Rahimi, pesquisadores e *designers* de algoritmos de *machine learning* não têm critérios rigorosos para a escolha de uma arquitetura de inteligência artificial sobre outra – visto que não existem padrões para a escolha dos dados de entrada – e sofrem de problemas de reprodutibilidade que impedem que outros pesquisadores ou reguladores testem esses sistemas em função de práticas experimentais inconsistentes (Hutson, 2018).

Além dos problemas de reprodutibilidade, algoritmos de *machine learning* não são transparentes com relação à forma como processam dados e constroem informação; são produtos industriais prontos, aplicados com diversos propósitos, mensurados em termos de um objetivo prático e não do processo. Ademais, são opacos com relação aos procedimentos adotados, não permitindo, assim, controle de suas operações aplicadas em diversos campos da sociedade (Pasquale, 2015). Sem que sejam transparentes, algoritmos de *machine learning* não são passíveis de responsabilização pelos cidadãos (Binns, 2018), e não possibilitam formas de aprendizado que permitam alterar seus termos. Ao contrário disso, algoritmos de *machine learning* incorporam todo o sistema de conhecimento e produzem as suas próprias formas de aprendizado – supervisionado ou não –, sem permitir a formuladores construir mecanismos de *feedback* para além daqueles que já estão incorporados na forma de dados.

Assim, algoritmos de *machine learning* espelham mais uma prática de alquimia do que um trabalho científico rigoroso. E aplicados em políticas públicas, é difícil sustentar que o ambiente de evidências seja melhorado e possa incidir na produção de políticas. Afirmar que algoritmos de *machine learning* facilitam a produção de evidências e, por sua vez, as capacidades analíticas do Estado pode nos fazer incorrer em oximoros que, na prática, não se fundamentam. Isto porque dados não são neutros. Como um objeto de conhecimento que classifica ou hierarquiza coisas ou pessoas, dados podem ser elementos que produzem vieses analíticos, hierarquias sociais ou distorções no entendimento das coisas (Gitelman e Jackson, 2013).

Aplicados em sistemas de inteligência artificial, bases de dados enviesadas podem produzir toda sorte de injustiça algorítmica, fazendo com que a estrutura de conhecimento reflita desigualdades as mais diversas, no campo racial (Benjamin, 2019; Noble, 2018), de gênero (Joyce *et al.*, 2021), ou toda sorte de desigualdades sociais que punem os mais pobres (Eubanks, 2018). O relatório de Philip Alston, no âmbito da Assembleia Geral da Organização das Nações Unidas, mostra como os governos em todo o mundo transformaram silenciosamente a dinâmica de acesso aos direitos sociais por meio de algoritmos de *machine learning*, criando a necessidade de um novo corpo de direitos – direitos digitais – para proteger as pessoas mais vulneráveis diante do *digital welfare state* (Alston, 2019). Exemplos abundam nessa direção.

No Brasil, tais exemplos também são abundantes. O Instituto Nacional do Seguro Social (INSS) centraliza as políticas de proteção social com especial ênfase no sistema de aposentadorias e benefícios sociais. Como resposta para o aumento de demanda da sociedade para concessão e revisão de benefícios sociais, o INSS passou a adotar algoritmos de *machine learning* que analisem os requerimentos. Em outras palavras, um algoritmo de *machine learning* analisa o requerimento textual e os dados de registros administrativos do INSS para conceder ou não o benefício. Em estimativa do Tribunal de Contas da União (TCU), cerca de 60% dos pedidos são recusados sem análise de

mérito, criando, na expressão do ministro Aroldo Cedraz, um sistema de “desproteção social” no Brasil. Segundo o ministro, em decisão exarada em acórdão do TCU, “é essencial que algoritmos sejam validados de forma criteriosa, com seus resultados sendo submetidos à revisão humana pelo período necessário para se obter segurança de que não existem falhas detectáveis que possam trazer prejuízo a qualquer das partes” (Brasil, 2023, p. 22).

De forma geral, algoritmos transformam as ideias por trás das políticas de proteção social. O uso extensivo de algoritmos de *machine learning* na proteção social cria uma perspectiva liberal restrita de concessão de benefícios e uma concepção ambígua atrelada à desconfiança. Ou seja, uma concepção que se concentra na auditoria dos benefícios e desmantelamento da efetividade da proteção, em uma tendência mundial de desmantelamento do estado de bem-estar por meio da digitalização (Collington, 2022). O que fica visível é que as mudanças epistêmicas do trabalho com as políticas públicas, que surgem com a instrumentalização de *machine learning*, estão centradas em ideias, perspectivas e enquadramentos de um mundo produzido artificialmente, voltado para a racionalização das políticas. Em outras palavras, o desenho de algoritmos é movido por ideias e enquadramentos que buscam um conhecimento baseado em dados como instrumento que justifique mudanças a partir de um objetivo – político – determinado (Mendonça, Filgueiras e Almeida, 2023).

Esse exemplo ilustrativo nos indica alguns caminhos a adotar quando algoritmos de *machine learning* são utilizados no ciclo das políticas públicas como produtores de evidências. O fato de estas tecnologias trabalharem com grandes volumes de dados não é uma condição suficiente para afirmarmos que *machine learning* expande a disponibilidade de evidências para a tomada de decisão em políticas públicas. Esses grandes volumes e diversidade de dados podem acelerar o uso de informações diversas que, por sua vez, podem ser captadas de diferentes formas. Entretanto, os problemas de *design* da tecnologia e as escolhas que os *designers* fazem com relação aos conjuntos de dados que serão utilizados, assim como a arquitetura analítica do algoritmo, borram as fronteiras entre ciência e alquimia, requerendo mecanismos de governança das inteligências artificiais e de controle de seus efeitos na sociedade. Em diversas situações, inteligências artificiais são aplicadas sem que seja possível calcular um curso de ação a partir de dados.

## 5 INTUIÇÃO E PRÁTICA

Segundo Amoore (2014), o trabalho com a inteligência artificial, especialmente os algoritmos de *machine learning*, requer um outro tipo de capacidade dos *designers*, mais imaginativa e intuitiva. Esse corolário de Amoore (2014), baseado nas críticas de Wittgenstein (1972) a Turing (1950), apoia-se no fato de que, em muitas situações, sistemas são feitos para calcular o incalculável, demandando mais um trabalho com a automatização do cálculo e imaginação da rotinização de procedimentos que incidam diretamente no mundo real. Algoritmos, assim, têm incorporados em si uma intuição matemática que traz uma série de efeitos políticos, demandando dos *designers* de sistemas uma nova capacidade: a imaginação.

Aplicados a políticas públicas, algoritmos de *machine learning* não produzirão, por si, evidências a respeito de um problema ou tarefa, mas mecanismos de otimização que se baseiam mais em um uso intuitivo de informações para imaginar futuros possíveis. Imaginar futuros possíveis com o apoio de previsões e simulações feitas por sistemas baseados em *machine learning* possibilita lidar com o incalculável e projetar o redesenho de políticas e recomposição de seus objetivos.

Seguindo o argumento aqui traçado, podemos dizer que sistemas de *machine learning* não trabalham e nem incrementam o trabalho com evidências em políticas públicas, embora sejam revestidos de cálculos matemáticos variados e um processo de racionalização organizacional e política. Em outras palavras, o aprendizado de máquina aplicado para produzir evidências em políticas públicas tem efeitos políticos diversos, que precisam ser mapeados na forma de riscos ao funcionamento de sistemas que sustentem a tomada de decisão e a realização de tarefas. O *insight* da imaginação e intuição como uma capacidade de formuladores não nos permite afirmar a construção de uma concepção científica das políticas públicas, mas a coexistência de um sistema político que incorpora sistemas sociotécnicos diversos que são capazes de alterar e instrumentalizar vários aspectos da sociedade por meio da interação entre humanos e máquinas.

Considerar esse caminho de uma capacidade imaginativa e intuitiva de gestores é, talvez, a grande mudança que sistemas de inteligência artificial incutem no conhecimento de formuladores e implementadores de políticas públicas, operando entre o trabalho com evidências, em um sentido mais largo, e a busca pela pedra filosofal, à medida que sistemas sociotécnicos aceleram transformações e práticas dentro do setor público.

## 6 CONCLUSÃO: ENTRE CIÊNCIA E ALQUIMIA, AS EVIDÊNCIAS EM POLÍTICAS PÚBLICAS

Sistemas de *machine learning* têm produzido mudanças epistemológicas e práticas relacionadas à produção de políticas públicas. As mudanças que hoje ocorrem no conhecimento sobre políticas públicas criam um novo paradigma epistêmico de *policy science* decorrente da emergência de novas tecnologias e crises correlacionadas, estando esse novo paradigma atrelado a mudanças teóricas e práticas (Hartley e Kuecker, 2022).

A partir de grandes volumes de dados que governos coletam e armazenam cotidianamente, as possibilidades para criar aplicações que incidam diretamente no processo das políticas são diversas e variadas, sustentadas em informações produzidas a partir de dados. Mas a diversidade de algoritmos e de aplicações possíveis com *machine learning* não necessariamente permite sustentar a expansão e o uso de evidências em políticas públicas. Ter mais dados disponíveis não significa, necessariamente, mais evidências. Evidências requerem processamento e a construção de informações que podem ser testadas, falseadas e controladas para atingir um objetivo de conhecimento. Evidências requerem, portanto, procedimentos rigorosos com relação à coleta e ao processamento de dados para atingir o objetivo proposto.

*Machine learning* dispensa esses procedimentos de coleta e processamento, como uma teoria do processo de políticas públicas em que, em um passe de mágica, algoritmos aprendem a partir de bases de dados de treinamento e produzem, com esse conhecimento alquímico, efeitos diversos na sociedade, com diretrizes mais políticas e intuitivas do que científicas. O incalculável, seguindo Amoore (2014), faz com que a intuição seja essencial, empacotada como uma capacidade nova quando algoritmos de *machine learning* são difundidos no setor público como uma solução à procura de problemas. Mais do que isso, *machine learning* oferece opções plausíveis para prever ou simular alternativas, mas não necessariamente evidências, ainda mais se considerando mudanças e crises epistêmicas que são moldadas no cenário político em função de tecnologias disruptivas (Hartley e Kuecker, 2022; Benkler, Faris e Roberts, 2018). Inteligência artificial é uma forma de entendimento da intuição (Frantz, 2003).

Lasswell (1971, p. 444) argumentou que “o computador de alta velocidade tem sido (...) uma ferramenta revolucionária. Com efeito, permite que um ponto de vista contextual e multivalorado (‘filosófico’) passe da fantasia e da exortação à realidade”. O imaginário positivista de Lasswell (1971) não permitiu conceber que mudanças em *policy science* decorrem de um mundo mais imprevisível, crítico e impensável, e que mesmo computadores abastecidos com algoritmos de *machine learning* podem errar quando dados não necessariamente produzem informação. Ao contrário do imaginário de Lasswell, algoritmos de *machine learning* rompem com a epistemologia de *policy science* ao introduzir uma nova forma de conhecimento baseada em tentativas e erros, artesanato com dados e intuições matemáticas.

Não por acaso, a disrupção contemporânea em políticas públicas exige de formuladores mais experimentação, tentativa e erro e processos de governança de tecnologias emergentes que ainda não estão definidos e empacotados *a priori* (Filgueiras e Raymond, 2023). Tecnologias disruptivas como inteligência artificial não desafiam as capacidades administrativas, gerenciais, políticas e relacionais. Elas desafiam a imaginação e a intuição de burocratas para lidar com problemas complexos e produzir soluções plausíveis mais inclusivas, justas e democráticas.

## REFERÊNCIAS

- ALSTON, P. **Extreme poverty and human rights**: note by the Secretary-General. New York: UN, 11 Oct. 2019. 23 p. (Report of the Special Procedure of the Human Rights Council). Disponível em: <https://digitallibrary.un.org/record/3834146?ln=en>.
- AMOORE, L. Security and the incalculable. **Security Dialogue**, v. 45, n. 5, p. 423-439, 2014. Disponível em: <http://dx.doi.org/10.1177/0967010614539719>.
- \_\_\_\_\_. The deep border. **Political Geography**, v. 96, p. 1-9, 2021. Disponível em: <https://doi.org/10.1016/j.polgeo.2021.102547>.
- BENJAMIN, R. Assessing risk, automating racism. **Science**, v. 366, n. 6464, p. 421-422, 2019. Disponível em: <https://doi.org/10.1126/science.aaz3873>.
- BENKLER, Y.; FARIS, R.; ROBERTS, H. **Network propaganda**: manipulation, disinformation, and radicalization in American politics. Oxford: Oxford University Press, 2018.
- BINNS, R. Algorithmic accountability and public reason. **Philosophy and Technology**, v. 31, n. 4, p. 543-556, 2018. Disponível em: <https://doi.org/10.1007/s13347-017-0263-5>.
- BRASIL. Tribunal de Contas da União. **Acórdão nº 514/2023**. Brasília: TCU, 2023. Disponível em: <https://contas.tcu.gov.br/sagas/SvlVisualizarRelVotoAcRtf?codFiltro=SAGAS-SESSAO-ENCERRADA&seOcultarPagina=S&item0=820342>.
- CAR, J. *et al.* Beyond the hype of big data and artificial intelligence: building foundations for knowledge and wisdom. **BMC Medicine**, v. 17, n. 143, 2019. Disponível em: <https://doi.org/10.1186/s12916-019-1382-x>.
- CARNEY, P. **The politics of evidence-based policymaking**. London: Palgrave-MacMillan, 2016.

- COLES-KEMP, L. *et al.* Digital welfare: designing for more nuanced forms of access. **Policy Design and Practice**, v. 3 n. 2, p. 177-188, 2020. Disponível em: <https://doi.org/10.1080/25741292.2020.1760414>.
- COLLINGTON, R. Disrupting the welfare state? Digitalisation and the retrenchment of public sector capacity. **New Political Economy**, v. 27, n. 2, p. 312-328, 2022. Disponível em: <https://doi.org/10.1080/13563467.2021.1952559>.
- CONNOLLY, R. Why computing belongs within the social sciences. **Communications of the ACM**, v. 63, n. 8, p. 54-59, 2020. Disponível em: <https://doi.org/10.1145/3383444>.
- CRAWFORD, K. **Atlas of AI: power, politics, and the planetary costs of artificial intelligence**. New Haven: Yale University Press, 2021.
- DAI, X. Enforcing law and norms for good citizens: one view of China's social credit system project. **Development**, v. 63, p. 38-43, 2020. Disponível em: <https://doi.org/10.1057/s41301-020-00244-2>.
- DUNLEAVY, P.; MARGETTS, H. The second wave of digital-era governance: a quasi-paradigm for government on the web. **Philosophical Transactions of the Real Society**, v. 371, n. 1987, p. 1-17, 2013. Disponível em: <https://doi.org/10.1098/rsta.2012.0382>.
- EKBIA, H. *et al.* Big data, bigger dilemmas: a critical review. **Advances in Information Science**, v. 66, n. 8, p. 1523-1545, 2014. Disponível em: <https://doi.org/10.1002/asi.23294>.
- EL-TALIAWI, O. G.; GOYAL, N.; HOWLETT, M. P. Holding out the promise of Lasswell's dream: big data analytics in public policy research and teaching. **Review of Policy Research**, v. 38, n. 6, p. 640-660, 2021. Disponível em: <https://doi.org/10.1111/ropr.12448>.
- EUBANKS, V. **Automating inequality: how high-tech tools profile, police, and punish the poor**. New York: St. Martin's Press, 2018.
- FILGUEIRAS, F.; RAYMOND, A. Designing governance and policy for disruptive digital technologies. **Policy Design and Practice**, v. 6, n. 1, p. 1-13, 2023. Disponível em: <https://doi.org/10.1080/25741292.2022.2162241>.
- FRANTZ, R. Herbert Simon: artificial intelligence as a framework for understanding intuition. **Journal of Economic Psychology**, v. 24, n. 2, p. 265-277, 2003. Disponível em: [https://doi.org/10.1016/S0167-4870\(02\)00207-6](https://doi.org/10.1016/S0167-4870(02)00207-6).
- FRISCHMANN, B.; SELINGER, E. **Re-engineering humanity**. Cambridge: Cambridge University Press, 2018.
- GIEST, S. Big data for policymaking: fad or fasttrack? **Policy Sciences**, v. 50, n. 3, p. 367-382, 2017. Disponível em: <https://doi.org/10.1007/s11077-017-9293-1>.
- GITELMAN, L.; JACKSON, V. Introduction. *In*: GITELMAN, L. (Ed.). **"Raw data" is an oxymoron**. Cambridge: MIT Press, 2013.
- HARTLEY, K.; KUECKER, G. D. **Disrupted governance: towards a new policy science**. Cambridge: Cambridge University Press, Mar. 2022.
- HUTSON, M. Has artificial intelligence become alchemy? **Science**, v. 360, n. 6388, p. 478-479, 2018. Disponível em: <https://doi.org/10.1126/science.360.6388.478>.

JOYCE, K. *et al.* Toward a sociology of artificial intelligence: a call for research on inequalities and structural change. **Socius: Sociological Research for a Dynamic World**, v. 7, n. 1, p. 1-11, 2021. Disponível em: <https://doi.org/10.1177/2378023121999581>.

KELLEHER, J. **Deep learning**. Cambridge: The MIT Press, 2019.

KITCHIN, R. Big data and human geography: opportunities, challenges, and risks. **Dialogues in Human Geography**, v. 3, n. 3, p. 262-267, 2013. Disponível em: <https://www.doi.org/10.1177/2043820613513388>.

KNUTH, D. **The art of computer programming**: fundamental algorithms. New York: Addison-Wesley, 1968. v. 1.

KOGA, N. *et al.* Analysing the information sources Brazilian bureaucrats use as evidence in everyday policymaking. **Policy and Politics**, v. 50, n. 4, p. 483-506, 2022a. Disponível em: <https://doi.org/10.1332/030557321X16588356122629>.

KOGA, N. *et al.* Apresentação. In: \_\_\_\_\_. (Org.). **Políticas públicas e usos de evidências no Brasil**: conceitos, métodos, contextos e práticas. Brasília: Ipea, 2022b.

KOGA, N. *et al.* Analytical capacity as a critical condition for responding to covid-19 in Brazil. **Policy and Society**, v. 42, n. 1, p. 117-130, 2023. Disponível em: <https://doi.org/10.1093/polsoc/puac028>.

LASSWELL, H. D. From fragmentation to configuration. **Policy Sciences**, v. 2, n. 4, p. 439-446, 1971. Disponível em: <https://doi.org/10.1007/BF01406144>.

MCCARTHY, J. Epistemological problems of artificial intelligence. In: WEBBER, B. L.; NILSSON, N. J. **Readings in artificial intelligence**. Berlin: Springer, 1981. p. 459-465.

MEIJER, A.; LORENZ, L.; WESSELS, M. Algorithmization of bureaucratic organizations: using a practice lens to study how context shapes predictive policing systems. **Public Administration Review**, v. 81, n. 5, p. 837-846, 2021. Disponível em: <https://doi.org/10.1111/puar.13391>.

MEIJER, A.; WESSELS, M. Predictive policing: review of benefits and drawbacks. **International Journal of Public Administration**, v. 42, n. 12, p. 1031-1039, 2019. Disponível em: <https://doi.org/10.1080/01900692.2019.1575664>.

MENDONÇA, R. F.; FILGUEIRAS, F.; ALMEIDA, V. A. **Algorithmic institutionalism**: the changing rules of social and political life. Oxford: Oxford University Press, 2023.

NOBLE, S. U. **Algorithms of oppression**: how search engines reinforce racism. New York: New York University Press, 2018.

OECD – ORGANISATION FOR ECONOMIC CO-OPERATION AND DEVELOPMENT. **Recommendation of the council on digital government strategies**. Paris: OECD, 2014. Disponível em: <https://www.oecd.org/gov/digital-government/Recommendation-digital-government-strategies.pdf>.

PARKHURST, J. **The politics of evidence**: from evidence-based policy to the good governance of evidence. London: Routledge, 2017.

PASQUALE, F. **The black box society**: the secret algorithms that control money and information. Cambridge: Harvard University Press, 2015.

- PORCIELLO, J. *et al.* Accelerating evidence-informed decision-making for the Sustainable Development Goals using machine learning. **Nature Machine Intelligence**, v. 2, p. 559-565, 2020. Disponível em: <https://doi.org/10.1038/s42256-020-00235-5>.
- RUSSELL, S. **Human compatible**: artificial intelligence and the problem of control. New York: Viking, 2019.
- RUSSELL, S. J.; NORVIG, P. **Artificial intelligence**: a modern approach. Englewood Cliffs: Prentice-Hall, 2010.
- SAMUEL, A. L. Some studies in machine learning using the game of checkers. **IBM Journal of Research and Development**, v. 44, n. 1/2, p. 206-226, 1959.
- \_\_\_\_\_. Artificial intelligence: a frontier of automation. **The Annals of the American Academy of Political and Social Science**, v. 340, n. 1, p. 10-20, 1962. Disponível em: <https://doi.org/10.1177/000271626234000103>.
- SIMON, H. A. Artificial intelligence: an empirical science. **Artificial Intelligence**, v. 77, n. 1, p. 95-127, 1995. Disponível em: [https://doi.org/10.1016/0004-3702\(95\)00039-H](https://doi.org/10.1016/0004-3702(95)00039-H).
- TURING, A. Computing machinery and intelligence. **Mind: A Quarterly Review of Psychology and Philosophy**, v. 59, n. 236, p. 433-460, 1950.
- VALLE-CRUZ, D. *et al.* Assessing the public policy-cycle framework in the age of artificial intelligence: from agenda-setting to policy evaluation. **Government Information Quarterly**, v. 37, n. 4, 2020. Disponível em: <https://doi.org/10.1016/j.giq.2020.101509>.
- VOLD, K.; HARRIS, D. R. How does artificial intelligence pose an existential risk? *In*: VÉLIZ, C. (Ed.). **The Oxford handbook of digital ethics**. Oxford: Oxford University Press, 2021. Disponível em: <https://doi.org/10.1093/oxfordhb/9780198857815.013.36>.
- WINSTON, P. H. **Artificial intelligence**. New York: Addison-Wesley, 1992.
- WITTGENSTEIN, L. **Blue and brown books**: preliminary studies for the philosophical investigations. New York: Blackwell, 1972.