

A ordem algorítmica das coisas: treinamento, classificação e predição¹

Paula C. PEREIRA²

Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ

RESUMO

Visando refletir sobre a racionalidade algorítmica e a ‘ordem das coisas’ a ela subjacente, esse trabalho realiza uma exploração da Inteligência Artificial a partir de suas três dimensões: treinamento, classificação e predição. Destrinchando cada uma destas modalidades, são exploradas implicações epistemológicas, tecnopolíticas e cronopolíticas desse modelo de saber e intervenção sobre a realidade.

Palavras-chave: Inteligência Artificial; racionalidade algorítmica; epistemologia centrada em dados; tecnopolítica; cronopolítica.

Introdução

No contexto de um modelo econômico assentado sobre um novo extrativismo que converte o mundo num grande “empório de dados” (MBEMBE, 2019, tradução minha) e orientado pelo modelo de negócios das grandes plataformas digitais (Cf. SADOWSKI, 2019; SRNICEK, 2017; ZUBOFF, 2021), a *racionalidade do algoritmo* vem se tornando central sobre os modos de conhecer e intervir sobre a realidade (BRUNO, 2021), impactando processos epistemológicos, políticos, econômicos, culturais, estéticos e subjetivos. Segundo Mbembe (ibid.), já não vivemos na era da máquina, mas na era do algoritmo ou, nos termos de Berardi (2019), passamos da era da *máquina externa* para a da *máquina interna*³. O algoritmo, sobretudo sob a forma do aprendizado de máquinas, popularmente chamado de Inteligência Artificial⁴, se tornou não apenas fundamental para o capital como fez surgir novas formas de produção e acúmulo de valor a partir dos dados que desencadearam um rearranjo dos diagramas de poder (Cf. MOROZOV, 2018; CELIS BUENO, SCHULTZ, 2021; WARK, 2019; ZUBOFF, 2021). Além disso, é um elemento essencial da radical reorganização do visível e da verdade pela qual passamos uma vez

¹ Trabalho apresentado no GP Tecnologias e Culturas Digitais, XXII Encontro dos Grupos de Pesquisas em Comunicação, evento componente do 45º Congresso Brasileiro de Ciências da Comunicação.

² Doutoranda em Comunicação e Cultura da UFRJ, pesquisadora do MediaLab.UFRJ e bolsista CNPq, email: paula.cpereira@gmail.com.

³ Para o autor, a passagem do séc. XX ao XXI implicou também uma mudança no tipo de máquinas predominantes em cada momento histórico. Enquanto o “século que acreditou no futuro” (p. 13) se relaciona à “Máquina Externa” (p. 15) — a máquina pesada, ferruginosa e volumosa, externa em relação ao corpo e à mente humana sintetizada sobretudo na vanguarda futurista e na projeção progressiva do futuro —, nossa época é marcada pela “máquina interiorizada” (p. 16) — a máquina bioinformática, miniaturizada, que se entrelaça com o sistema nervoso social e através da qual o controle se exerce. Nesse contexto, a máquina se converte em “diferença de informação, não exterioridade, mas sim modelação linguística, automatismo lógico e cognitivo” (p. 17).

⁴ Ainda que seja comum utilizar o termo Inteligência Artificial para se referir de modo genérico a aplicações baseadas em aprendizado de máquinas, na prática ela é apenas uma subárea dentro do grande conjunto da IA. Trata-se, contudo, da vertente mais popular e onde os maiores avanços técnicos na predição calculada vêm sendo obtidos.

que age diretamente sobre a regulação do nosso espectro visível e legível nos ecossistemas digitais através de uma série de personalizações, filtragens e classificações em ambientes de alta entropia informacional. Simultaneamente, crescem as evidências sobre como a agência algorítmica acentua assimetrias históricas, atualizando práticas racistas, sexistas, classistas e eugenistas e excluindo minorias de oportunidades progressivamente reguladas por algoritmos (Cf. EUBANKS, 2019; NOBLE, 2021; O’NEIL, 2021; SILVA, 2020; CHUN, 2021; BEIGUELMAN, 2021).

Porém, apesar dos crescentes efeitos da mediação algorítmica sobre o nosso atual ‘estado de coisas’, os discursos que propagam uma visão essencializante do algoritmo como “ente único” (FALTAY, 2020, p.9) e desmaterializado dificultam reconhecer que os sistemas e processos algorítmicos estão sempre condicionados por dinâmicas econômicas, sociotécnicas, políticas e culturais, atrelados materialmente à infraestruturas, instituições, estados e corporações específicos, assim como a exploração de recursos naturais, mão de obra barata e dados em escala do qual dependem (CRAWFORD, 2021). A consolidação e o exercício de uma *governamentalidade algorítmica* (ROUVROY, BERNS, 2015), sob a qual nossas condutas estariam progressivamente sendo conduzidas (FOUCAULT, 1995), implica assim a materialidade e a articulação de uma complexa rede sociotécnica de agentes heterogêneos, multiescalares e distribuídos, formada, além de algoritmos, por corporações, centros de pesquisa, desenvolvedores, *crowdworkers*, infraestruturas técnicas, fontes de dados e de minérios, etc.

Alimentando-se de cada fragmento de informação deixado por nossas atividades nas mídias digitais, o novo modelo — simultaneamente econômico, epistemológico e político — prototipado no Vale do Silício, visa tornar todo aspecto da existência mensurável, capturável, previsível e, sobretudo, monetizável: dos nossos hábitos às nossas personalidades, emoções, e, sobretudo, nossas propensões, inclinações, vulnerabilidades e supostos desejos (Cf. BRUNO, BENTES, FALTAY, 2019). A mineração desse acúmulo de dados por meio de inteligência de máquina permite calcular *quais os futuros prováveis*: seja sobre os comportamentos digitais, financeiros, eleitorais ou criminais. Esforços analíticos, comerciais e criativos são mobilizados assim para *antecipar o futuro*, prevendo a propensão de conteúdos viralizarem, usuários comprarem, crimes ocorrerem, eleitores votarem, consumidores quitarem dívidas, mobilizando uma ‘maquinaria adivinhatória’ que pretende nos conhecer melhor que nós mesmos.

A elaboração de “produtos de predição” se tornou a base de um lucrativo mercado capitaneado pelas gigantes da tecnologia que Shoshana Zuboff (op. cit.), ao descrever a emergência de um capitalismo de vigilância chamou de “mercados de futuros comportamentais”, ou seja, a comercialização de predições sobre nossos comportamentos futuros com base em dados do passado, visando sobretudo direcionamento de anúncios personalizados. É justamente esse *poder preditivo*, essa capacidade não apenas de prever mas em última instância de *produzir performaticamente o futuro*, que transforma o saber baseado em dados massivos e algoritmos num instrumento multiplamente valioso e disputado na atualidade.

A centralidade da predição no governo algorítmico está diretamente relacionada à capacidade técnica dos algoritmos que utilizam métodos de aprendizado de máquinas (*machine learning algorithms*, ou apenas ML, em inglês), sobretudo as redes neurais, de reconhecer padrões através de um cálculo indutivo sobre grandes conjuntos de dados. O que diferencia estes algoritmos dos chamados ‘algoritmos baseados em regras’ (*ruled-based algorithms*, em inglês) é que eles são capazes de ‘aprender’ certas propriedades, mais especificamente padrões, a partir de dados sem terem sido de antemão programados para isso. Desse processo resulta um modelo estatístico capaz de gerar predições sobre novos conjuntos de dados, calculando a probabilidade de determinados resultados ocorrerem. O aprendizado de máquinas consiste, portanto, essencialmente, no desenvolvimento de programas capazes de resolver problemas a partir de exemplos.

Esse tipo de tecnologias e sistemas está presente hoje nos mais variados âmbitos, desde ferramentas de tradução e geração de textos (os chamados modelos de linguagem natural), reconhecimento automatizado de imagens (a chamada visão computacional), reconhecimento facial, assistentes virtuais, na chamada Análise Preditiva ou nos algoritmos de recomendação de conteúdo que integram as interfaces das grandes plataformas digitais como Facebook, Instagram, YouTube, TikTok, Netflix, Spotify, etc. Para além dos contextos estritamente digitais, em esferas em que as implicações biopolíticas (FOUCAULT, 2008) se tornam mais evidentes, seja na segurança pública, na educação, na justiça criminal, no trabalho, na saúde ou na vigilância militar a predição calculada por meio de sistemas de aprendizado de máquinas vem se tornando uma tecnologia cada vez mais mobilizada para prometer a modernização dos serviços ao instalar um novo regime de antecipação de eventos (BENBOUZID, CARDON, 2018) e de automatização das decisões .

A ordem algorítmica das coisas e as três modalidades da IA

A noção de *racionalidade algorítmica* da qual lançamos mão ao longo deste texto pode ser descrita, junto à Fernanda Bruno, como “um modelo de racionalidade onde os algoritmos ocupam um lugar central nos processos de conhecimento de uma certa realidade, bem como nos processos de tomada de decisão e de gestão dessa mesma realidade.” (BRUNO, op. cit., p. 155). Inspirando-se na noção de racionalidade foucaultiana (FOUCAULT, 2006, 1995), a autora esclarece que “[u]m modelo de racionalidade implica simultaneamente produzir conhecimento e intervir sobre um determinado contexto, problema, fenômeno ou realidade”. (ibid.). No presente contexto, o termo *racionalidade algorítmica* designa tanto a centralidade que os algoritmos adquirem na contemporaneidade sobre os modos de conhecer, decidir, intervir e gerir a realidade, quanto os princípios que regem essa mesma racionalidade.

Para utilizar outro termo foucaultiano, poderíamos dizer que se trata de uma incursão sobre o modo como o campo epistemológico que emerge a partir do uso de algoritmos ditos inteligentes sobre conjuntos massivos de dados instaura uma determinada “ordem das coisas” (FOUCAULT, 2000, p. XV). Ao descrever o *a priori* que definiria de antemão o espaço das identidades, das semelhanças e das analogias para cada estrato histórico, o autor define tal ordem como “uma definição dos segmentos sobre os quais poderão aparecer as semelhanças e as diferenças, os tipos de variação de que esses segmentos poderão ser afetados, o limiar, enfim, acima do qual haverá diferença e abaixo do qual haverá similitude” (ibid.) e que é, pontua o autor, “indispensável para o estabelecimento da ordem mais simples” (ibid.). Aqui, essa ordem se refere ao modo como o regime de saber centrado em dados e algoritmos mapeia, captura, classifica, interpreta e simultaneamente produz realidades, fenômenos, subjetividades, e a partir de que princípios e operações.

Visando explorar o modo como a racionalidade algorítmica instaura seus códigos ordenadores e seu espaço do saber (FOUCAULT, 2000) através de um mergulho em sua dimensão programática, utilizaremos como base o modelo proposto por Pasquinelli e Joler (2020) para descrever as três modalidades que compõem a IA enquanto um *instrumento de conhecimento*: treinamento, classificação e previsão. Em termos mais práticos, essas modalidades correspondem, respectivamente, à *extração de padrões*, *reconhecimento de padrões* e *geração de padrões*. Tomando emprestado um termo de Leibniz, os autores chamam a esse dispositivo de Nooscópio, um “instrumento para ver

e navegar o espaço do conhecimento”. Destrinchando cada uma dessas modalidades exploraremos algumas implicações, sobretudo epistemológicas, tecnopolíticas e cronopolíticas desse modelo que não é somente de conhecimento, mas em última instância de produção da realidade. Em termos metodológicos, esse entendimento implica um olhar atento para a mediação tecnológica simultaneamente como *produto* (das forças que lhe dão forma) e *produtora* (de modos de saber e de ser) e para a força performativa que rege a racionalidade algorítmica (BRUNO, op. cit.)

“O que não é computável, não existe”

Antes de adentrar nas três dimensões da IA convém pontuar como os processos que viemos descrevendo integram um projeto de *datificação da vida* que é condição de possibilidade para que a IA opere como simultaneamente como uma indústria extrativa e como instrumento de conhecimento. Nesse projeto, a fronteira essencial passa a ser aquela que divide o *computável* e o *incomputável*. Como pontua Mbembe, estamos nos movendo para um momento histórico no qual “o que não é computável não existe” (2019, tradução minha). Ou seja, só adquire status ontológico aquilo que pode ser digitalizado, processado e interpretado pelas tecnologias e protocolos computacionais. Segundo Hui, a própria fantasia de uma superinteligência artificial é expressão de uma “forma extrema de computacionalismo, de acordo com a qual o mundo é calculável e poderia ser esgotado através de operações matemáticas” (2020, p. 178-9). A grande ambição da indústria da IA, aponta Crawford, é “capturar o planeta em uma forma computacionalmente legível” (op. cit., p. 11, tradução minha).

A datificação da vida e a delegação da produção de conhecimento e decisões às máquinas computacionais também disparam importantes inflexões nos métodos tradicionais de construção de evidências e interpretação dos fenômenos. No artigo “O fim da teoria: o dilúvio de dados torna o método científico obsoleto” (ANDERSON, 2008), que viria a se tornar paradigmático da *epistemologia centrada em dados* (RICAURTE, 2019), o editor da revista *Wired*, Chris Anderson, propõe que com a disponibilidade de dados massivos não haveria mais a necessidade da ‘velha’ teoria e o método científico — baseado em criar hipóteses e modelos e testá-los — se tornaria obsoleto⁵. Afinal, “[c]om

⁵ É claro que o simplista ‘fim da teoria’ que Anderson anuncia de modo efusivo corresponde apenas à obsolescência nesse regime epistemológico do método científico baseado em teorias causais e hipóteses, uma vez que é evidente que existe todo um aparato teórico subjacente a esse novo entendimento do mundo.

dados suficientes, os números falam por si mesmos” (ANDERSON, op. cit., tradução minha).

Apesar do artigo de Anderson soar simplista até mesmo do que viria a se consolidar ao longo da última década como a Ciência de Dados, ele manifesta aspectos importantes da epistemologia *data-driven* que hoje orienta grande parte das análises dos fenômenos nos mais diversos contextos. Nesse *dataísmo* (HAN, 2018), associado ao já velho solucionismo tecnológico (MOROZOV, op. cit), promove-se a ilusão de que os dados existem em ‘estado natural’, são autoevidentes, neutros e objetivos (GITELMAN, JACKSON, 2013; HAN, op. cit) e de que se os problemas ainda não foram solucionados é porque não há dados suficientes sobre o assunto (logo, é necessário obtê-los). Além de um modelo de gestão da realidade que considera apenas os ‘fatos’ computáveis por dados e algoritmos, o que esse discurso torna opaco é que “dados brutos são um oxímoro” (GITELMAN e JACKSON, op. cit., p. 3, tradução minha); dados não são simplesmente extraídos — ainda que a ideologia que os tem por centro seja guiada por uma lógica extrativista — mas são sempre resultado de sofisticados processos e técnicas de produção e interpretação maquínicas e humanas. Como bem observa Strecker (2022), “os dados não falam por si só, mas são ‘feitos para falar’”.

Treinamento

A primeira dimensão do Nooscópio da IA proposto por Pasquinelli e Joler é o treinamento dos modelos algorítmicos. Conforme descrevem os autores, antes desse processo, o algoritmo é como uma “folha em branco”. Durante o treinamento ou ‘aprendizagem com dados’, um algoritmo extrai os padrões contidos no conjunto de dados de treinamento⁶. Quanto maior a quantidade de dados utilizados nessa etapa, maior a efetividade do algoritmo e maior a complexidade de tarefas capaz de executar (CELIS BUENO, SCHULTZ, 2021).

Quando um modelo é treinado com dados ditos rotulados, ou seja, dados de antemão identificados com metadados que designam características, classes ou propriedades, diz-se que ele é do tipo *supervisionado*. O aprendizado supervisionado é utilizado em áreas como reconhecimento facial e de imagens. Nesse caso, o conjunto de dados rotulados é o parâmetro que o modelo utiliza para fazer classificações ou previsões.

⁶ Os padrões identificáveis pelos algoritmos de ML podem corresponder aos mais diversos objetos e eventos: imagens, textos, pronúncias de palavras, históricos de busca, emoções e expressões faciais, crimes e fraudes, rostos, perfis comerciais, policiais, eleitorais, militares, e assim por diante.

Quando o modelo dispensa a necessidade de treinamento com dados rotulados e é capaz de reconhecer padrões sem a necessidade dessa etapa, diz-se que é do tipo *não-supervisionado*.

Para dar um exemplo da área de reconhecimento de imagens, campo no qual as redes neurais se originaram e que mais as utiliza, para que um algoritmo se torne capaz de diferenciar imagens de maçãs e laranjas, é necessário que se colete, rotule e treine uma rede neural em bancos com milhares de imagens de maçãs e laranjas. Se tudo funcionar como o esperado, o modelo estatístico treinado será capaz de reconhecer a diferença entre as duas classes em novos conjuntos de imagens.

Bancos de dados de treinamento são, portanto, parte fundamental do regime de saber algorítmico: eles são a base sobre a qual o aprendizado de máquinas é construído (e, conseqüentemente as previsões que produz) e centrais para os modos como os sistemas de IA percebem e classificam o mundo, uma vez que definem os segmentos a partir dos quais algo é reconhecido e interpretado como informação ou ruído, padrão ou anomalia, visível ou invisível nesses sistemas. “Esses conjuntos de dados moldam os limites epistêmicos que governam como a IA opera e, nesse sentido, criam os limites de como a IA pode “ver” o mundo.” (CRAWFORD, op. cit., p. 98, tradução minha).

Uma dimensão nem sempre explícita do modelo de negócios baseado em dados e inteligência de máquina é a necessidade de contínuo aperfeiçoamento que ele requer; aquilo que seus produtores e promotores vendem como *otimização* e que com frequência figura nos ambíguos termos de uso como justificativa para a captura e análise massiva de dados dos usuários. Uma parte essencial das arquiteturas algorítmicas reside assim no contínuo treinamento de seus modelos, o que depende da consolidação de bancos de dados cada vez mais volumosos e sofisticados e da revisão contínua sobre a precisão das capacidades dos algoritmos realizarem as tarefas para as quais foram projetados.

Isso explica tanto o extrativismo de dados que está no centro da economia digital contemporânea quanto a hegemonia das *big techs* na indústria da IA: as práticas da captura e acumulação massiva de dados do capitalismo de vigilância resultaram na geração de gigantescos bancos de dados que passaram a ser utilizados para treinamento algorítmico e foram uma das condições para o desenvolvimento desse tipo de tecnologia (ZUBOFF, op. cit; CELIS BUENO, SCHULTZ, op. cit., CRAWFORD, op. cit.). Além disso, quanto maior o acesso quantitativo e qualitativo a dados, maior a sofisticação dos

modelos e, conseqüentemente, maior seu *potencial preditivo* uma vez que mais padrões são incorporados.

Além do trabalho de treinamento feito pelos desenvolvedores desses sistemas técnicos, parte do trabalho contínuo de treinamento dos algoritmos é distribuído nas redes sociotécnicas entre os próprios usuários. A cada busca que realizamos e o modo como interagimos com os resultados ofertados, a cada conteúdo que postamos nas redes sociais, a cada validação de que ‘não somos robôs’ ou identificação de ‘quais imagens contém barcos’, a cada vez que simulamos num app ‘como seremos quando velhos’, estamos, dentre outras coisas, treinando e aperfeiçoando modelos de IA. Ou seja, nos convertemos não somente em fontes gratuitas e incessante de dados, mas em treinadores de algoritmos, trabalho pelo qual obviamente também não somos remunerados (Cf. TERRANOVA, 2000, 2004; CELIS BUENO, SCHULTZ, op. cit.).

Uma segunda parcela desse trabalho contínuo de treinamento é realizada de modo fragmentado pelos chamados *crowdworkers*: trabalhadores terceirizados, massivamente do Sul Global, que realizam uma série de microtarefas repetitivas e mal remuneradas como rotular e classificar imagens e vídeos, escutar e transcrever áudios, moderar conteúdo potencialmente nocivo, validar resultados que algoritmos produzem e muitas outras⁷. Essa força de trabalho distribuída que sustenta as maquinarias da Inteligência Artificial encarna a formação de um verdadeiro *precariado algorítmico* que preenche as “lacunas” desses sistemas e é omitido dos discursos sobre as virtudes ‘autônomas’ dos sistemas que ajudam a construir e aperfeiçoar (PEREIRA, 2019).

Visando demonstrar como não há nada de neutro ou natural no modo como se consolidam os bancos de treinamento, especialmente aqueles que contêm dados biométricos, pesquisadores como Kate Crawford e Trevor Paglen têm realizado uma arqueologia desses sistemas sociotécnicos em projetos como a exposição *Training Humans* (2019, Fondazione Prada), dedicada unicamente às imagens de treinamento algorítmico⁸. Dentre as obras, está *They Took the Faces from the Accused and the Dead...(SD18)* baseada no banco de dados do *American National Standards Institute*, cujos arquivos de fotos de acusados e condenados foram cedidos pelo governo estadunidense para treinamento de softwares de reconhecimento facial. Hoje, fontes como

⁷ As tarefas são distribuídas online, sob demanda, por meio de plataformas como o Mechanical Turk, de propriedade da Amazon.

⁸ Para saber mais, ver: <https://www.fondazioneprada.org/project/training-humans/?lang=en>

o banco de dados da ANSI foram substituídas principalmente pelas fotos que ‘subimos’ nas redes sociais e sobre as quais pouco controle, segurança e privacidade temos já que tudo que está online se torna um potencial dado para treinamento do IA’s.

Uma vez incorporadas às bases de treinamento, quase sempre sem consentimento algum, essas imagens se tornam um substrato técnico para a precisão algorítmica (CRAWFORD, op. cit.). ‘Esvaziadas’ de seu contexto original e da especificidade de seu significado — e muitas vezes da violência através da qual foram obtidas, como mostra o projeto de Crawford e Paglen — elas passam a integrar uma coleção massiva de dados para operações máqunicas abstratas de corporações privadas. Tais imagens funcionam numa lógica *pós-representacional*, aproximando-se daquilo que Harun Farocki chamou de *imagem operativa*: imagens que não visam representar algo, mas que “existem no contexto de uma operação, servem para balizar a performance de um dispositivo, são incorporadas a uma linha de produção e são úteis dentro de procedimentos produtivos” (FAROCKI, ELIAS, 2019).

Questionar como são treinados os algoritmos, por quem, com que dados e como esses dados são obtidos, compreendidos e utilizados se tornam essenciais para uma reflexão acerca das implicações éticas, epistemológicas e políticas da IA.

Classificação

Os algoritmos de aprendizado de máquinas costumam dividir-se em dois grandes conjuntos: algoritmos de *classificação* e de *regressão* (ou previsão). Os primeiros são utilizados normalmente para atribuir categorias discretas de rótulos de classes (*class labels*, em inglês) enquanto os segundos para prever uma quantidade contínua. Os classificadores são utilizados para reconhecer, por exemplo, um spam, um objeto ou um rosto humano, atribuindo-lhes um sinal (verdadeiro ou falso) conforme se enquadrem ou não na categoria para a qual o algoritmo foi previamente treinado.

Essa modalidade da IA depende da construção de uma complexa estrutura taxonômica uma vez que para que *elementos* sejam ligados a *classes* ou *categorias* é necessário que de antemão tais correspondências sejam definidas. Parafraseando Foucault (2000), é necessário que exista previamente um sistema de elementos que ligue as *palavras* e as *coisas*.

É aqui onde entra em jogo uma dimensão que está no centro da prática da IA: as *políticas de classificação* (CRAWFORD, op. cit.). Tais políticas atravessam todo o

regime de saber algorítmico e ordenam desde o modo como a IA é produzida (dos centros de pesquisa à ‘indústria tech’), como os bancos de treinamento são estruturados e futuramente utilizados, como esquemas específicos de ordenamento social naturalizam hierarquias e ampliam desigualdades, como modelos taxonômicos, que nada possuem de neutro, ‘esquadrinham’ e segmentam o mundo. Dito de outro modo, a racionalidade algorítmica e a ordem das coisas a ela atrelada implicam um amplo e intenso processo de (re)classificação e (re)segmentação da realidade, dos problemas, fenômenos, sujeitos, populações, identidades, etc, cujas implicações vêm afetando o próprio entendimento (ontológico, epistemológico, político) de tais ‘questões’ e modo como se produzem no tempo. Num termo, as políticas da classificação algorítmica são dispositivos de saber-poder.

Como afirmam Bowker e Star (2000), classificações são tecnologias poderosas que, uma vez incorporadas à infraestruturas de trabalho e hábitos, tornam-se relativamente invisíveis sem contudo perder seu poder. Seja no ato de rotular imagens para bancos de treinamento, identificar pessoas com reconhecimento facial ou na perfilização algorítmica, a taxonomia classificatória subjacente a esses sistemas técnicos tende a desaparecer.

Para dar um breve exemplo de como as políticas da classificação algorítmica se materializam, pensemos no *ImageNet*⁹, o mais canônico banco de imagens de treinamento para computação visual, criado em 2009 e atualmente composto por mais de 14 milhões de imagens provenientes das mais diversas fontes nas redes e distribuídas em mais de 20.000 categorias

A estrutura semântica do *ImageNet* é baseada no *WordNet*, um banco de dados de classificação de palavras desenvolvido na Universidade de Princeton na década de 1980 e se organiza segundo uma estrutura de sinônimos cognitivos (*synsets*, em inglês). Cada *synset* corresponde a um conceito distinto com sinônimos agrupados e organizados numa hierarquia que vai dos conceitos gerais aos mais específicos. Cada conceito é por sua vez organizado em uma das nove categorias de nível superior: planta, formação geológica, objeto natural, esporte, artefato, fungo, pessoa, animal e diversos¹⁰.

⁹ <https://www.image-net.org/>.

¹⁰ A ambição do projeto é bem sintetizada pela declaração de uma de suas criadoras, a professora Fei-Fei Li: “Vamos mapear todo o mundo dos objetos.” (apud CRAWFORD, op. cit, p. 107, tradução minha)

Enquanto categorias de substantivos como ‘cadeira’ dificilmente suscitarão alguma controvérsia quanto a sua aplicação (ou, caso existam, as implicações de dita controvérsia dificilmente serão graves), definir quais imagens são classificadas como correspondentes a ‘doença’ ou ‘saúde’, por exemplo, é um ato carregado de implicações éticas e políticas. Nesse contexto, “tudo é achatado e preso a uma etiqueta, como borboletas de taxidermia em uma vitrine. Os resultados podem ser problemáticos, ilógicos e cruéis, especialmente quando se trata de rótulos aplicados às pessoas” (CRAWFORD, PAGLEN, 2019, tradução minha). Associar imagens específicas a categorias como ‘alcoólatra’, ‘macaco’¹¹, ‘louco’ ou ‘prostituta’, trabalho em geral realizado pelos *crowdworkers*, tende a atualizar e intensificar práticas racistas, sexistas e estigmatizantes, em suma, violentas. Além disso, esses sistemas taxonômicos são incapazes de lidar com questões de gênero, por exemplo, sem reduzi-las a categorias binárias e excludentes.

Há um tipo de feitiçaria que entra na criação de categorias. Criar uma categoria ou nomear coisas é dividir um universo quase infinitamente complexo em fenômenos separados. Impor ordem a uma massa indiferenciada, atribuir fenômenos a uma categoria – isto é, nomear uma coisa – é, por sua vez, um meio de reificar a existência dessa categoria. (CRAWFORD, PAGLEN, *ibid.*, tradução minha)

Para além dos usos específicos de algoritmos classificadores, mas certamente a eles atrelados, é interessante observar como a ordem das coisas que o regime de saber algorítmico instaura, ancorado numa grande segmentação dos fenômenos em categorias ultrarefinadas incide também no modo como as próprias identidades e subjetividades são produzidas e produzem sujeitos, interferindo sobre aquilo que somos e o que podemos ser. Materializada sobretudo em técnicas de perfilização automatizada e *microtargeting* visando o direcionamento de conteúdo (supostamente) personalizado, a ‘clusterização’¹² massiva que a racionalidade algorítmica promove e através da qual intervém parece sintomática de uma espécie ‘pulsão classificatória’ no contemporâneo — que certamente é mais ampla do que ela, mas que encontra aí um dos meios mais eficazes de respondê-la. Uma das consequências desse processo tende a ser a produção de modos de subjetivação através dos quais não apenas passamos a nos entender enquanto ‘sujeitos classificáveis’, independente de quão ‘refinadas’ ou ‘inovadoras’ sejam as categorias

¹¹ Tornou-se emblemático o caso do Google Photos que ‘taggeou’ pessoas negras como gorilas em 2015. Para um levantamento de casos de racismo algorítmico, ver o levantamento mantido por Tarcízio Silva em: <https://tarciziosilva.com.br/blog/destaques/posts/racismo-algoritmico-linha-do-tempo/>.

¹² Clusters são agrupamentos de dados que compartilham atributos e/ou tendem a se conectar entre si. O axioma que rege essa técnica é a *homofilia*, segundo a qual “similaridade gera conexão” (CHUN, 2021, p. 74, tradução minha) e que para Chun estrutura o modo como as arquiteturas digitais contemporâneas se organizam.

utilizadas, como encontrar aí um lugar privilegiado de construção de identidade e produção de subjetividades.

Predição

A última modalidade da IA no modelo proposto por Pasquinelli e Joler (op. cit.), que abordaremos de modo mais breve, é a da *previsão* ou *geração de padrões*. No aprendizado de máquinas, essa vertente é utilizada para fazer uma projeção de padrões futuros de acordo com padrões passados. Isso é feito através de um cálculo indutivo que, reconhecendo certas regularidades num determinado conjunto de dados, prediz a probabilidade de determinados resultados ocorrerem (seja a parte ‘faltante’ de um áudio ou a probabilidade de crimes futuros, como no policiamento preditivo).

A predição algorítmica opera, portanto, essencialmente através de um *cálculo de probabilidades*. É a partir dessa característica que refletiremos sobre algumas implicações *cronopolíticas* do uso de algoritmos de aprendizado de máquinas para a predição de eventos e comportamentos enfatizando o modo como o governo algorítmico, através de uma normatividade estatística (ROUVROY, BERNS, op. cit.), visa *reduzir o possível aos limites do provável*.

Como observa Bruno acerca do alvo privilegiado da mediação algorítmica, “é precisamente sobre a *ação possível dos indivíduos* que incide a atenção e o interesse dos diversos ramos que se dedicam ao conhecimento e ao controle de condutas nos ambientes digitais.” (2020, p. 263, destaque meu). Portanto, é sobretudo aquilo que entenderemos aqui como o *campo do possível* que a governamentalidade algorítmica (ROUVROY algorítmico visa conhecer e sobre o qual visa intervir¹³. Por esta razão, estas tecnologias podem ser entendidas enquanto *dispositivos de governo do tempo* cujas maiores implicações concernem ao modo como regulam e intervêm no curso das ações e eventos possíveis.

Uma vez que o regime de conhecimento dessas tecnologias está intrinsecamente relacionado ao uso de saberes estatísticos visando a predição e antecipação de eventos, comportamentos, riscos, poderíamos afirmar que a racionalidade algorítmica se baseia numa normatividade estatística que visa probabilizar a totalidade da realidade,

¹³ Na prática, o ordenamento do campo do possível ao qual nos referimos se manifesta concretamente no modo como tais algoritmos regulam, por exemplo, o que é visível e legível nas plataformas digitais (a que conteúdos cada usuário tem ou não acesso, que ações são permitidas, proibidas, facilitadas e/ou dificultadas em cada contexto, que comportamentos são induzidos ou evitados, a que tipos de perfis está associado e que são base das ofertas, filtragens e rankeamentos personalizados que lhe são feitas, etc).

esquadrinhando-a em termos puramente numéricos e traçando um mapa de suas tendências, propensões, inclinações e potencialidades sobre as quais intervém. Essa probabilização da realidade — e no limite, do futuro uma vez que aqui está necessariamente implicada a dimensão temporal — abre a “possibilidade de governar os comportamentos sem se ocupar diretamente com os indivíduos para se contentar em governar a partir de uma expressão estatística da realidade” (ROUVROY, BERNS, op. cit., p. 52).

Nesse regime, simultaneamente epistemológico, normativo, temporal e de poder, “se captura o possível, reduzindo-o à mera probabilidade” enquanto “o provável, por sua vez, nos é imposto como necessário” (BERARDI, 2019b, p. 29-30). Assim, uma das principais ações que o governo algorítmico estabelece é uma modulação do campo do possível através das ‘malhas’ do provável. Um dos efeitos dessa racionalidade sobre o tempo é aquilo que Fernanda Bruno chama de “o sequestro do futuro” (op. cit., p. 262).

O sequestro do futuro descrito por Bruno se refere à capacidade de agir sobre os comportamentos em tempo real que marca o modelo de negócios hegemônico das plataformas digitais e que depende, simultaneamente, da contínua antecipação de nossos comportamentos e da capacidade de modificá-los em tempo real intervindo sobre nossas arquiteturas de escolha. Essa intervenção contínua e calculada sobre o ‘próximo passo’ implica para a autora “um sequestro, no nível cotidiano, do nosso campo de ação possível” (BRUNO, op. cit., p. 263). Nesse contexto, “o futuro e a ação possível, como reserva aberta de possibilidades, de encontros e de inesperado, são sequestrados nessas microantecipações cotidianas nos ambientes e plataformas online” (ibid., p. 264).

Uma vez que não se trata somente de novas formas de conhecer o sujeito e o mundo, mas do modo como estes se atualizam e produzem no tempo, refletir a fundo sobre as implicações da agência algorítmica para a constituição do campo do possível e defender, como sugere Zuboff, o “direito ao tempo futuro” (2021, p. 376) se tornam tarefas urgentes para uma tecnopolítica da era do algoritmo.

Referências bibliográficas

- ANDERSON, C. The End of Theory: the data deluge makes the scientific method obsolete. **Wired**, 23 de junho de 2008. Disponível em: <<https://www.wired.com/2008/06/pb-theory/>>. Acesso em 4, fevereiro, 2022.
- BENBOUZID, B.; CARDON, D.. Machines à prédire. **Réseaux**, vol. 211, n. 5, pp. 9-33, maio de 2018.
- BEIGUELMAN, G.. **Políticas da Imagem: vigilância e resistência na dadosfera**. São Paulo: Ubu Editora, 2021.
- BERARDI, F. B.. **Depois do Futuro**. São Paulo: Ubu Editora, 2019.
- BERARDI, F. B.. **Futurabilidad: la era de la impotencia y el horizonte de posibilidad**. Buenos Aires: Caja Negra, 2019b.
- BOWKER, G.; LEIGH STAR, S.. **Sorting Things Out: Classification and Its Consequences**. Cambridge, Mass.: MIT Press, 1999.
- BRUNO, F. Tecnopolítica, racionalidade algorítmica e mundo como laboratório. In: GROHMANN, Rafael. **Os laboratórios do trabalho digital: entrevistas**. São Paulo: Boitempo, 2021.
- BRUNO, F.; BENTES, A.; FALTAY, P.. Economia Psíquica dos Algoritmos e Laboratório de Plataforma: Mercado, Ciência e Modulação do Comportamento. **Revista Famecos**, v. 26, n. 3, 2019.
- CASTRO, E.. **El Vocabulario de Michel Foucault: un recorrido alfabético por sus temas, conceptos y autores**. Bernal: Universidad Nacional de Quilmes, 2004.
- CELIS BUENO, C.; SCHULTZ, M. J.. Extractivismo de datos. **Imaginación maquina**. Disponível em: <<http://imaginacionmaquina.cl/extractivismo-de-datos>>, Acesso em 1, maio, 2022.
- CHUN, W. H. K. **Discriminating data : correlation, neighborhoods, and the new politics of recognition**. Cambridge: The MIT Press, 2021.
- CRAWFORD, K.. **Atlas of AI: Power, Politics, and the Planetary Costs of Artificial Intelligence**. Yale University Press: New Heaven, London, 2021.
- CRAWFORD, K; PAGLEN, T. **Excavating AI: The Politics of Training Sets for Machine Learning**. Setembro de 2019. Disponível em: <<https://excavating.ai>>. Acesso em 15 de julho de 2022.
- EUBANKS, V.. **Automating Inequality: how high-tech tools profile, police, and punish the poor**. New York: Picador, 2019.
- FALTAY, P.. **Máquinas paranoides e sujeitos influenciáveis: conspiração, conhecimento e subjetividade em redes algorítmicas**. 2020. Tese (Doutorado) - Pós-Graduação em Comunicação e Cultura, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2020.
- FAROCKI, H.; ELIAS, E. Harun Farocki: máquinas de visão, máquinas de guerra. **Revista Zum** (online), novembro de 2019. Disponível em: <<https://revistazum.com.br/radar/farocki-maquinas-de-visao/>>. Acesso em 15 de julho de 2022.
- FOUCAULT, M.. O Sujeito e o Poder. In: RABINOW, Paul, DREYFUS, Hubert L. **Michel Foucault: uma trajetória filosófica (para além do estruturalismo e da hermenêutica)**. Rio de Janeiro: Forense Universitária, 1995.
- FOUCAULT, M.. **As palavras e as coisas: uma arqueologia das ciências humanas**. 8ª ed. São Paulo: Martins Fontes, 2000 [1966].
- FOUCAULT, M.. **Ditos & Escritos IV: estratégia, poder-saber**. Rio de Janeiro: Editora Forense Universitária, 2006.

FOUCAULT, M.. **O nascimento da biopolítica**: curso dado no College de France (1978-79). São Paulo: Martins Fontes, 2008b.

GITELMAN, L.; JACKSON, V.. Introduction. In: GITELMAN, Lisa. **“Raw Data” is an Oxymoron**. Cambridge, London: MIT Press, 2013.

HAN, B.. **Psicopolítica: o neoliberalismo e as novas técnicas de poder**. Belo Horizonte: Âyiné, 2018.

HUI, Y.. **Tecnodiversidade**. São Paulo: Ubu Editora, 2020.

MBEMBE, A.. Thoughts on the planetary: An interview with Achille Mbembe. **New Frame**, 17, janeiro, 2019b. Disponível em: <<https://www.newframe.com/thoughts-on-the-planetary-an-interview-with-achille-mbembe/>>. Acesso em 4, fevereiro, 2022.

MOROZOV, E.. **Big Tech: a ascensão dos dados e a morte da política**. São Paulo: Ubu Editora, 2018.

NOBLE, S. U. **Algoritmos da Opressão**. Santo André: Editora Rua do Sabão, 2021.

O’NEIL, C.. **Algoritmos de Destruição em Massa**. Santo André: Editora Rua do Sabão, 2021.

PEREIRA, P.. 2019. #Dobras 38 // Precariado algorítmico: o trabalho humano fantasma nas maquinarias da inteligência artificial. **Blog MediaLab.UFRJ**, setembro de 2019. Disponível em: <<https://medialabufrj.net/blog/2019/09/dobras-38-precariado-algoritmico-o-trabalho-humano-fantasma-nas-maquinarias-da-inteligencia-artificial/>>. Acesso em 15, abril, 2022.

PASQUINELLI, M.; JOLER, V.. O Manifesto Nooscópio: Inteligência Artificial como Instrumento de Extrativismo do Conhecimento. **Blog Lavits**, maio de 2020. Disponível em: <<https://lavits.org/o-manifesto-nooscopio-inteligencia-artificial-como-instrumento-de-extrativismo-do-conhecimento/?lang=pt>>. Acesso em 4, fevereiro, 2022.

RICAURTE, P.. Data Epistemologies, Coloniality of Power, and Resistance. **Television & New Media**, vol. 20, n. 4, pp. 350- 365, março de 2019.

ROUVROY, A., BERNS, T.. Governamentalidade Algorítmica e perspectivas de emancipação: o dispar como condição de individuação pela relação? **Revista ECO Pós**, vol. 18, n. 2, pp. 36-56, 2015.

SADOWSKI, J. When data is capital: Datafication, accumulation, and extraction. **Big Data & Society**, vol. 6, n.1, pp. 1-12, 2019.

SILVA, Tarcízio. **Visão Computacional e Racismo Algorítmico: branquitude e opacidade no aprendizado de máquina**. Revista ABPN, v. 12, pp. 428-448, 2020.

SRNICEK, N. **Platform Capitalism**. Malden: Polity Press, 2017.

STRECKER, H. Dobras #53 // “Você É O Que Você Ouve”: Spotify E A Promessa Algorítmica De Nos Conhecer Melhor Do Que Nós Mesmos. **Blog MediaLab.UFRJ**, maio de 2022. Disponível em: <<https://medialabufrj.net/blog/2022/05/dobras-53-voce-e-o-que-voce-ouve-spotify-e-a-promessa-algoritmica-de-nos-conhecer-melhor-do-que-nos-mesmos/>>

TERRANOVA, T. Free Labor: Producing Culture for the Digital Economy. **Social Text**, 18(2), 35-58, 2000

TERRANOVA, T. **Network culture: politics for the information age**. London: Pluto Press, 2004.

ZUBOFF, S.. **A Era do Capitalismo de Vigilância: a luta por um futuro humano na nova fronteira do poder**. São Paulo: Intrínseca, 2021.