



UNIVERSIDADE DE BRASÍLIA
Faculdade de Direito

Programa de Pós-Graduação em Direito

MARIA CRISTINE BRANCO LINDOSO

**DISCRIMINAÇÃO DE GÊNERO EM PROCESSOS
DECISÓRIOS AUTOMATIZADOS**

Brasília
2019



UNIVERSIDADE DE BRASÍLIA
Faculdade de Direito
Programa de Pós-Graduação em Direito

MARIA CRISTINE BRANCO LINDOSO

**DISCRIMINAÇÃO DE GÊNERO EM PROCESSOS
DECISÓRIOS AUTOMATIZADOS**

Dissertação apresentada à Banca Examinadora da Faculdade de Direito da Universidade de Brasília como requisito parcial para a obtenção do título de Mestre em Direito, elaborada sob a orientação da Prof.^a Dra. Ana Frazão.

Brasília
2019

Ficha catalográfica elaborada automaticamente,
com os dados fornecidos pelo(a) autor(a)

LM332d Lindoso, Maria Cristine
Discriminação de Gênero em Processos Decisórios
Automatizados / Maria Cristine Lindoso; orientador Ana
Frazão. -- Brasília, 2019.
116 p.

Dissertação (Mestrado - Mestrado em Direito) --
Universidade de Brasília, 2019.

1. Decisões automatizadas. 2. Discriminação de gênero. 3.
Algoritmos. I. Frazão, Ana, orient. II. Título.

UNIVERSIDADE DE BRASÍLIA
Faculdade de Direito
Programa de Pós-Graduação em Direito

Dissertação apresentada à Banca Examinadora da Faculdade de Direito da Universidade de Brasília como requisito parcial para a obtenção do título de Mestre em Direito.

MARIA CRISTINE BRANCO LINDOSO

BANCA EXAMINADORA

Professora Doutora Ana Frazão (Orientadora)
Universidade de Brasília

Professora Doutora Laura Schertel Mendes
Universidade de Brasília

Professora Doutora Caitlin Sampaio Mulholland
Pontifícia Universidade Católica do Rio de Janeiro

Professora Doutora Amanda Athayde
Universidade de Brasília

Brasília, 11 de dezembro de 2019.

AGRADECIMENTOS

Não existe projeto de minha autoria que não seja dedicado, primeiramente, ao Mauricio Lindoso. O pai incrível, apoiador e carinhoso, que sempre acreditou no meu potencial e se esforçou para me dar o melhor em termos de educação, qualidade de vida, amor e cuidado. A você, sou grata por tudo.

À Cristine Branco e à Vovó Catarina, agradeço por estarem ao meu lado durante a caminhada, guiando meus passos e incentivando meus investimentos arriscados, que alguns diriam ser teimosia. Mãe, você é uma inspiração que me ensina todos os dias como ser forte. Obrigada por ser minha torcedora número um e por me ajudar a construir o que tenho.

Agradeço à Ana Frazão, que me acompanha desde os primeiros semestres da graduação, com sua parceria incansável e poderosa, mostrando-me a força e a competência que nós mulheres alcançamos no Direito. Obrigada por acreditar no meu trabalho; por disponibilizar tanto do seu tempo ao longo desses anos para ouvir minhas angústias e me ajudar a construir as mais diversas discussões que renovam, a cada dia, meu caminho pelo mundo jurídico.

Ao Alex Lindoso, meu grande encorajador, incansável na luta por me fazer sair da minha zona de conforto para perceber o novo, pesquisar algo diferente e a isso me dedicar. Ao Luis Mauricio Lindoso e à Carolina Lindoso-Neet, por serem parceiros da jornada. À Flávia Ferreira, pelos laços de amor e carinho mais fortes que o sangue.

Agradeço ao Angelo Prata de Carvalho, ao Carlos Ávila, à Amanda Visito e à Paula Baqueiro por serem as melhores amigas que pude construir ao longo da jornada de UnB, e por serem as primeiras pessoas com quem quero dividir todas as alegrias e dúvidas da vida. Obrigada por serem os amigos inspiradores, pacientes, verdadeiros e amorosos que são. Vocês quatro, com suas bestagens, são a causa de grande parte do que sou hoje. À Sylmara, pela espiritualidade e pela prática que encontramos juntas ao longo dos anos, e que foram fundamentais para me inspirarem.

À Laura Schertel Mendes, por sempre ter dividido comigo as ideias deste trabalho. Também à professora Caitlin Mulholland e à professora Amanda Atahyde, por aceitarem participar de uma das partes mais importantes da minha jornada neste mestrado, que é a da apresentação desta dissertação.

À Lígia Melo e à Tatiana Martins, em nome de todos os colegas do Trench, Rossi & Watanabe, pelo amor e cuidado diário, por dividirem o cotidiano, fazendo dele

um lugar mais leve. Especialmente a vocês duas, obrigada pela amizade mais atenciosa e amorosa, pelas aventuras da rotina e por viverem comigo os novos desafios.

Agradeço à Márcia Melo, pela leitura cuidadosa deste trabalho, que tanto o enriqueceu.

Finalmente, ao Henrique de Faria, com quem divido o amor mais verdadeiro e compartilho a alegria de poder viver mais uma etapa desta maratona.

A todos vocês, obrigada.

“Em la tierra seremos reinas,
y de verídico reinar,
y siendo grandes nuestros reinos,
llegaremos todas al mar.”¹

¹ MISTRAL, Gabriela. *Todas ibamos a ser reinas*, 2005.

RESUMO

O presente estudo objetiva analisar de que maneira os processos decisórios automatizados podem discriminar mulheres. Através da construção de definições relevantes para a compreensão de como funcionam as decisões automatizadas, e também correlacionando o desenvolvimento tecnológico desigual que se vive hoje com uma perspectiva de gênero, pretende-se compreender em que medida os algoritmos, o tratamento de dados em massa, e as tecnologias do tipo *big data* e *data mining* podem acabar reproduzindo vieses inconscientes que implicam no tratamento diferenciado de mulheres de forma a prejudicá-las na busca pela igualdade. Para tanto, o presente estudo mapeou pesquisas empíricas realizadas em outros estudos, e valendo-se da produção bibliográfica que vem sendo desenhada sobre o tema, pretendeu, ao fim, identificar em quais etapas do processo decisório automatizado pode ocorrer essa discriminação, e quais seriam discussões interessantes, do ponto de vista da estrutura automatizada, para tentar solucionar esse problema.

Palavras-chave: decisões automatizadas; discriminação de gênero; algoritmos.

ABSTRACT

The intention of the present study is to analyze how automated decision-making processes may discriminate against women. This is done by means of developing relevant concepts for understanding how automated decisions work, and also by analyzing technological development under a gender perspective. By going through these steps, this study aims at understanding to what extent algorithms, mass data processing and technologies such as big data and data mining may end up replicating unconscious biases that result in the unequal treatment of women, and ultimately delays the search for equality. For this analysis, the present study identified empirical researches and analyzed the academic studies that have been developed around this theme so as to identify in which stages of the automated decision-making process the discrimination occurs, and which relevant discussions should society engage in, under the perspective of automated structure, in order to solve this problem.

Keywords: automated decisions; gender discrimination; algorithms.

SUMÁRIO

INTRODUÇÃO	12
O FUNCIONAMENTO DOS PROCESSOS AUTOMATIZADOS SOB UMA PERSPECTIVA DE GÊNERO	17
1.1 Considerações preliminares.....	17
1.2 Dados pessoais.....	18
1.2.1 Dados pessoais sensíveis e a caracterização do gênero como dado pessoal sensível.....	21
1.2.2 Dados anonimizados	24
1.3 <i>Big data</i>	26
1.3.1 O funcionamento dos algoritmos	32
1.3.2 <i>Data mining</i>	37
GÊNERO E TECNOLOGIA.....	40
2.1 O contexto da preocupação entre desigualdade e tecnologia	40
2.2A tecnologia como vetor de promoção da desigualdade entre homens e mulheres	47
2.2.1 O conceito de discriminação	48
2.2.2 Mulheres e processos automatizados	51
TIPOLOGIA DA DISCRIMINAÇÃO DE GÊNERO EM PROCESSOS AUTOMATIZADOS.....	57
3.1 Considerações preliminares.....	57
3.2 Discriminação de gênero pela coleta de dados pessoais	59
3.2.1. Falta de representatividade dos dados	60
3.2.2 Uso de Dados Históricos.....	65
3.2.3 Supressão de dados pessoais sensíveis	67
3.2.4 Anonimização de dados pessoais	70
3.3 Discriminação de gênero por algoritmos e <i>data mining</i>	72
3.3.1 Discriminação inserida no desenho algorítmico	73
3.3.2 Discriminação através do treinamento do algoritmo e criação do modelo.....	76
3.3.3 Discriminação no <i>data mining</i> por correlações e inferências estatísticas.....	78
POSSÍVEIS SOLUÇÕES PARA ELIMINAÇÃO DA DISCRIMINAÇÃO DE GÊNERO EM PROCESSOS DECISÓRIOS AUTOMATIZADOS	82
4.1 Considerações preliminares.....	82
4.2 Possíveis soluções para a discriminação de gênero pela coleta de dados pessoais	86
4.2.1 Falta de representatividade dos dados	86
4.2.2 Uso de Dados Históricos.....	88

4.2.3 Supressão de dados pessoais sensíveis	89
4.2.4 Anonimização de dados pessoais	92
4.3 Possíveis soluções para a discriminação de gênero por algoritmos e <i>data mining</i>	93
4.3.1 Discriminação inserida no desenho algorítmico	94
4.3.2 Discriminação através do treinamento do algoritmo e criação do modelo.....	102
4.3.3 Discriminação no <i>data mining</i> por correlações e inferências estatísticas .	103
CONCLUSÃO.....	106
REFERÊNCIAS	110

INTRODUÇÃO

Segundo o senso demográfico de 2016 realizado pelo Instituto Brasileiro de Geografia e Estatística (IBGE), as mulheres ganham 20,5% menos que os homens², mesmo estudando mais e realizando, em paralelo à vida profissional remunerada, 73% mais horas semanais extras, apenas de afazeres domésticos³. 60,9% dos cargos gerenciais, tanto na esfera pública, como na privada, ainda são ocupados por homens, mesmo que as mulheres representem, hoje, a maior parte da população⁴. Os anos passam, mas elas são minoria no parlamento, na polícia⁵, no mundo executivo⁶ e na ciência⁷. Não suficiente, as mulheres estão sujeitas a uma realidade de desrespeito por parte dos homens, de modo que uma em cada três mulheres é ou foi vítima de violência por parte de algum homem ao longo da vida⁸. Ou seja, os desdobramentos da desigualdade permeiam todas as esferas da vida feminina.

Como essas, existem tantas outras pesquisas que demonstram que a desigualdade de gênero é uma realidade no Brasil e no mundo, e ainda são necessários muitos esforços coletivos para que ela seja eliminada. Essa premissa – de que mulheres sofrem discriminação pelo simples fato de serem mulheres – é adotada ao longo do presente trabalho sob uma perspectiva diferente, que é a da tecnologia e da automatização de decisões.

² PARADELLA, Rodrigo. *Diferença cai em sete anos, mas mulheres ainda ganham 20,5% menos que homes*. Agência IBGE Notícias, 2019. Disponível em: <<https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-de-noticias/noticias/23924-diferenca-cai-em-sete-anos-mas-mulheres-ainda-ganham-20-5-menos-que-homens>>; acesso 22 ago 2019.

³ PERET, Eduardo. *Mulher estuda mais, trabalha mais e ganha menos do que o homem*. Agência IBGE Notícias, 2018. Disponível em: <<https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-de-noticias/noticias/20234-mulher-estuda-mais-trabalha-mais-e-ganha-menos-do-que-o-homem>>; acesso em 22 ago 2019.

⁴ _____. *Estatística de gênero: responsabilidade por afazeres afeta inserção das mulheres no mercado de trabalho*. Agência IBGE Notícias, 2018. Disponível em: <<https://agenciadenoticias.ibge.gov.br/agencia-sala-de-imprensa/2013-agencia-de-noticias/releases/20232-estatisticas-de-genero-responsabilidade-por-afazeres-afeta-insercao-das-mulheres-no-mercado-de-trabalho>>; acesso em 22 ago 2019.

⁵ IBGE - Instituto Brasileiro de Geografia Estatística. *Estatísticas de gênero*. Indicadores sociais das mulheres no Brasil, 2018. Disponível em: <https://biblioteca.ibge.gov.br/visualizacao/livros/liv101551_informativo.pdf>; acesso em 22 ago 2019.

⁶ IBGE, Op. cit., 2018.

⁷ MORAES, Tadeu. *Só 14% da Academia Brasileira de Ciências é hoje integrada por mulheres*. Estudo analisou a diversidade de gênero e a regional na instituição brasileira, 2018. Disponível em: <<https://www1.folha.uol.com.br/ciencia/2018/08/so-14-da-academia-brasileira-de-ciencias-e-hoje-integrada-por-mulheres.shtml>>; acesso em 22 ago 2019.

⁸ _____. *Relatório Final Quantitativo*. Pesquisa Eles por Elas, 2016. Disponível em: <http://www.onumulheres.org.br/wp-content/uploads/2018/04/Relatorio_UNU_ElesporElas_PesquisaQuantitativa2016.pdf>; acesso em 22 ago 2019.

A automatização de decisões, tal como ela ocorre hoje, está inserida no contexto de quarta revolução industrial, descrita por Klaus Schwab como um momento do desenvolvimento que culminou (i) no uso de tecnologias de ponta em processos cotidianos, e (ii) na difusão do processamento de dados em massa através da expansão do *big data*; além de ocasionar (iii) profundas modificações nas estruturas sociais, políticas e de mercado⁹. Trata-se de revolução cujo início esteve fundado na desigualdade, trazendo a falsa ideia de que o acesso à informação e ao conteúdo estavam disponíveis mundialmente e ao alcance de um celular, quando, na verdade, grande parte da população mundial que sequer tem acesso à energia elétrica¹⁰, está excluída desse processo¹¹.

Outra característica que marca o desenvolvimento desigual da quarta revolução industrial diz respeito ao aprofundamento da distância existente entre os agentes de mercado que manipulam dados pessoais e os próprios usuários. Os primeiros, em decorrência de um grande vácuo temporal de ausência de regulação, conseguiram se valer de sua produção científica para fundarem monopólios de tratamento de dados¹², e desenvolverem tecnologias do tipo *big data* e *data mining* que, como vem sendo comprovado, estão sendo responsáveis por manipular os comportamentos e desejos dos usuários, sem que esses possam saber ou ter controle desses processos¹³.

As próprias informações pessoais, difundidas na forma de dados, foram e vêm, até hoje, sendo utilizadas em desrespeito aos direitos de personalidade, já que os usuários sequer conseguem ter controle da maneira sobre a qual os conteúdos que lhes dizem respeito estão sendo difundidos, compartilhados ou vendidos. E foi nesse contexto que se inseriu a regulação que se tem hoje, no Brasil consolidada recentemente pela Lei Geral de Proteção de Dados Pessoais, Lei nº 13.709 de 14 de agosto de 2018, à espelha da mais moderna regulação europeia.

Esses diplomas - europeu e brasileiro - representam uma preocupação coletiva acerca dos rumos dessa quarta revolução industrial, e estabelecem diretrizes e balizas para que todo o processo de tratamento de dados seja de controle do usuário,

⁹ SCHWAB, Klaus. *A quarta revolução industrial*. São Paulo: Edipro, 2016.

¹⁰ LERMAN, Jonas. *Big data and Its Exclusions*. Stanford Law Review, v. 66, 2013.

¹¹ Veja-se que, a esse respeito, é importante destacar ser a energia elétrica um requisito essencial para a realização da segunda revolução industrial, que não foi vivida por diversos países até hoje. Nesse sentido: LERMAN, Jonas. *Big data and Its Exclusions*. Stanford Law Review, v. 66, 2013.

¹² Esse tema é abordado por Shoshana Zuboff ao discutir foi o capitalismo de vigilância se estruturou na sociedade hoje, e como os monopólios das empresas que tratam dados pessoais viabilizou uma mudança paradigmática de todos os mercados, através das análises comportamentais feitas pelas empresas. Nesse sentido: ZUBOFF, Shoshana. *The age of surveillance capitalism. The fight for a human future at the new frontier of power*. New York: Public Affairs, 2019.

¹³ RICHARDS, Neil M.; KING, Jonathan H. *Big Data Ethics*. Wake Forest Law Review, No. 393, 2014.

respeitando-se a privacidade em relação a esses conteúdos, e também a intenção dos usuários em relação a eles. São diplomas que visam alcançar a realidade da tecnologia na tentativa de assegurar que todo esse desenvolvimento tecnológico se em respeito a princípios básicos da democracia, como o da dignidade da pessoa humana.

Sabe-se que as decisões automatizadas envolvem diversos aspectos da vida cotidiana, e são utilizadas pelos agentes públicos e privados para selecionarem candidatos para vagas de emprego, direcionarem anúncios, concederem crédito e apólices de seguro, realizarem monitoramento policial, dentre tantos outros exemplos. Elas são, na verdade, estudos estatísticos primorosos, feitos por fórmulas matemáticas, com objetivo de predizerem comportamentos e intenções dos usuários. No meio desse processo, que envolve leitura massiva de dados pessoais, percebeu-se que alguns grupos específicos poderiam estar sendo prejudicados pelas decisões produzidas ao final.

Diversos estudos – os quais serão abordados ao longo do presente trabalho – demonstraram que mulheres, juntamente com outros grupos minoritários, tinham tratamento diferenciado, com impacto negativo em suas realidades, decorrente dessa automatização decisória, e muitas vezes, isso sequer era comentado. Foram estudados os mais variados *softwares* de automatização e os resultados produzidos eram sempre semelhantes: a realidade discriminatória das mulheres estava sendo reproduzida e, em algumas circunstâncias, aprofundada, também pelas máquinas.

Sabendo que as mulheres já vivem em situação desigual, o espanto decorrente dessas pesquisas se deu por causa da difusão de percepção de que esses programas, e também essas tecnologias preditivas feitas com base em análise de dados, seriam idôneas, e produziriam o melhor resultado possível para um problema específico. Toda a crença de que as máquinas eram neutras estaria sendo questionada, e poucas pessoas saberiam como apurar se os resultados finais produzidos estavam corretos ou não – dos mais pequenos, como os que mostram um anúncio para um usuário em uma página da internet, até os maiores, que decidem quanto tempo de prisão um cidadão poderá enfrentar –.

Esse contexto se associa a uma discussão que cresceu com a regulação do tratamento de dados pessoais, que é a da transparência. Há muito começou a se falar da falta de controle sobre os algoritmos que estruturaram esses processos automatizados, e sobre a verdadeira caixa preta existente entre essas grandes plataformas, como a Google,

o maior buscador de pesquisas do mundo, no que diz respeito à forma como são produzidos os seus resultados¹⁴.

Essas discussões se associam a uma realidade relativamente nova no Brasil, porque a Lei Geral de Proteção de Dados Pessoais ainda entrará em vigor, em agosto de 2020. Ou seja, diversos debates que já estão em estágios avançados mundo a fora, ainda são relativamente preliminares no território nacional. E é nesse contexto que o presente trabalho se instaura. Partindo-se da premissa de que existe desigualdade de gênero no Brasil, este estudo pretende fazer uma análise de como os processos automatizados de decisão podem ser potencialmente discriminatórios para mulheres.

A esse respeito, o Capítulo 01 aborda as definições importantes para a correta compreensão de como funcionam os processos automatizados de tomada de decisão. São abordadas definições de dados pessoais, dados sensíveis, dados pessoais anônimos, dados anonimizados, *big data*, algoritmos e *data mining*. É possível compreender, da leitura do referido Capítulo, a revolução provocada pelo advento do *big data* e do *data mining* nos mais variados mercados, a fim de se perceber a dimensão das mudanças estruturais provocadas pelas tecnologias preditivas.

O Capítulo 02 busca compreender a relação entre o gênero e a tecnologia, com o objetivo de compreender por qual motivo o auge do desenvolvimento científico ainda não conseguiu solucionar questões atinentes ao preconceito de mulheres. No Capítulo, também é construída a definição de discriminação de gênero compatível com os valores democráticos atuais, e também com as definições delimitadas no Capítulo 01.

O Capítulo 03, por sua vez, pretende analisar como, e em quais etapas, ocorre a discriminação de gênero nos processos automatizados. A primeira etapa analisada é a da (i) coleta e do tratamento de dados, quando se percebe o potencial discriminatório (a) pela falta de representatividade de dados; (b) pelo uso de dados históricos; (c) pela supressão de dados pessoais sensíveis; e (d) pela anonimização de dados pessoais. A segunda etapa analisada é através (ii) dos algoritmos, quando o potencial discriminatório se verifica (a) pelo desenho algorítmico; (b) pelo treinamento algorítmico; e (c) pelas correlações e inferências estatísticas do próprio *data mining*.

O Capítulo 04, ao fim, objetiva analisar possíveis soluções para eliminar, ou, ao menos, diminuir, esse potencial discriminatório em cada uma das etapas mapeadas no Capítulo 03. Também é analisada a viabilidade jurídica dessas soluções, a fim de elucidar

¹⁴ PASQUALE, Frank. *The Black Box Society: The Secret Algorithms That Control Money and Information*, Harvard University Press, 2015.

as discussões e propor avanços para o fim da discriminação de mulheres através das decisões automatizadas.

Toda a pesquisa elaborada é feita através de um estudo bibliográfico de como se dá a relação entre gênero e tecnologia, de como funcionam as tecnologias preditivas que se utilizam da leitura de dados pessoais em massa, e de como a discriminação de mulheres pode ocorrer nos processos automatizados de tomada de decisão. Foram analisadas pesquisas produzidas nessa área, e conclusões de autores mundo à fora acerca dos vieses de gênero nas tecnologias preditivas, e quais as possíveis formas de correção dessas distorções.

CAPÍTULO 1

O FUNCIONAMENTO DOS PROCESSOS AUTOMATIZADOS SOB UMA PERSPECTIVA DE GÊNERO

1.1 Considerações preliminares

O presente estudo se propõe a analisar, à luz da perspectiva de gênero, o potencial discriminatório das decisões automatizadas. Para que isso seja feito, é importante compreender, em um primeiro momento, como se deu o advento das principais tecnologias preditivas utilizadas atualmente, como são tomadas essas decisões automatizadas, e quais as estruturas essenciais para que se possa compreender o processo de tratamento de dados pessoais massivo como um todo.

Esse é o objetivo deste primeiro capítulo. Pretende-se, inicialmente, analisar como foi alcançado o estágio que se denomina quarta revolução industrial, como funciona a automatização dos processos, e porquê esse ápice do desenvolvimento tecnológico está associado à desigualdade. Essas são compreensões relevantes para que uma melhor construção das dificuldades de relação entre o gênero e a tecnologia da automatização, juntamente com as discussões éticas que são travadas em relação ao processamento massivo de dados.

A partir desta pretensão, serão analisadas algumas definições relevantes, quais sejam as de (i) dados pessoais e (ii) *big data*. Dentro do primeiro grupo de definições, serão pormenorizadas algumas categorias de dados pessoais, que são a de dados pessoais (i.i) sensíveis; (i.ii) anônimos; e (i.iii) anonimizados. Já no segundo grupo de definições, foram criadas categorias associadas aos dados do tipo *big data*, que são as de (ii.i) algoritmos; e (ii.ii) *data mining*.

Ressalte-se que as definições relacionadas aos dados pessoais estão sendo abordada neste Capítulo para que se possa discutir a importância desse conteúdo, e porquê ele suscita demasiadas controvérsias e preocupações por parte dos agentes reguladores. Já as definições relacionadas ao *big data* são fundamentais para que se possa compreender como funciona e como surgiu a tomada de decisão automatizada.

1.2 Dados pessoais

A definição mais difundida de dados pessoais é a de que são um conteúdo que pode ser associado a uma pessoa específica, em uma circunstância específica¹⁵.

Sua existência é tão antiga quanto a humanidade, e muito antes da automatização dos processos decisórios, e até da internet, os seres humanos já desenvolviam grande capacidade de coleta desses dados –denominados *raw data* – e análise de suas informações, com o objetivo de identificar de padrões semelhantes. Esses eram os primeiros estudos estatísticos realizados, os quais foram desenvolvidos a partir da análise minuciosa das informações dos cidadãos (ou seja, dos dados pessoais), a fim de traduzirem comportamentos, características, realidades e desejos da sociedade.

Eram, e são utilizados para definição de políticas públicas, aprimoramento do desempenho de empresas com seus consumidores, teste de aderência de produtos no mercado, avaliação da eficácia de medicamentos, dentre tantos outros exemplos¹⁶. Com o tempo, aprimorou-se a capacidade de coleta desses dados pessoais, e de análise de suas informações, como será pormenorizado adiante ao se falar em *big data*. Mas, de certa forma, sua finalidade originária permanece a mesma, e eles são, até hoje, utilizados para uma análise matemática de situações.

Uma das consequências relacionadas ao aumento da capacidade de coleta dos dados pessoais diz respeito ao fato de que qualquer informação que seja associada a um usuário determinado é considerada dado pessoal. São dados que informam o nome, a data de nascimento, o gênero e a raça do usuário, mas que também informam o tempo de permanência em uma determinada página de rede social, a aquisição feita, a quantidade de interações pela internet, a busca realizada na página do Google, dentre outras informações. Tantas quanto possíveis são as informações que se podem extrair da rede e que são consideradas dados pessoais por relacionarem algum comportamento ou característica a uma pessoa específica.

Nesse contexto, a definição expressa do dado pessoal abarca uma controvérsia no que diz respeito à natureza jurídica na qual se enquadraria: se seria a de bem jurídico ou se seria a extensão da personalidade individual. Os autores que se alinham à primeira perspectiva, como é o caso do teórico Lawrence Lessig, compreendem

¹⁵ MENDES, Laura Schertel. *Privacidade, proteção de dados e defesa do consumidor. Linhas gerais de um novo direito fundamental*. ed. Saraiva, Série IDP, 2014, p. 56.

¹⁶ AFFELT, Amy. *Big Data, Big Opportunity*. Australian Law Librarian, vol. 21, No. 2, 2013, p. 1.

que sua natureza é a de bem jurídico, uma vez que são objetos de transações e de negócios jurídicos firmados na rede¹⁷. E essa ideia é fundada na premissa de que nenhuma navegação no espaço da internet é gratuita, visto que a contraprestação do serviço de acesso às redes sociais, às páginas, às buscas, aos serviços de música, dentre tantos outros, é o compartilhamento da informação daquele usuário, que é o dado pessoal. Assim, os dados seriam, em verdade, bens dos usuários que são a moeda de troca virtual.

Já a segunda corrente compreende o dado pessoal como uma própria projeção da personalidade no âmbito virtual. A personalidade, à luz do direito civil brasileiro, pode ser analisada à luz da capacidade, que habilita o cidadão a participar de relações jurídicas, mas também à luz do “*conjunto de características e atributos da pessoa humana*”, que definem e caracterizam a essencialidade de um indivíduo¹⁸. Assim, como os dados pessoais associam características e atributos a um usuário específico, definem a essencialidade de um indivíduo no mundo virtual, o qual passa a ter todo o conjunto de atributos inerentes à condição humana, e que são objeto de proteção no direito brasileiro através dos direitos de personalidade.

A partir do entendimento de que os dados pessoais são apenas bens jurídicos, não seria possível deduzir que a divulgação indevida e não autorizada de um dado pessoal estaria violando, também, a privacidade de um usuário. Seria, nessa circunstância, uma discussão adstrita apenas ao âmbito do direito contratual, uma vez que houve a quebra de uma das cláusulas de um pacto no qual uma parte livremente dispôs de um bem (o dado pessoal), em troca de uma contraprestação (o acesso a uma página, por exemplo). Por outro lado, considerando que os dados pessoais são projeções da própria personalidade, a difusão desautorizada do conteúdo implica a divulgação desautorizada de informações que são atributos da essência do usuário, de suas características mais íntimas e determinantes.

Essa segunda perspectiva também culminou em discussões que criaram um novo direito fundamental, qual seja o direito à proteção de dados pessoais¹⁹. Esse novo direito decorre da percepção de que o dado pessoal é uma extensão da personalidade, e, assim considerado, a ele também se estendem as garantias dos direitos de personalidade,

¹⁷ LESSIG, Lawrence. *The Architecture of Privacy*, 1998, p. 17.

¹⁸ TEPEDINO, Gustavo. *A Tutela da Personalidade no Ordenamento Civil-constitucional Brasileiro*. Temas de Direito Civil, 3a ed., Renovar, 2004, p. 27.

¹⁹ FUSTER, Gloria González. *The Emergence of Personal Data Protection as a Fundamental Right of the EU*. Law, Governance and Technology Series, v. 16, Springer International Publishing Switzerland: Belgica, 2014.

que são irrenunciáveis e não sofrem nenhum tipo de limitação voluntária. Não suficiente, o surgimento de um novo direito fundamental de proteção de dados também decorre da preocupação com a privacidade, em razão da facilidade com que se coletam, compartilham e tratam dados pessoais atualmente, a fim de evitar que o comércio de dados se transforme em simples negociação contratual, quando, em verdade, ele pode trazer impactos diretos para a vida do usuário.

Como diz Virgílio Almeida, “*quanto mais se vive online, mais os outros vão saber sobre nós*”²⁰, motivo pelo qual a própria definição de privacidade vem se renovando dentro do ordenamento jurídico. Antes compreendida como o direito de ser deixado sozinho²¹, a privacidade se torna um direito de controle, de autodeterminação informativa²², na medida em que a informação existe, mas os limites de seu compartilhamento e uso são de faculdade do usuário. É nesse aspecto que se reforça a relevância da compreensão de dado pessoal como extensão da própria personalidade. A esse respeito:

“O direito à privacidade transformou-se para fazer emergir a dimensão dos dados pessoais, à medida que surgiram novos desafios ao ordenamento jurídico a partir do tratamento informatizado de dados. A transformação desse conceito pode ser percebida de forma mais clara a partir da década de 70, com a edição de legislações específicas e de decisões judiciais de diversos países, bem como a partir da aprovação de acordos internacionais e transnacionais em diferentes níveis. Todos esses instrumentos compartilham o conceito segundo o qual os dados pessoais constituem uma projeção da personalidade do indivíduo e que, portanto, merecem uma tutela jurídica.”²³

É por isso que, atualmente, uma melhor definição de dado pessoal é aquela que abarca a sua extensão como direito de personalidade, justamente para que seu uso possa respeitar uma série de garantias do usuário, dentre as quais se enquadra a do direito à privacidade. Ela é um requisito essencial à democracia, justamente para que o tratamento de dados possa respeitar os princípios constitucionais relacionados à proteção

²⁰ ALMEIDA, Virgílio A.F.. Privacy Problems in the Online World. IEEE Internet Computing, v. 16, p. 4-6, 2012, p. 6.

²¹ WARREN, Samuel D.; BRANDEIS, Louis D. *The right to privacy*. Harvard Law Review, vol. 4, No 5, 1890, p. 193-220.

²² KONDER, Carlos Nelson. O tratamento de dados sensíveis à luz da Lei 13.709/2018. In: FRAZÃO, Ana; TEPEDINO, Gustavo; OLIVA, Milena Donato (Org.). *A Lei Geral de Proteção de Dados Pessoais e Suas Repercussões no Direito Brasileiro*. Revista dos Tribunais: São Paulo, 2019, p. 450.

²³ MENDES, Laura Schertel. *Privacidade, proteção de dados e defesa do consumidor. Linhas gerais de um novo direito fundamental*. ed. Saraiva, Série IDP, 2014, p. 29.

da dignidade da pessoa humana²⁴, e para que eles não sejam interpretados exclusivamente dentro da ótica de mercado²⁵.

Como mencionado, os dados pessoais foram tutelados pelo ordenamento jurídico brasileiro dentro dessa perspectiva, na medida em que a Lei Geral de Proteção de Dados assegurou aos usuários diversas maneiras de controle do uso e do compartilhamento de seus dados. Uma dessas formas é o respeito à finalidade da coleta do dado pessoal, que deverá obedecer ao que foi informado ao usuário no primeiro momento, e acabará por impor uma certa limitação ao compartilhamento indiscriminado dos conteúdos para terceiros²⁶.

Em relação aos dados pessoais, a LGPD também trouxe outra perspectiva, que diz respeito à vedação do uso de dados como forma de discriminação. A ideia de discriminação será detalhada adiante e o conceito abordado neste trabalho será definido no segundo capítulo. Contudo, é relevante considerar que, novamente, o ordenamento jurídico reforça a proteção aos dados pessoais em consonância com a proteção aos direitos de personalidade, vedando qualquer tratamento diferenciado que prejudique a capacidade do indivíduo de se autodeterminar.

A esse respeito, Caitlin Mulholland entende que essa vedação do legislador – art. 6º, IX, LGPD – é quase um reconhecimento de que o tratamento de dados pessoais pode ser diferenciado, “*sem que isso leve a consequências excludentes que poderiam ser consideradas ilícitas*”.²⁷ Dessa forma, não é vedado utilizar dados pessoais para fins mercadológicos, tampouco tratar de forma diferente os vários usuários na rede.

1.2.1 Dados pessoais sensíveis e a caracterização do gênero como dado pessoal sensível

²⁴ MULHOLLAND, Caitlin Sampaio. *Dados pessoais sensíveis e a tutela de direitos fundamentais: uma análise à luz da Lei Geral de Proteção de Dados (Lei 13.709/18)*. Revista de direitos e Garantias Fundamentais, Vitória, v. 19, n. 3, set.-dez., 2018, p. 174.

²⁵ A esse respeito, Laura Schertel Mendes analisa que a compreensão do dado pessoal enquanto bem jurídico iria acabar causando diversas distorções prejudiciais à democracia, uma vez que (i) nem toda a população iria poder usufruir desse direito de forma igual, culminando-se em uma violação ao princípio constitucional da igualdade; e (ii) os dados pessoais iriam ser fraudados pelos próprios usuários, com o objetivo de que se adequem às demandas e expectativas de mercado e consigam melhores negócios com os agentes que coletam e tratam esses conteúdos. (MENDES, Laura Schertel. *Privacidade, proteção de dados e defesa do consumidor. Linhas gerais de um novo direito fundamental*. ed. Saraiva, Série IDP, 2014, pp. 122-123).

²⁶ RODOTÁ, Stefano. *A vida na sociedade de vigilância: privacidade hoje*. Rio de Janeiro: Renovar, 2008, p. 87.

²⁷ MULHOLLAND, Caitlin Sampaio. *Dados pessoais sensíveis e a tutela de direitos fundamentais: uma análise à luz da Lei Geral de Proteção de Dados (Lei 13.709/18)*. Revista de direitos e Garantias Fundamentais, Vitória, v. 19, n. 3, set.-dez., 2018, p. 164.

Os dados pessoais sensíveis foram definidos na LGPD nos seguintes termos²⁸:

“Art. 5º, LGPD: Para os fins desta Lei, considera-se:
II: dado pessoal sensível: dado pessoal sobre origem racial ou étnica, convicção religiosa, opinião política, filiação a sindicato ou a organização de caráter religioso, filosófico ou político, dado referente à saúde ou à vida sexual, dado genético ou biométrico, quando vinculado a uma pessoa natural”

Assim, trata-se de um tipo de dado pessoal de natureza diferenciada, já que a ele pode estar associado um conteúdo com potencial discriminatório. Como os dados pessoais são projeções da personalidade, algumas das características que determinam o indivíduo podem ser tratadas na sociedade de forma discriminatória, e o próprio diploma legal se encarrega de enumerar algumas delas de forma explícita. Para os dados inseridos nessas circunstâncias, criaram-se obrigações específicas, cuja adequação por parte dos agentes de mercado é medida que se impõe para assegurar a proteção do usuário e de sua personalidade.

O art. 11, por exemplo, impõe, para o tratamento, compartilhamento ou divulgação dos dados pessoais sensíveis, o consentimento do usuário de forma específica e destacada. O parágrafo 4º do mesmo artigo, por sua vez, veda o compartilhamento desse tipo de dado em algumas circunstâncias, mas, principalmente, quando o objetivo for a obtenção de vantagem econômica. Esse artigo, inclusive, reforça a escolha do legislador acerca da proteção da individualidade do usuário, em oposição à lógica de mercado.

A diferenciação dos dados pessoais sensíveis está atrelada a um dos mais relevantes princípios que orientam todo o diploma, qual seja o princípio da não discriminação anteriormente mencionado²⁹. Novamente, o ordenamento jurídico parece reconhecer que a manipulação de dados pessoais possui um risco discriminatório, e busca assegurar, assim, diretrizes mínimas, além da aplicação de princípios norteadores de toda a atividade de tratamento de dados, que protegem o usuário³⁰.

²⁸ De acordo com o Regulamento Geral de Proteção de Dados da União Europeia – comumente conhecido como GDPR -, são dados sensíveis, dispostos no art. 9º, aqueles que revelarem a origem racial ou étnica do usuário, opiniões políticas, crenças religiosas ou filosóficas, associação a sindicatos, dados genéticos, dados biométricos para fins de identificação pessoal e dados relativos ao estado de saúde ou à vida sexual e/ou orientação sexual de uma pessoa. Ou seja, a redação do dispositivo brasileiro é praticamente idêntica e se alinha à tendência mais recente de definição de dados pessoais sensíveis.

²⁹ MULHOLLAND, Caitlin Sampaio. *Dados pessoais sensíveis e a tutela de direitos fundamentais: uma análise à luz da Lei Geral de Proteção de Dados (Lei 13.709/18)*. Revista de direitos e Garantias Fundamentais, Vitória, v. 19, n. 3, set.-dez., 2018, p. 166.

³⁰ MULHOLLAND, Caitlin; FRAJHOF, Isabella Z. Inteligência Artificial e a Lei Geral de Proteção de dados pessoais: Breves anotações sobre o direito à explicação perante a tomada de decisões por meio de

A esse respeito, deve-se destacar que a categorização feita pelo diploma brasileiro não se limita à assegurar ao usuário o controle sobre suas informações com potencial discriminatório, mas objetiva, também, colocar enfoque positivo no tratamento desse tipo de conteúdo, justamente para que, consciente de seu potencial discriminatório, o agente possa adotar medidas para coibir a discriminação. Pode-se dizer que há, aqui, a inserção de uma ética de dados. Ela será discutida adiante, mas é importante já mencionar essa questão, a fim de orientar a atuação dos agentes com vistas, não exclusivamente, ao benefício econômico, mas sim ao livre exercício da dignidade da pessoa humana e todos aos desdobramentos a ela associados.

É por esse motivo que a interpretação do art. 5º, II, da LGPD, que caracteriza e qualifica os dados pessoais sensíveis, deve se dar de maneira extensiva, e não restritiva, sendo esse rol meramente exemplificativo, e não taxativo³¹. Veja, a orientação ética de todo o diploma legal é de vedar a discriminação e proteger a personalidade individual e todos os seus desdobramentos, garantido ao usuário o controle de seus dados. A própria definição do dado sensível se relacionada exclusivamente ao seu potencial discriminatório³², então, existindo um conteúdo potencialmente discriminatório, a ele deve ser estendida a proteção dos dados pessoais sensíveis, sob pena de fazer letra morta a intenção legislativa³³.

Essa ressalva é importante porque o gênero não está exemplificado como dado pessoal sensível, mas ele deve ser assim considerado em decorrência da realidade de discriminação vivida pelas mulheres no Brasil. Se ser mulher é uma condição que, por si só, impõe limitações ao exercício da personalidade, então o dado que informa o gênero de um usuário tem potencial discriminatório evidente, já que ele poderá impor tratamento diferenciado a uma pessoa, e esse tratamento poderá ser considerado ilícito.

Essa concepção do gênero como dado pessoal sensível foi adotada na reunião do grupo de mulheres dos 20 países mais desenvolvidos do mundo -G20-, oportunidade

machine learning, p. 269. In: FRAZÃO, Ana; MULHOLLAND, Caitlin (coord.). *Inteligência Artificial e direito: ética, regulação e responsabilidade*. São Paulo: Thomson Reuters, 2019.

³¹ KONDER, Carlos Nelson. O tratamento de dados sensíveis à luz da Lei 13.709/2018. In: FRAZÃO, Ana; TEPEDINO, Gustavo; OLIVA, Milena Donato (Org.). *A Lei Geral de Proteção de Dados Pessoais e Suas Repercussões no Direito Brasileiro*. Revista dos Tribunais: São Paulo, 2019, p. 455.

³² DONEDA, Danilo; SCHERTEL MENDES, Laura. *Marco jurídico para a cidadania digital: uma análise do projeto de lei 5.276/2016*. Revista de Direito Civil Contemporâneo, vol. 9, p.35-48, out-dez 2016, p. 5.

³³ LINDOSO, Maria Cristine. O processo decisório na era do Big Data: como novos mecanismos de processamento de dados através de algoritmos interferem nas tomadas de decisão., p. 373. In: FERNANDES, Ricardo Vieira de Carvalho; CARVALHO, Angelo Gamba Para (Coord.). *Tecnologia jurídica & direito digital: II Congresso Internacional de Direito, Governo e Tecnologia*. Belo Horizonte: Fórum, 2018.

em que foram consolidadas diretrizes específicas para (i) o combate da discriminação de mulheres no tratamento de dados em massa, e (ii) a promoção da igualdade de mulheres a partir do uso dos mecanismos automatizados. Dentre os compromissos firmados pelos estados-membro, destacam-se as orientações de buscas pelas regulações objetivando a transparência no processamento de dados pessoais; incentivos à criação de bancos de dados abertos e neutros em relação ao gênero; e desenvolvimento de políticas públicas e pesquisas que busquem critérios equitativos para ajudar a corrigir as distorções da vida real em relação à desigualdade de gênero³⁴.

Perceber o gênero como dado pessoal sensível, no mesmo sentido dos países-membros do G20 e da orientação doutrinária que vêm se consolidando, é relevante para ajudar a combater a discriminação em processos automatizados. E isso porque aos dados sensíveis são exigidas regras de conformidade diferenciadas, que aumentam o controle do usuário sobre o tratamento dos dados e a segurança de que os seus conteúdos não serão compartilhados sem o devido cuidado. Essa regulação específica, se estendida ao gênero, poderá ajudar a coibir o potencial discriminatório que é analisado neste trabalho, como será detalhado no Capítulo 03.

1.2.2 Dados anonimizados

Dados anonimizados são aqueles que antes eram caracterizados como dados pessoais, mas que, por expresse interesse do agente de mercado, foram transformados em anônimos, a partir da retirada de todas as características potencialmente identificadoras. Esses dados pessoais se transformaram, assim, em dados que não podem ser identificados com nenhum usuário e específico, e que, portanto, também não se sujeitam ao regramento jurídico de tratamento de dados pessoais³⁵.

A compreensão dessa característica específica, para fins deste trabalho, é importante porque a anonimização de dados pessoais, muitas vezes, pode ser responsável por uma potencial discriminação em processos automatizados. Como será detalhado no Capítulo 03, isso ocorre porque a eliminação das características identificadoras nunca é perfeita, de modo que, através de correlações e inferências estatísticas, o usuário poderá ser novamente identificado.

³⁴ AVILA, Renata, *et al.*. *Artificial Intelligence: Open Questions about Gender Inclusion*. In: policy Brief w20, Argentina, 2018.

³⁵ SCHERTEL, Laura Mendes. *Privacidade, proteção de dados e defesa do consumidor*. Linhas gerais de um novo direito fundamental. Saraiva- Série IDP, 2014, p. 79.

A esse respeito, é importante destacar que a não conformidade costuma ser um dos principais motivos pelo qual os agentes de mercado anonimizam dados pessoais, justamente porque querem se submeter a um regramento jurídico mais brando e, por consequência, menos custoso³⁶. De fato, a compatibilização com as regras de tratamento de dados pessoais pode impor barreiras importantes para o desenvolvimento das atividades dos agentes, mas elas são fundamentais para assegurarem a proteção da personalidade e evitarem que os monopólios constituídos no vácuo regulatório possam aprofundar, ainda mais, a sua capacidade de manipulação e controle do usuário.

Diversos estudos demonstraram que a capacidade de tratamento de dados pessoais em massa assegura ao agente uma vantagem competitiva muito relevante em relação aos demais, justamente porque permite a ele ter um estudo estatístico preciso que vai lhe garantir uma predição potencialmente verdadeira. Isso quer dizer que o agente irá saber o que o usuário vai querer, antes mesmo de o próprio usuário formar essa convicção, porque os estudos estatísticos terão demonstrado que as chances de aquela convicção ser formada são muito altas. Assim, o agente de mercado irá se adiantar em relação aos demais, e até ao próprio usuário, a ponto de poder manipular livremente sua vontade³⁷.

Essa ideia será desenvolvida cuidadosamente adiante, mas ela é importante para compreender que o agente possui incontáveis vantagens ao não ter que se submeter a uma regulação rígida que busca proteger o usuário. A principal delas é a competitiva, que lhe assegura a capacidade de manipulação dos desejos individuais, sem que o próprio usuário saiba que está sendo manipulado. E a anonimização de dados pessoais, em alguma medida, garante isso. Ela garante a não conformidade com o mesmo resultado de um tratamento de dados pessoais, pois o conteúdo final terá sido inferido por outros meios.

Outra questão relacionada ao motivo pelo qual os dados pessoais são anonimizados e que também se relaciona com a conformidade regulatória. Isso porque, em diversas circunstâncias, dados pessoais são coletados de forma desautorizada e seu tratamento é feito ilicitamente, sem o controle dos usuários e sem o respeito à finalidade que lhes foi assegurada. Através da eliminação das características que permitem a associação, o agente consegue tornar lícito o tratamento de dados que antes era irregular, sem se adequar às normas jurídicas específicas. Além disso, é como se o agente

³⁶ SCHWARTZ, Paul M.; SOLOVE, Daniel J., *The PII Problem: Privacy and a new personally identifiable information*. N.Y.U L. Rev., 86^aed., 2011.

³⁷ RICHARDS, Neil M.; KING, Jonathan H. *Big Data Ethics*. Wake Forest Law Review, No. 393, 2014.

conseguisse legitimar o produto final de seu tratamento de dados, que nunca esteve em conformidade com a lei.

Dessa forma, para o propósito deste trabalho, compreender o que são dados anonimizados é relevante, porque o seu uso em processos automatizados também representa um potencial risco à discriminação de gênero.

1.3 *Big data*

O *big data* é um tipo de dado, com grande capacidade de processamento e que permite reunir diversos conteúdos variados em um único sistema. Seu diferencial reside, justamente, na sua capacidade dele de ser tratado de forma célere e menos custosa³⁸.

O seu surgimento é decorrência do aprimoramento da capacidade humana de coleta de dados³⁹. Isso porque, os seres humanos sempre conseguiram coletar dados crus, que eram analisados com propósito de identificação de padrões similares. Percebeu-se, com o tempo, que várias outras informações poderiam ser analisadas e que praticamente qualquer coisa poderia ser transformada em dado para ser submetida à análise de padrões. Contudo, existia verdadeira limitação física relacionada à capacidade de leitura e interpretação de grande quantidade de dados, o que impossibilitava estudos estatísticos com maior precisão que poderiam ser feitos⁴⁰.

Através essa percepção, parte do desenvolvimento tecnológico se voltou para criação de mecanismos de leitura de dados de forma mais rápida, a fim de superar a atuação humana e instaurar uma análise massiva. À época, alguns países estavam inseridos no contexto da Terceira Revolução Industrial, caracterizada pelo início de algumas automatizações e pelos expressivos investimentos em tecnologia⁴¹. Vivia-se a Segunda Guerra Mundial, e a perspectiva de perder domínio territorial, e de reestruturar uma nova ordem global, fizeram com que aumentassem os investimentos nas áreas da ciência e da tecnologia. Os países estimularam as indústrias a produzirem inovações que

³⁸ DUMBILL, Edd. *What Is Big Data?: An Introduction to the Big Data Landscape*, O'Reilly, 2012. Disponível em: <<https://www.oreilly.com/ideas/what-is-big-data>>; acesso em 21 jul 2019.

³⁹ Alguns estudos sugerem que os registros mais antigos de coleta de dados são de mais de 7.000 anos atrás, na Mesopotâmia, para mapear o crescimento de rebanhos. Ver, nesse sentido: RIJMENAM, Mark Van. *A short story of Big Data*, 2018. Disponível: <<https://datafloq.com/read/big-data-history/239>> acesso em 22 out 2019.

⁴⁰ MAYER-SCHONBERGER, Viktor; CUKIER, Kenneth. *Big data*. Como extrair volume, variedade, velocidade e valor da avalanche de informação cotidiana. 1. ed., Rio de Janeiro: Elsevier, 2013, p. 5.

⁴¹ SCHWAB, Klaus. *A quarta revolução industrial*. São Paulo: Edipro, 2016, p. 34.

pudessem ser utilizadas no ambiente da guerra, e que, posteriormente, migraram para o cotidiano⁴².

Nessa época que surgiram os primeiros computadores, usados com o propósito de realizarem comunicações ainda rudimentares e fazerem mapeamento de satélites e bombas. Com o tempo, essas máquinas foram sendo utilizadas para transferirem e armazenarem informações, bem como analisarem dados em uma capacidade superior à humana⁴³.

Nesse contexto, destaca-se a atuação de Alan Turing, em um dos primeiros computadores conhecidos pela humanidade, fabricado com o propósito de interceptar comunicações nazistas e decodificá-las a partir da identificação de padrões semelhantes em poucas horas⁴⁴. Os estudos de Turing ficariam famosos por estruturarem as primeiras premissas do que hoje conhecemos como inteligência artificial, justamente em razão da sua capacidade de vislumbrar, naquela época, o potencial da tecnologia que estava sendo produzida. Em um artigo de 1950, por exemplo, ele sugeriu que, um dia, a capacidade de processamento dos computadores seria tão poderosa a ponto de ser indecifrável para o pensamento humano⁴⁵.

Entre 1960 e 1990, o desenvolvimento científico esteve em plena expansão⁴⁶, com a criação dos primeiros bancos de dados⁴⁷ e intensificação da criação de máquinas computadorizadas, as quais passaram a ser vendidas para grandes empresas, e depois para o público em geral⁴⁸. Nessa época, o mundo vivia um processo de migração do fluxo de informação do papel para as mídias digitais, o que corroborou com o fato de que cada vez

⁴² RICHARDS, Neil M.; KING, Jonathan H. *Big Data Ethics*. Wake Forest Law Review, No. 393, 2014, p. 397.

⁴³ RICHARDS; KING, Op. cit..

⁴⁴ RIJMENAM, Mark Van. *A short story of Big Data*, 2018. Disponível: <<https://datafloq.com/read/big-data-history/239>> acesso em 22 out 2019.

⁴⁵ RICHARDS, Neil M.; KING, Jonathan H. *Big Data Ethics*. Wake Forest Law Review, No. 393, 2014, p. 397 *apud* TURING, Alan M.. *Computing Machinery and Intelligence*, 1950.

⁴⁶ Deve-se destacar que essa plena expansão tecnológica, com a venda de computadores pessoais, não é a realidade para toda a população global. O próprio Klaus Schwab ressalva que 17% da população mundial ainda não viveu a segunda revolução industrial, uma vez que não possuem acesso à eletricidade, e mais de 4 bilhões de pessoas vivem sem acesso à internet (SCHWAB, 2016, p. 36).

⁴⁷ O primeiro que se tem notícia foi criado em 1965 pelo governo dos estados Unidos, com o objetivo de armazenar mais de 742 milhões de registros de pagamento de impostos, juntamente com mais de 175 milhões de impressões digitais. RIJMENAM, Mark Van. *A short story of Big Data*, 2018. Disponível: <<https://datafloq.com/read/big-data-history/239>> acesso em 22 out 2019.

⁴⁸ Aqui cabe destacar a célebre percepção de Bill Gates, em 1980, de querer “um computador em cada mesa, em cada casa”. RICHARDS, Neil M.; KING, Jonathan H. *Big Data Ethics*. Wake Forest Law Review, No. 393, 2014, p. 397 *apud* BEAUMONT, Claudine. *Bill Gates’s Dream: A computer in every home*. Telegraph, 27 jun 2008.

mais dados estavam sendo produzidos e poderiam ser analisados⁴⁹, estimulando o avanço nas análises de dados através de computadores. Em paralelo, surgiu a internet, popularizando-se de forma crescente o acesso à comunicação através de uma plataforma unificada⁵⁰.

A grande mudança ocorreu na virada do século com o processo de expansão da internet e das máquinas computadorizadas, que foi fruto de intensas pesquisas na área de tecnologia. Houve uma verdadeira revolução digital, que marcou o funcionamento dos mercados para como são conhecidos hoje, e que culminou no aumento expressivo dos dados que estavam sendo produzidos⁵¹. Ou seja, além da própria percepção de que vários conteúdos diferentes poderiam ser submetidos às análises matemáticas, a quantidade de dados que estava sendo produzida aumentou, porque o acesso aos instrumentos que produziam esses dados também cresceu.

Houve também uma intensa sofisticação da tecnologia, e pode-se dizer que, apesar de não ter sido um processo que ocorreu em todos os países, a capacidade de compartilhamento rápido de informações fez surgir uma economia global, que integrou diversos países de forma rápida e pouco custosa⁵². O *big data* foi justamente essa grande mudança, foi a chave que viabilizou toda essa transformação e que possibilitou a sofisticação da tecnologia que culminou na criação da inteligência artificial, da robótica e dos sistemas automatizados de tomada de decisão.

Empresas que estavam se aproveitando do vácuo regulatório em relação ao uso de dados pessoais, como a Google e o Yahoo, viram-se obrigadas a desenvolverem novos mecanismos para que mais dados fossem coletados e analisados de uma forma rápida e menos custosa. Essas empresas já tinham acesso a grandes quantidades de conteúdos, mas sofriam com a impossibilidade de processamento massivo e pouco custoso⁵³.

⁴⁹ Até a virada do século, por exemplo, estudos indicam que apenas um quarto da informação mundial estava armazenada em meio digital, já que a maior parte do conteúdo estava disposto em meios analógicos, como livros, papéis e fotografias. Já em 2007, e considerando também que os dados se multiplicam em grande velocidade, apenas 7% dos dados estavam em meio analógico, e a maioria das informações já havia migrado para um meio digital. Nesse sentido, ver: MAYER-SCHONBERGER, Viktor; CUKIER, Kenneth. *Big data*. Como extrair volume, variedade, velocidade e valor da avalanche de informação cotidiana. 1. ed., Rio de Janeiro: Elsevier, 2013, p. 5.

⁵⁰ RICHARDS, Neil M.; KING, Jonathan H. *Big Data Ethics*. Wake Forest Law Review, No. 393, 2014, p. 394.

⁵¹ SCHWAB, Klaus. *A quarta revolução industrial*. São Paulo: Edipro, 2016, p. 34.

⁵² SCHWAB, Klaus. *A quarta revolução industrial*. São Paulo: Edipro, 2016, p. 34.

⁵³ RICHARDS, Neil M.; KING, Jonathan H. *Big Data Ethics*. Wake Forest Law Review, No. 393, 2014, p. 404.

Essas foram empresas que, consolidaram seus monopólios em coleta e tratamento de dados pessoais através do *big data*, que foi o mecanismo por elas desenvolvido para facilitar o tratamento de dados em massa. Assim, a primeira importância ao se analisar o que é o *big data*, diz respeito ao fato de que ele foi responsável por uma verdadeira revolução mundial, que permitiu a análise volumosa, veloz e variada, que hoje se vive a tecnologia como tal.

Essas características, inclusive, costumam ser frequentemente mencionadas nos estudos acerca do *big data*, e são conhecidas como é caracterizado pelos seus “3Vs”. O primeiro desses “Vs” – volume -, diz respeito à densidade desse dado, e sua importância está associada justamente a esse momento de grande crescimento de conteúdo processável com o advento da quarta revolução industrial⁵⁴. O segundo, trata da velocidade e diz respeito à capacidade de gerar, acessar, processar e analisar dados.

Antes, o processamento de conteúdo poderia levar dias, ao passo que hoje, diversos sistemas conseguem analisar, em tempo real, os dados coletados, produzindo previsões estatísticas e resultados esperados⁵⁵. Essa característica possibilitou que o impacto das decisões automatizadas, da inteligência artificial e das análises preditivas fosse sentido imediatamente pelos usuários, interferindo diretamente em suas vidas e nas formas de relacionamento. Foi também em razão da velocidade na coleta e no tratamento de dados em massa que as decisões automatizadas ganharam mais relevância, justamente porque representam a capacidade das máquinas de superação da inteligência humana, através de uma análise de conteúdo muito rápida, que jamais poderia ser feita pelo cérebro.

No que diz respeito à variedade, o terceiro “V”, ele se relaciona à quantidade de conteúdos distintos que podem ser reunidos a uma só vez dentro do *big data*. Essa característica do *big data* fez perceber que os agentes também desenvolveram melhores capacidades de coleta de dados diversos dos indivíduos⁵⁶, de modo que todo tipo de conteúdo que pudesse ser associado a alguém, poderia ser traduzido em informação útil aos agentes de mercado. Isso promoveu o que hoje se conhece como datificação da vida,

⁵⁴ STUCKE, Maurice E.; GRUNES, Allen P. *Big Data and Competition Policy*. Oxford University Press, 2016, p. 19.

⁵⁵ STUCKE, Maurice E.; GRUNES, Allen P. *Big Data and Competition Policy*. Oxford University Press, 2016, p. 19.

⁵⁶ STUCKE, Op. cit., 2016.

que diz respeito a esse processo de transformar as interações em dados e que culminou na migração dos relacionamentos para a realidade virtual⁵⁷.

A variedade dos dados também fez com que os agentes pudessem agregar ainda mais valor ao conteúdo produzido em razão da capacidade de criarem novos dados advindos da fusão de outros coletados de fontes distintas⁵⁸. Ou seja, uma única informação, um dado cru por assim dizer, em si, possui muito pouco valor agregado, já que não permite traçar um perfil preciso e completo em relação a um determinado usuário. O *big data* inovou em relação a isso, pois permitiu que um único dado agregasse nele próprio diversas informações distintas, dando mais conhecimento aos agentes de mercado acerca da realidade e dos desejos de cada um. Esse fato, inclusive, foi o responsável por promover o aprofundamento da relação de hipossuficiência no mercado digital, uma vez que aumentou a disparidade de poder e informação existente entre o agente e o usuário⁵⁹.

É nesse contexto que se costuma falar, ainda, em outro “v” que está sendo associado ao *big data*, qual seja o do valor. Isso porque, é a potencialidade oferecida pelo *big data*, de variedade, volume e velocidade, aliados ao propósito de tomar uma decisão, que fez com que os dados pessoais fossem valorizado. Alec Ross ainda pondera que a própria capacidade de o *big data* produzir mais dados, a partir da fusão de diferentes conteúdos, também contribui para agregar valor a ele, mas que o grande diferencial diz respeito à velocidade na capacidade de processamento, porque fez com que a eficiência sempre perseguida pelo mercado pudesse ser notada de forma imediata⁶⁰. É essa também a ponderação Stucke e Grunes: a rápida capacidade de coleta, armazenamento e processamento de conteúdo é determinante para impactar no valor agregado que o dado tem⁶¹.

A partir das características mencionadas, é possível perceber que o *big data* deu ao mercado novas possibilidades de atuação, na medida em que permitiu aos agentes coletarem conteúdos sobre eles próprios, que não eram considerados em análises estatísticas. Se antes os perfis de potenciais consumidores eram traçados apenas em razão do seu gênero, da capacidade financeira, e as vezes da raça, hoje esses perfis são

⁵⁷ MAYER-SCHÖNBERGER, V. and CUKIER, K. *The Rise of Big Data: How It's Changing the Way We Think*. Foreign Affairs, vol. 92, no. 3, May/June, 2013.

⁵⁸ STUCKE, Maurice E.; GRUNES, Allen P. *Big Data and Copettition Policy*. Oxford University Press, 2016, p. 19.

⁵⁹ STUCKE, Op. cit., 2016.

⁶⁰ ROSS, Alec. *Industries of the Future*. New York: Simon & Shuster, 2016, p. 346.

⁶¹ STUCKE, Maurice E.; GRUNES, Allen P. *Big Data and Copettition Policy*. Oxford University Press, 2016., p. 19.

complexos a ponto de conseguirem relacionar todo o tipo de interação virtual daquele usuário com um interesse específico, tornando possível medir diversos indicadores que, analisados em conjunto, conseguem criar previsões perfeitas sobre as intenções e desejos, que, às vezes, o próprio usuário não sabe que tem.

É nesse sentido que preocupações acerca do potencial das máquinas começaram a se desenvolver, porque a análise de dados foi capaz de criar um perfil do indivíduo de tamanha profundidade, que nem o próprio indivíduo pode controlar. A esse fenômeno, dá-se o nome de *profiling* e ele somente foi possível porque o *big data* possibilitou a análise inimaginável de conteúdo. A partir da criação de um perfil do usuário, através dos dados que ele próprio forneceu – às vezes de forma inconsciente ou desautorizada - os agentes de mercado conseguem criar previsões de qualquer gênero, e essas, por sua vez, tornam-se decisões que impactam diretamente a vida desses usuários⁶². São decisões sobre quais anúncios ele vai receber, sobre quais interações vão ser indicadas nas redes sociais, sobre quais as chances de ele ser beneficiado por uma sentença menos severa, ou sobre qual a probabilidade de ele possuir o perfil adequado para uma vaga de emprego.

Destaca-se que esse potencial do *big data* não beneficiou apenas os agentes de mercado, mas também o consumidor, já que o desenvolvimento de um comércio especializado, focado nos interesses pessoais de cada um, possibilitou direcionar a ele somente produtos que poderia ter a chance de adquirir⁶³. A grande discussão a esse respeito, é se realmente o usuário consegue controlar esse processo, se consegue influenciar a análise comportamental feita pelos dados, ou se é essa análise que o influencia.

Apesar de produzi-los, o usuário não sabe quais conteúdos estão sendo utilizados a seu respeito – se são as informações que constam na página da rede social, ou as últimas buscas feitas no Google, ou o tempo em que ele ficou conversando em uma sala de bate papo. Assim, será que o usuário efetivamente controla seus interesses, ou acaba sendo manipulado por aquilo que os agentes, insistentemente, irão lhe apresentar?

⁶² ROSS, Alec. *Industries of the Future*. New York: Simon & Shuster, 2016, p. 345.

⁶³ OECD *Exploring the Economics of Personal Data*. Paris: OECD Publishing, 2013, p. 12. Disponível em: <<https://doi.org/10.1787/5k486qtxldmq-en>>, acesso em 21 ago 2019.

Será que o cálculo probabilístico feito pelo *big data* diz respeito ao que o usuário quer, ou ao que ele tem mais chances de consumir⁶⁴?

Eis a principal importância, nesse contexto, da compreensão do *big data* para este estudo. Se a nova economia de tratamento de dados pessoais consegue tomar decisões que impactam tão diretamente a realidade dos usuários, é necessário então que exista uma discussão sobre como essas decisões são tomadas, e sobre quais os riscos a seu respeito. Diversos estudos regulatórios estão inseridos, nesse contexto, dentro de uma perspectiva de que os grandes monopólios de tratamento de dados pessoais podem possuir um efetivo controle dos usuários⁶⁵. Isso precisa ser observado de perto para evitar ilícitos dos mais variados, desde os concorrenciais, até os ligados à proteção da personalidade e da privacidade.

Os próprios impactos sociais que o *big data* tem nos interesses pessoais e no desenvolvimento de preferências e escolhas que são tomadas virtualmente é uma questão que vem sendo estudada, considerando os estudos comportamentais feitos através dos dados e de que modo eles podem ser utilizado como instrumentos de manipulação⁶⁶. O enfoque deste estudo é apenas uma das tantas preocupações que estão inseridas nessa realidade, que é o da discriminação de gênero.

1.3.1 O funcionamento dos algoritmos

Os algoritmos são as estruturas matemáticas que permitiram organizar a automatização de processos e viabilizar a análise do *big data*, a fim de que sejam feitas as previsões e, conseqüentemente, tomadas as decisões de forma automatizada⁶⁷.

Essas estruturas matemáticas são fórmulas que representam transcrições dos desejos e intenções de um ser humano. Elas se organizam a partir de modelos matemáticos repetitivos⁶⁸ que analisam informações previamente inseridas (*inputs*)⁶⁹,

⁶⁴ Essa é a tese levantada hoje em dia acerca do *marketing* digital personalizado, que endereça ao usuário a propaganda específica aos seus interesses. A esse respeito: TURROW, Joseph. *Niche Envy*. Marketing Discrimination in the Digital Age. Cambridge: The MIT Press, 2006.

⁶⁵ ZUBOFF, Shoshana. *The age of surveillance capitalism*. The fight for a human future at the new frontier of power. New York: Public Affairs, 2019.

⁶⁶ SCHROEDER, Ralph. *Social Theory After the Internet*. Media, Technology and Globalization. UCL Press, 2018, p. 144.

⁶⁷ CORMEN, T.H. *Algorithms Unlocked*. MIT Press, 2013, p. 1.

⁶⁸ O'NEIL, Cathy. *Weapons of math destruction*. How big data increases inequality and threatens democracy. New York: Crown Publishers, 2016.

⁶⁹ DONEDA, DANILO ; Almeida, Virgilio A.F. . What Is Algorithm Governance?. IEEE Internet Computing, v. 20, p. 60-63, 2016, p. 60.

para gerarem um resultado específico⁷⁰ (*output*). Os algoritmos são utilizados em varias indústrias diferentes, mas para fins do estudo das estruturas repetitivas, eles são o maquinário, que permite identificar e entender uma repetição, um modelo⁷¹ a ser seguido⁷². A partir da compreensão das estruturas do modelo, ou seja, dos seus padrões, o algoritmo consegue viabilizar um estudo estatístico específico para o *big data* – chamado *data mining*, que será analisado a seguir – e produzir uma resposta que representa, ao menos em tese, a melhor forma de desempenhar a tarefa que lhe foi designada. Assim, há um propósito final na análise de dados, e é isso que dá coesão estrutural ao *big data*.

Toda a automatização do processo decisório diz respeito, portanto, à uma capacidade matemática de analisar o vasto conteúdo, identificar padrões semelhantes, criar um modelo promover, em tempo muito curto, uma perspectiva estatisticamente respaldada de qual será o resultado mais provável de dar certo. É isso que o algoritmo faz. Existem vários tipos distintos, mas, para fins deste trabalho, destacam-se apenas dois: os algoritmos preditivos, que objetivam antecipar fatos futuros com base na análise de dados históricos⁷³; e os algoritmos de otimização, que se prestam a reduzir os custos de transação e produção de determinada atividade econômica⁷⁴.

O algoritmo é uma estrutura matemática e é preciso ensiná-lo a analisar os padrões e a fazer as leituras importantes para o processo decisório específico. Na maior parte das vezes, isso é feito pelos programadores através de processo de aprendizagem de espelhamento de informações no próprio algoritmo. Alguns deles operam, nesse sentido, através de *screening decisions*, que são quando dois algoritmos distintos trabalham em conjunto para selecionar uma pessoa - ou várias - dentro de um grupo maior, com objetivo de atender a uma finalidade específica⁷⁵. Outra forma de aprendizagem do algoritmo é através da leitura de modelos previamente desenhados por um ser humano⁷⁶, com o

⁷⁰ GOETTENAUER, Carlos Eduardo. Algoritmos, Inteligência Artificial, Mercados. Desafios ao arcabouço jurídico. In: FRAZÃO, Ana; CARVALHO, Angelo Gamba Prata de. *Empresa, Mercado e Tecnologia*. Belo Horizonte: Fórum, 2019, p. 270.

⁷¹ Por modelo, define-se uma percepção reduzida da realidade.

⁷² BAROCAS, Solon; SELBST, Andrew D. *Big Data's disparate impact*. California Law Review, 2016, p. 2.

⁷³ GOETTENAUER, Carlos Eduardo. Algoritmos, Inteligência Artificial, Mercados. Desafios ao arcabouço jurídico. In: FRAZÃO, Ana; CARVALHO, Angelo Gamba Prata de. *Empresa, Mercado e Tecnologia*. Belo Horizonte: Fórum, 2019, p. 277.

⁷⁴ GOETTENAUER, Op. cit., 2019.

⁷⁵ KLEINBERG, Jon; et. al. *Discrimination in the age of algorithms*, 2019, p. 1.

⁷⁶ BAROCAS, Solon; SELBST, Andrew D. *Big Data's disparate impact*. California Law Review, 2016, p. 2.

programador que se responsabiliza por inserir os conteúdos e ensinar quais são os resultados esperados.

Esses algoritmos performam vários tipos de tarefas distintas. Eles são responsáveis por estruturar análises de créditos, decisões judiciais, previsões estatísticas, meteorologia, funcionamento de bolsas de valores e até de inteligência artificial. Mais que isso, os algoritmos são responsáveis por toda a sofisticação das maiores corporações existentes no mundo, justamente porque, foi a partir delas – complexas fórmulas matemáticas que resolvem problemas através de um método –, que os modelos de negócios foram intensamente modificados e se tornaram mais eficientes⁷⁷. Como exemplos dessa revolução estrutural dos agentes de mercado, tem-se a Google, que, utilizando um algoritmo, unificou quase toda a internet em uma única plataforma de busca; a Amazon, conseguiu difundir a leitura de livros clássicos e construir perfis de interesse para direcionamento de conteúdo; e o Facebook, que possibilitou a conexão de milhares de pessoas de forma simultânea⁷⁸.

Uma outra característica relevante em relação aos algoritmos, e que possui especial importância para fins deste estudo, diz respeito à sua capacidade de desempenho autônomo. Juntamente com o *big data*, e sabendo que a quantidade de dados analisados muitas vezes pode ser imensurável, costuma-se dizer que os algoritmos conseguem produzir *outputs* incontrolláveis, independentemente dos desejos e intenções do programador⁷⁹. Portanto, a análise estatística feita pelos algoritmos com o *big data* se dá em uma quantidade incalculável que, muitas vezes, sequer é possível compreender como os resultados foram alcançados⁸⁰. É isso que é a opacidade dos algoritmos, ou seja, a falta de conhecimento direto acerca de seus critérios de funcionamento.

Existem casos famosos que representam justamente essa incapacidade de controle dos resultados produzidos, e que geraram grandes repercussões para os agentes de mercado. Um deles ficou conhecido como caso Tay, um *software* de inteligência artificial desenvolvido pela Microsoft, com o objetivo de mimetizar comportamentos do Twitter, e interagir, de forma autônoma, com os usuários. O único controle inicial que os programadores possuíam em relação à Tay dizia respeito à estrutura operacional do

⁷⁷ FINN, Ed. *What Algorithms Want*. Imagination in the age of Computing. Cambridge: MIT Press, 2017, p. 20.

⁷⁸ FINN, Op. cit., 2017, p. 20.

⁷⁹ DONEDA, Danilo; ALMEIDA, Virgílio A.F.. What Is Algorithm Governance?. IEEE Internet Computing, v. 20, p. 60-63, 2016, p. 60.

⁸⁰ DONEDA; ALMEIDA, Op. cit., 2016, p. 60.

software, e como ela deveria aprender e mimetizar as interações para postar em seu perfil coisas relacionadas aos usuários que com ela conversavam⁸¹.

Os programadores não poderiam imaginar, contudo, que os usuários do Twitter que iriam interagir com a Tay seriam racistas, nazistas e homofóbicos, e iriam acabar ensinando o programa a mimetizar comportamentos que são considerados crimes. Em poucos dias, a Tay estava postando em sua página da rede social frases desprezíveis que obrigaram a Microsoft a retirá-la do ar e fazer um pedido público de desculpas aos que se sentiram ofendidos⁸².

Esse caso reflete a incapacidade de os programadores controlarem os resultados dos algoritmos, mas também mostra que a estrutura deve estar, em verdade, sujeita aos desejos e interesses dos seres humanos. Assim, a Tay poderia ter sido criada com um mecanismo matemático que barrasse a reprodução desses tipos de comportamentos, o que não iria mitigar a opacidade de sua estrutura, mas iria, por assim dizer, controlá-la.⁸³

Outro caso interessante e mais recente é o da empresa Google, a qual foi compelida a modificar sua estrutura algorítmica a fim de que os resultados produzidos a partir de buscas específicas como “mulheres negras” e “mulheres lésbicas” não remetesse a uma hiperssexualização das mulheres, ou fetichização de suas características⁸⁴. As pesquisas por esses termos, até pouco tempo, sempre mostravam imagens pornográficas como primeiros resultados, e isso causava diversos prejuízos às mulheres que não se sentiam representadas, ou que acabavam sendo associadas à pornografia, em um reforço de estereótipos prejudiciais ao gênero. Em alguma medida, esses resultados foram atribuídos à opacidade do algoritmo, responsável pela produção de resultados supostamente incontroláveis pela empresa.

Contudo, algum tempo depois, e também em decorrência da forte pressão que a empresa estava sofrendo, a Google conseguiu fazer modificações na sua estrutura algorítmica para que esses resultados não deixassem de aparecer, mas que não figurassem mais nos primeiros itens. No lugar, o algoritmo agora consegue associar as palavras

⁸¹ MULLER, Léo. *Tay: Twitter conseguiu corromper a IA da Microsoft em menos de 24 horas*, 2016. Disponível em: <<https://www.tecmundo.com.br/inteligencia-artificial/102782-tay-twitter-conseguiu-corromper-ia-microsoft-24-horas.htm>>; acesso em 22 ago 2019.

⁸² MAGRANI, Eduardo. *Entre dados e robôs*. Ética e privacidade na era da hiperconectividade. Porto Alegre: Arquipélago Editorial, 2019, p. 170.

⁸³ MAGRANI, Eduardo. *Entre dados e robôs*. Ética e privacidade na era da hiperconectividade. Porto Alegre: Arquipélago Editorial, 2019, p. 170.

⁸⁴ NOBLE, Sofiya Umoja. *Algorithms of Oppression*. How Search Engines Reinforce Racism. New York University Press, 2018, p. 54.

buscadas a imagens representativas, com mulheres negras e lésbicas em situação de orgulho, e não de pornografia⁸⁵.

Novamente, esse caso retrata a opacidade dos algoritmos e a falta de controle que os agentes têm em relação aos resultados produzidos. Contudo, retrata também a possibilidade de uma atuação positiva para controlar, minimamente, o algoritmo desenvolvido, fazendo com que o produto final daquele processo automatizado esteja sujeito aos interesses humanos. E isso não poderia ser diferente, porque seria no mínimo fatalista considerar que os processos automatizados, criados por seres humanos para melhor alcançarem seus objetivos, tornaram-se completamente dissociados dos seus desejos e são incontroláveis. Essa distopia é decorrente da opacidade dos algoritmos, mas ela não impõe uma sujeição dos agentes às máquinas.

Inclusive, a opacidade pode ser interpretada como algo que beneficia os agentes de mercado e não que os prejudica em razão da incapacidade de controle de resultados. Isso porque, através da opacidade, os agentes conseguem proteger suas estruturas matemáticas por meio de segredos industriais, garantindo vantagens econômicas e concorrenciais com a não divulgação de suas fórmulas e seus métodos de funcionamento⁸⁶. É de fácil percepção que os algoritmos desenvolvidos pelas empresas lhes trazem mais benefícios que prejuízos, e que a opacidade não é efetivamente um problema quando se está lucrando com a automatização de processos feita sem qualquer controle. Esses lucros também vêm por outros caminhos que não o da desregulação, e são o da não superação desses modelos de negócios e da manutenção de determinados monopólios.⁸⁷

Foi nesse contexto que cresceram as discussões da necessidade de transparência no tratamento de dados pessoais, principalmente sob o argumento de que os algoritmos são verdadeiras “caixas-pretas” (*black boxes*)⁸⁸, sob as quais os usuários não possuem qualquer controle, e que são comumente difundidos como essencialmente opacos, mas que costumam ser livremente manipulados pelos interesses dos agentes de

⁸⁵ NOBLE, Op. cit., 2018 e MARINHO, Julia. *Google muda algoritmo para que 'lésbica' não seja mais sinônimo de 'pornô'*, 2019. Disponível em: <<https://www.tecmundo.com.br/internet/144805-google-muda-algoritmo-lesbica-nao-seja-sinonimo-porno.htm>>; acesso em 22 out 2019.

⁸⁶ DONEDA, Danilo; ALMEIDA, Virgílio A.F. *What Is Algorithm Governance?*. IEEE Internet Computing, v. 20, p. 60-63, 2016, p. 61.

⁸⁷ DONEDA; ALMEIDA, Op. cit., 2016, p. 61.

⁸⁸ PASQUALE, Frank. *The Black Box Society: The Secret Algorithms That Control Money and Information*, Harvard University Press, 2015.

mercado em busca de lucros e do fortalecimento de seus monopólios no mercado de dados.

Frank Pasquale diz, inclusive, que não há uma tradição de transparência por parte da ciência, e, no mercado de tratamento de dados pessoais, essa tradição se transformou em desejo, por parte dos agentes, de que eles mantenham obscuras suas técnicas de funcionamento em relação às informações dos usuários, como mencionado anteriormente sobre os algoritmos. Há uma construção social de que o conhecimento só existe nos limites em que permitido socialmente, e isso por um motivo simples: conhecimento é poder⁸⁹. Assim, a relação de hipossuficiência entre os usuários e os agentes se acentua, porque o poder em relação aos dados é exclusivo dos agentes.

Essas considerações acerca dos algoritmos são imprescindíveis para este trabalho. Primeiro, porque são relevantes para compreensão de como são organizados os processos automatizados e como é possível que o *big data* consiga ser utilizado pelos agentes de mercado. Segundo, porque a própria estrutura pode, em determinadas circunstâncias, ser objeto de análise por parte dos agentes reguladores, justamente porque ela tem um potencial de causar prejuízos das mais variadas naturezas, desde os concorrenciais, até os sociais, bem como o da discriminação de gênero abordada neste estudo.

1.3.2 *Data mining*

O *data mining* diz respeito ao mecanismo de estudo estatístico do *big data*, ou seja, da identificação automatizada dos padrões constantes nos dados⁹⁰, com o objetivo de ser produzido um resultado ou uma predição final.

Analisando-se a forma de funcionamento do *data mining*, ou seja, a maneira como os algoritmos conseguem extrair informações dos dados, percebe-se que, em sua essência, essa tecnologia pressupõe um tipo de discriminação estatística⁹¹: são matematicamente selecionados os padrões mais semelhantes e esses são agrupados em

⁸⁹ PASQUALE, Op. cit., 2015, pp. 4/6.

⁹⁰ CALDERS, Toon; CUSTERS, Bart. What is Data Mining and How Does It Work? In: CUSTERS, Bart et al. (Org.). *Discrimination and Privacy in the Information Society*. Data Mining and Profiling in Large Databases. Springer: 2013, p. 27.

⁹¹ BAROCAS, Solon; SELBST, Andrew D. *Big Data's disparate impact*. California Law Review, 2016, p. 7.

perfis que conseguem prever seus interesses comuns. Com isso, é possível retratar, para dentro de uma base de dados, um cenário similar ao da realidade⁹².

Apesar de representar um tipo de análise estatística, esse mecanismo possui relevantes diferenças em relação aos estudos estatísticos propriamente ditos, que são produzidos por pesquisadores e institutos científicos renomados. Essas diferenças se relacionam quanto à metodologia de obtenção da estatística, que costuma ser muito rígida nos estudos científicos e pouco cuidadosa nas análises de *data mining*. É isso porque, no desenvolvimento de pesquisas estatísticas avançadas, há uma etapa importante do processo que diz respeito à coleta de dados, que é feita exclusivamente para aquele fim, de forma específica e planejada para alcançar as finalidades daquele estudo⁹³. Já no *data mining*, a coleta de dados é feita de forma indiscriminada, sem critérios em relação à fonte da coleta ou à forma de armazenamento do conteúdo⁹⁴.

Ainda em relação ao *data mining*, percebe-se que ele, juntamente com o *big data*, e através dos algoritmos que possibilitam as previsões, foram responsáveis por conquistarem, no imaginário humano, a ideia de que as decisões automatizadas são as melhores possíveis. Isso se deve ao fato de que a quantidade de dados analisados, a profundidade dos agrupamentos e a criação dos perfis transcendem a capacidade humana⁹⁵. Associando-se, ainda, a ideia de que o estudo estatístico tem presunção científica por se tratar de uma análise matemática quantitativa, também se permitiu difundir a ideia de neutralidade, pois o resultado final produzido diz respeito, exclusivamente, a um resultado calculado por uma fórmula.

Além disso, o uso desse tipo de tecnologia assegurou diversos avanços na desburocratização de tomada de decisões. Com o uso de algoritmos e do *big data*, o *data mining* permitiu que fossem construídos padrões preditivos aptos a decidirem questões relevantes, diminuindo custos para fazê-lo, possibilitando a sistematização da orientação

⁹² BAROCAS; SELBST, Op. cit., 2016, p. 7.

⁹³ CALDERS, Toon; CUSTERS, Bart. What is Data Mining and How Does It Work? In: CUSTERS, Bart et al. (Org.). *Discrimination and Privacy in the Information Society*. Data Mining and Profiling in Large Databases. Springer: 2013, p. 27

⁹⁴ CALDERS; CUSTERS, Op. cit., 2013, p. 27

⁹⁵ É o que Christin et. al. diz ao mencionar que “os algoritmos preditivos racionalizaram o processo de tomada de decisão resumindo todas as informações relevantes de uma forma mais eficiente do que o cérebro humano”[Predictive algorithms rationalize the decision-making process by summarizing all relevant information in a more efficient way than the human brain] In: CHRISTIN, Angèle; ROSENBLAT, Alexa; BOYD Danah. Courts and Predictive Algorithms. Nova Iorque: New York University, Criminal Justice Policy Program, 27 de outubro de 2015. Disponível em: <http://www.law.nyu.edu/sites/default/files/upload_documents/Angele%20Christin.pdf> Acesso em: 30.08.2017.

em decisões similares e, ao menos em tese, eliminando vieses subconscientes do processo decisório, tendo em vista que toda a estruturação da resposta final teria sido matemática.

De fato, a tomada de decisão humana possui diversos elementos incontroláveis de natureza subconsciente, muitas vezes dotados de vieses e subjetividades, como já analisou Daniel Kahneman⁹⁶. Esses elementos subjetivos dizem respeito às vivências pessoais de cada um, às opiniões políticas, às relações de poder estabelecidas, dentre outras questões que podem eliminar a racionalidade absoluta de uma decisão⁹⁷. Por isso, os programas que se utilizam de *data mining* se tornaram saídas que afastam a subjetividade e tentam trazer racionalidade ao processo decisório.

Ocorre que, nessa análise estatística, há certa opacidade, no mesmo sentido em que se fala dos algoritmos. Não se pode dizer que existe algum tipo de transparência sobre como são feitos esses estudos estatísticos em massa, quais dados são analisados e de que forma as decisões finais são tomadas, se elas representam realmente o melhor resultado matemático ou se representam o melhor resultado para aquele agente de mercado específico. É nesse ponto que se insere a importância da compreensão do *data mining* para este estudo.

Percebe-se, ao fim, que todas as definições também estão interligadas. Compreender, como feito no início deste Capítulo, o que são dados pessoais e suas variações, e também como funciona o *big data*, auxilia a perceber como ocorreram mudanças estruturais significativas na sociedade em razão do desenvolvimento tecnológico. As tecnologias preditivas são um resultado desse desenvolvimento, e são apenas um fruto de intenso aprimoramento da análise massiva de dados e de construção de perfis dos usuários através de máquinas.

⁹⁶ KAHNEMAN, Daniel. *Thinking, Fast and slow*. Ferrar, Straus & Giroux, 2011.

⁹⁷ KAHNEMAN, Op. cit., 2011.

CAPÍTULO 2

GÊNERO E TECNOLOGIA

2.1 O contexto da preocupação entre desigualdade e tecnologia

Como exposto no Capítulo 01, o processo decisório automatizado é fruto do intenso desenvolvimento tecnológico, que conseguiu associar a criação de máquinas ao tratamento de dados pessoais em massa, com a finalidade de gerarem previsões estatísticas de múltiplas finalidades.

Algumas autoras associam os primórdios desse desenvolvimento tecnológico ao contexto de intensa militarização pós-segunda guerra mundial⁹⁸, quando predominava o ambiente de disputas territoriais a nível mundial e a produção científica era essencialmente masculina⁹⁹. Esse entendimento se justifica pelo fato de que diversas produções criadas exclusivamente para atender às necessidades da guerra migravam para a sociedade civil e eram aproveitadas também por outros agentes de mercado, em outros contextos.

De fato, muita produção científica é fruto dessa época, mas isso também se deve ao fato de que as pesquisas na área de tecnologia eram muito incentivadas no período. A premissa de que o desenvolvimento tecnológico está apenas associado à militarização, contudo, não é necessariamente verdadeira, principalmente quando se considera que o *big data* – que foi a principal tecnológica responsável pelas modificações estruturais da sociedade e dos mercados - foi desenvolvido por empresas privadas que buscavam aprimorar seus modelos de negócios.

As grandes discussões acerca desse desenvolvimento tecnológico, contudo, não dizem respeito, necessariamente, o debate sobre de suas origens. Elas abordam, em suma, a possibilidade de os seres humanos exercerem o seu controle, e não serem manipulados por ela, e começaram a ocorrer quando os contornos da internet, cuja expansão se deu em meados de 1990, foram primeiramente percebidos pela população e pelos governos.

⁹⁸ LEURS, Koen; SHEPHERD, Tamara. Datafication & Discrimination. In: SCHÄFER, Mirko Tobias; ES, Karin Van. *The Datafield Society. Studying Culture Through Data*. Amsterdam University Press, 2017, p. 211.

⁹⁹ COCKBURN, Cynthia. *Male Dominance and Technological Change*. Pluto press: London, 1983.

Como narra Lessig, essa popularização da internet não foi planejada nem controlada, mas acabou ocorrendo com a pretensão de se criar um espaço idealizado de absoluto exercício da liberdade, em contexto de anarquia. Tinha-se a ideia de que era possível exercer “*o controle, sem os governos, o consenso sem poder*”¹⁰⁰. E isso se deve ao contexto da época. Vivia-se grande frustração com os prejuízos causados pela Segunda Guerra Mundial e com o fim da Guerra Fria, de modo que a pretensão dos usuários que ingressaram no mundo virtual nos primeiros momentos era a própria fuga da realidade e de seus desdobramentos.

A falta de controle e limites da internet logo começaram a causar preocupações nos governos, notadamente quando se percebeu que (i) tratava-se de um espaço em que não se poderia assegurar a segurança jurídica e a força vinculante dos contratos; (ii) determinados agentes de mercado estavam conseguindo excessivo poder através do controle dos dados pessoais que estavam conseguindo coletar; e (iii) a liberdade, premissa fundante desse espaço, estava sendo prejudicada.

Especificamente em relação ao primeiro ponto, os governos verificaram que o cyberspaço criado pela internet aumentou o fluxo de informações entre países a ponto de provocar conflitos sobre quais as leis seriam aplicáveis, e também sobre quais eram as autoridades em relação aquele espaço¹⁰¹. A quantidade de informação produzida a nível global aumentou em um tempo muito mais curto¹⁰² também porque a internet alterou a dinâmica de compartilhamento de conteúdo e difusão da informação, viabilizando a criação de novas estruturas – como as redes sociais –, que intensificaram a produção de notícias e o acesso a elas¹⁰³.

A própria ausência de limites territoriais do cyberspaço fez com que surgissem questionamentos em relação aos valores essenciais ao liberalismo, que se

¹⁰⁰ LESSIG, Lawrence. *Code*. Version 2.0. New York: Basic Books, p. 3. A esse respeito, o autor ainda cita uma frase interessante do manifesto que foi difundido à época, no qual se diz: “We reject: kings, presidents and voting. We believe in: rough consensus and running code.” [Tradução Livre: Nós rejeitamos: reis, presidentes e votações. Nos acreditamos em consensos e códigos.]

¹⁰¹ GOLDSMITH, Jack; WU, Tim. *Who Controls the Internet? Illusions of Borderless World*. Oxford University Press, 2006.

¹⁰² Estima-se que, com o advento do *big data*, houve um crescimento exponencial da quantidade de informação no mundo, de modo que, entre os anos de 1453 e 1503, tem-se que a quantidade de informação na Europa duplicou, o que foi medido pela quantidade de livros produzidos à época. Já em 2013, com a consolidação dessas novas tecnologias, dobrar a quantidade de informação no mesmo continente levaria apenas três anos. (MAYER-SCHONBERGER, Viktor; CUKIER, Kenneth. *Big data*. Como extrair volume, variedade, velocidade e valor da avalanche de informação cotidiana. 1. ed., Rio de Janeiro: Elsevier, 2013, p. 5.)

¹⁰³ LEVY, Pierre. *Cibercultura*. Editora 34, 2010, p. 121.

sagrara vitorioso da Guerra Fria. São exemplos as formas com as quais se poderia assegurar validade aos contratos, ou como seria protegida a propriedade intelectual¹⁰⁴.

À época, Reindeberg, por exemplo, criou o conceito de Lex Informática, a partir da ideia de era necessário exercer algum tipo de regulação sobre a internet, para garantir quais as bases legais comuns seriam utilizadas¹⁰⁵. E a melhor forma de fazê-lo não necessariamente era através da lei ou do direito, mas sim a partir da própria tecnologia¹⁰⁶, ou, como entendeu Lessig em seguida, a partir do próprio código da internet¹⁰⁷.

A segunda preocupação que inaugurou essas discussões foi a do surgimento de monopólios de agentes que tratavam dados pessoais. Através da internet, aumentou-se muito a possibilidade de coleta de dados pessoais, e algumas empresas específicas desenvolveram grande capacidade de manipulação dos usuários, através de técnicas comportamentais de análise de dados e criação de perfis¹⁰⁸. Decorrente dessa preocupação, aprofundaram-se os debates acerca de privacidade, principalmente porque a datificação da vida estava transformando as interações em dados pessoais, permitindo uma identificação e um mapeamento muito preciso dos desejos e interesses de cada usuário¹⁰⁹.

A terceira preocupação, por sua vez, decorreu da subversão do ideal de liberdade que havia sido o causador da expansão da internet. Toda a estruturação inicial da internet estava inserida em um contexto de liberdade, de emancipação das pessoas que criavam uma comunidade através dessa nova sociedade que surgia. E, nessa época, era comum acreditar que esse cyberspaço, por representar tão essencialmente a liberdade, iria acabar dirimindo certos preconceitos existentes na sociedade, até porque todos seriam um código igual na rede, impassíveis de discriminações como de raça e de gênero¹¹⁰.

Com o tempo, contudo, percebeu-se que essa não era a realidade. O cyberspaço estava se aprimorando para limitar o exercício da liberdade individual, na

¹⁰⁴ JOHNSON, David R.; POST, David. *Law and Borders*. The rise of Law in Cyberspace. In: Stanford Law Review, v. 48, 1996.

¹⁰⁵ REIDENBERG, Joel. *Lex informatica*. The formulation of policy rules through technology, 1998, p. 554.

¹⁰⁶ REIDENBERG, Op. cit. 1998.

¹⁰⁷ LESSIG, Lawrence. *Code*. Version 2.0. New York: Basic Books.

¹⁰⁸ Ver, nesse sentido: ZUBOFF, Shoshana. *The age of surveillance capitalism. The fight for a human future at the new frontier of power*. New York: Public Affairs, 2019.

¹⁰⁹ HELMS, Shawn. *Translating privacy values with technology*, 2001, p. 3

¹¹⁰ NISSENBAUM, Helen. *Etichs*. In NISSENBAUM, Helen, *Information Technology and Etchics*, Berkshire Encyclopedia of Human-Computer Interaction, BerkShire Publishing Group, 2004, p. 235-239.

medida em que os usuários não poderiam se manifestar espontaneamente, e que todos os preconceitos socialmente difundidos estavam permeados no cyberspaço¹¹¹. As pessoas não eram tratadas como iguais e os relacionamentos que lá se estabeleciam não estavam livres das amarras socialmente existentes fora do espaço virtual.

Os governos começaram, então, a criar formas de controle da *internet*, principalmente com o objetivo de garantir a territorialidade. Criaram-se políticas de controle extraterritorial das condutas, mecanismos para se assegurar força aos negócios jurídicos e instrumentos para garantir a proteção da propriedade intelectual¹¹². Isso acabou culminando no que alguns chamam de “morte da internet”¹¹³, mas não ocorreu só pelos governos, como também pelos próprios agentes de mercado, os quais começaram a estruturar suas redes de forma direcionada aos usuários de cada país. O código foi sendo moldado para a criação de uma nova rede com base nas diferenças culturais, linguísticas e econômicas, de modo que a geografia se tornou um *proxy* importante para diferenciar interesses e preferências destinadas aos usuários¹¹⁴.

Apesar das tentativas de controle, as mudanças decorrentes desse período de desregulação foram inevitáveis e o mundo foi profundamente modificado sob as mais variadas perspectivas. Na cultura, por exemplo, percebeu-se a emancipação das revoluções. Antes, elas estavam sujeitas a grandes acontecimentos, como foi o caso das duas primeiras ocorridas entre os anos de 1780-1950, em razão da Revolução Industrial e da Segunda Guerra Mundial. Depois da popularização da internet e do uso do *big data*, essas grandes mudanças culturais se tornaram independentes de eventos paradigmáticos específicos, e passaram a depender, apenas, do desejo dos usuários em razão do fácil acesso à informação¹¹⁵.

As relações sociais também já vinham se alterando, porque, com a internet, os relacionamentos e formas de comunicação já não eram mais os mesmos¹¹⁶. Passou-se

¹¹¹ NAKAMURA, Lisa. *Gender and Race Online*. In: GRAHAN, Mark; DUTTON, Willian H. *Society and the Internet: How Networks of information and Communication are Changing Our Lives*. Oxford Scholarship Online, 2014.

¹¹² GOLDSMITH; WU, Op. cit., 2006.

¹¹³ GOLDSMITH, Jack; WU, Tim. *Who Controls the Internet? Illusions of Borderless World*. Oxford University Press, 2006.

¹¹⁴ GOLDSMITH; WU, Op. cit., 2006.

¹¹⁵ STRIPHAS, Ted. Algorithmic culture. In: *European Journal of Cultural Studies*, 2015, vol. 18, p. 395-412.

¹¹⁶ Apesar disso, também foi estabelecido um fluxo de influência cultural, que fez com que grandes formadores de opiniões e conteúdos, que já eram muito poderosos antes do advento do *big data*, lucrassem ainda mais e expandissem seus horizontes de interferência (in: CASTELLS, Manuel. *O poder da comunicação*. São Paulo: Paz e Terra, 2016.)

a priorizar a conexão virtual, e se fortaleceu a estrutura cooperativa internacional, que promoveu o encurtamento das distâncias, a modificação das noções de tempo¹¹⁷, e a alteração da ideia de relacionamentos¹¹⁸.

Em decorrência desse ambiente pouco controlado, a internet e o *big data* também causaram o fenômeno da datificação da vida¹¹⁹, porque todos os relacionamentos foram transportados para o mundo virtual e viraram dados que impulsionam e reforçam essa migração da realidade, como mencionado no Capítulo 01. Foi nesse contexto que se fundaram os monopólios dos agentes de dados, porque as menores experiências cotidianas se tornaram dados comportamentais com informações que agora poderiam ser analisadas em um grande volume, em muito pouco tempo. E, a partir disso, a automatização ganhou mais força, justamente com a criação de perfis e a viabilização das análises preditivas¹²⁰.

Em relação à política, essas modificações ocorreram na esfera de poder mundial, permitindo redefinir a importância da informação no contexto social¹²¹ e transformando o acesso ao conteúdo em uma verdadeira estrutura de poder¹²². O objetivo inicial da internet chegou a ser alcançado, porque, de fato, criou-se um novo tipo de sociedade, prestigiando a maior autonomia dos cidadãos. Não ocorreram, contudo, as mudanças políticas profundas pretendidas pelos usuários nos primórdios do cyberspaço, porque a política também chegou na internet.

Surgiu uma força de organização que permitiu a ocupação de espaços públicos, a divulgação de práticas condenáveis pelo público internacional (que antes estavam presas nos segredos de cada país), e organização de uma oposição aos regimes totalitários¹²³. Foi a partir desse contexto que a algumas populações foi oportunizada a

¹¹⁷ LEVY, Pierre. *Cibercultura*. Editora 34, 2010, p. 124.

¹¹⁸ Aqui, ficam ressalvados os lugares que não participaram sequer da segunda ou terceira revolução industrial, e que sofrem com o isolamento tecnológico em razão de suas condições de vulnerabilidade e pobreza.

¹¹⁹ MAYER-SCHÖNBERGER, V. and CUKIER, K. *The Rise of Big Data: How It's Changing the Way We Think*. *Foreign Affairs*, vol. 92, no. 3, May/June, 2013.

¹²⁰ ZUBOFF, Shoshana. *The age of surveillance capitalism. The fight for a human future at the new frontier of power*. New York: Public Affairs, 2019, p. 21.

¹²¹ MAYER-SCHONBERGER, Viktor; CUKIER, Kenneth. *Big data*. Como extrair volume, variedade, velocidade e valor da avalanche de informação cotidiana. 1. ed., Rio de Janeiro: Elsevier, 2013, p. 66.

¹²² PASQUALE, Frank. *The Black Box Society: The Secret Algorithms That Control Money and Information*, Harvard University Press, 2015.

¹²³ CASTELLS, Manuel. *Networks of Outrage and Hope*. Social movements in the internet age. Cambridge: Polity Press, 2a ed. 2015.

possibilidade de redesenhar os contornos de suas próprias histórias¹²⁴, ainda que isso não tenha sido feito de forma oposição da população à regimes totalitários abrangente.

O que se tem hoje, contudo, é que essa auto-organização não ocorreu sozinha, já que a internet e o *big data* também viabilizaram a criação de novas formas de controle e de vigilância, para que as estruturas de poder conseguissem se solidificar com o objetivo de manter a dinâmica econômica mundial. Na época em que surgiram os debates de regulação, os governos intensificaram o uso dessas tecnologias para desburocratizarem suas estruturas e aprimorarem as formas que possuíam de poder e autoridade. Por esse motivo, as formas de monitoramento e investigação ganharam contornos sem precedentes: computadores e câmeras sofisticadas permitem identificar bombas à distância, mapear o trajeto de um indivíduo, localizar criminosos em meio a uma multidão, controlar fronteiras, dentre tantas outras tarefas.

Ao fim, foi possível perceber profundas mudanças ocorridas na sociedade. Mais importante ainda, foi possível perceber que toda a criação da internet, e o desenvolvimento de ferramentas de controle, e também de tecnologias que fortaleceram sua existência – como é o caso do *big data* – decorreram de uma primeira desregulação do espaço cibernético, de modo que, quando diversas discussões sobre a importância da regulação, e também as formas de fazê-la, começaram a surgir, já havia uma desvantagem técnica dos reguladores em relação aos agentes de mercado, além de uma realidade consolidada, com mudanças estruturais na vida cotidiana, grandes monopólios de tratamento de dados pessoais e pouco controle sobre como, de fato, funcionava esse novo mundo.

Até hoje existe um intenso debate sobre como é possível regular a internet, e como se pode controlar o funcionamento do *big data*. Mas já se pode perceber as consequências ocasionadas desse atraso da regulação em relação ao advento dessas tecnologias: dentre tantas outras coisas – como as implicações concorrenciais, políticas, sociais, econômicas e até em relação à própria crise da democracia - a perpetuação da desigualdade é a que se destaca neste estudo.

Essa perpetuação da desigualdade é fruto de um dos principais motivos que ensejaram a chamada “morte da internet”, justamente porque afronta diretamente o ideal da liberdade que era anteriormente difundido. E esse prejuízo à liberdade teve início muito antes de os usuários perceberem que os preconceitos estavam sendo transportados

¹²⁴ CASTELLS, Op. cit. 2015.

para a realidade virtual, justamente porque toda a quarta revolução industrial, que viabilizou essa difusão da internet e da coleta de dados em massa, foi, em verdade, fundada na desigualdade e na exclusão de determinados grupos. Isso porque, ela foi considerada global, mas acabou por excluir mais da metade dos países do mundo através da não democratização do acesso à elementos básicos para a sobrevivência na era moderna, como a própria energia elétrica¹²⁵. O desenvolvimento tecnológico se destinou a aumentar as riquezas dos países que tiveram acesso a essas tecnologias, mas muito pouco a compartilha-la com outros países.

Além disso, e em razão da criação de grandes monopólios de agentes que coletavam dados pessoais, essa revolução industrial fez aumentar ainda mais a distância e a desigualdade no relacionamento entre os agentes de mercado e os usuários. Diz-se que, com o acesso à informação, essa relação hipossuficiente tenderia a diminuir, mas a verdade é que os poderes adquiridos pelos agentes através do tratamento de dados com foco em predição comportamental assumiram contornos incontroláveis, e sujeitaram os usuários a uma situação de submissão ainda maior das vontades de mercado¹²⁶.

Nesse contexto, e considerando que a difusão da internet estava repetindo o padrão de desenvolvimento tecnológico discriminatório até então existente – onde os países não compartilhavam entre si as tecnologias para que o crescimento fosse global – e também estavam aprofundando relações de hipossuficiência já existentes, era inevitável que os preconceitos em relação às minorias também fosse reproduzido no cyberspaço.

Especificamente em relação às mulheres, percebe-se que o *big data* intensificou a reprodução de estereótipos de gênero e que, no lugar de promover a inclusão das mulheres pelo acesso, muitas vezes, foi um grande catalisador da exclusão desse grupos a partir do reforço dos padrões tão prejudiciais à luta pela igualdade¹²⁷. E isso foi percebido nos mais variados ambientes, desde salas de relacionamento, nas quais as mulheres eram julgadas por suas condutas, ainda que fossem pudicas ou libertárias, até as salas de jogos virtuais, nas quais elas eram excluídas e desrespeitadas ao longo das interações com os outros jogadores, simplesmente por serem mulheres¹²⁸.

¹²⁵ LERMAN, Jonas. *Big data and Its Exclusions*. Stanford Law Review, v. 66, 2013.

¹²⁶ ZUBOFF, Shoshana. *The age of surveillance capitalism*. The fight for a human future at the new frontier of power. New York: Public Affairs, 2019.

¹²⁷ KIRK, Mary. *Gender and Information Technology*. Moving beyond access to co-create global partnership. New York: Information Science Reference, 2009, p. 113.

¹²⁸ NAKAMURA, Lisa. Gender and Race Online. In: GRAHAN, Mark; DUTTON, Willian H. *Society and the Internet: How Networks of information and Communication are Changing Our Lives*. Oxford Scholarship Online, 2014.

Também esse foi um campo que a regulação, quando começou a ser debatida, não conseguiu coibir, a ponto de hoje em dia, no auge das discussões sobre predições e inteligência artificial, ainda é necessário mapear em que etapas pode ocorrer a discriminação, e de que forma os agentes precisam enfrentar essa questão.

2.2 A tecnologia como vetor de promoção da desigualdade entre homens e mulheres

Aa internet se propunha, inicialmente, a ser uma organização livre, sem qualquer grupo de controle. Mas a própria criação de fronteiras à rede, o surgimento de formas de controle e o exercício de poder por parte dos Estados, e também o surgimento do *big data*, com a datificação das relações, criaram uma realidade social, política, econômica e financeira muito distinta. Essa realidade vem sendo objeto de profundas análises e diversos de seus desdobramentos são pautas de críticas por parte dos doutrinadores que debatem formas e motivos para a regulação. Dentre essas várias modificações, o presente estudo tem foco na análise das relações entre o gênero e a tecnologia.

Já existe, em alguma medida, debate acerca da relação entre discriminação de minorias em relação à tecnologia. Alguns estudos mais recentes vêm analisando a capacidade preditiva dos algoritmos à luz do racismo e do preconceito de classe, e de que forma o *big data* atou como vertente para, em algumas circunstâncias, intensificar disparidades preexistentes¹²⁹. Contudo, dentro das questões sociais, o presente estudo busca focar em um único desdobramento do uso da internet e também do *big data*, especificamente no que diz respeito ao tratamento automatizado de dados pessoais para tomada de decisões, qual seja o da discriminação de mulheres. E, para fazê-lo, é importante entender como se deu a relação entre as mulheres e a tecnologia, a fim de compreender de que forma hoje, no auge do desenvolvimento tecnológico, ainda assim se produzem instrumentos que perpetuam a discriminação.

¹²⁹ A maior parte das pesquisas produzidas nesse sentido analisam os vieses discriminatórios dos algoritmos que fazem análise de crédito (é o caso de HURLEY, Mikella; ADEBAYO, Julios. *Credit Scoring in the Era of Big Data*. Yale Journal of Law and Technology, 2016, v. 148.), e também que fazem predições para decisões judiciais (como o estudo de HU, Margaret, *Big Data Blacklisting*, Florida: Florida Law Review, 2015, v. 67.). Em ambas, as temáticas da raça e da localização geográfica como proxy que permite inferências racistas são muito presentes

2.2.1 O conceito de discriminação

Antes de pormenorizar a relação entre gênero e tecnologia, faz-se necessário detalhar qual a definição de discriminação de mulheres que será utilizada neste trabalho.

A construção dessa definição prescinde de compreensão preliminar de que se vive em um paradigma mundial que busca a igualdade entre os seres humanos. Esse paradigma, pode-se dizer, foi adotado mundialmente quando da criação da Declaração Universal dos Direitos Humanos¹³⁰, que estabeleceu o princípio ético universal da igualdade, e foi especialmente incorporado no direito brasileiro pela Constituição de 1988, que trata a igualdade como um de seus valores fundamentais.

A compreensão preliminar de igualdade é fruto de uma consolidação do próprio conceito, que sofreu grandes modificações ao longo dos anos. Nos primeiros momentos, a igualdade era vista à luz de uma concepção estratificada e patrimonialista, como prelecionou John Rawls¹³¹. Foi só depois que começaram movimentos pela inclusão de determinados grupos marginalizados que foi possível absorver a ideia de diferença para dentro da busca pela igualdade, e isso se deu, para as mulheres, através de várias etapas. A primeira delas foi buscar superar a divisão de gênero entre os espaços públicos e privados, para que as mulheres pudessem ocupar posições que não fossem estritamente relacionadas ao cuidado dos filhos e da casa¹³².

¹³⁰ ONU. “*Universal Declaration of Human Rights*”, 1948. Disponível em: <<http://www.un.org/en/universal-declaration-human-rights/>>, acesso em 22 out 2019.

¹³¹ Para o autor, a igualdade seria a aplicação de dois princípios fundamentais: o de que cada um terá direito ao maior número de liberdades básicas (políticas, de discurso, de consciência, de pensamento, de propriedade, das pessoas e das prisões psicológicas); e o de que as desigualdades sociais e econômicas serão organizadas a fim de que se possa ter uma expectativa razoável de que (i) elas existem como forma de vantagem coletiva, justificadas pela diferenciação da autoridade e da responsabilidade, e (ii) elas podem se modificar, de modo que as posições de autoridade e responsabilidade serão acessíveis para todos (RAWLS, John. *A Theory of Justice*. United States: Beknap, 1971, p. 53) Ora, sabendo a época em que o autor desenvolveu essa ideia, percebe-se que ele sequer considerava a existências das mulheres como sujeitos de direito, até porque a elas não eram asseguradas nenhuma das liberdades básicas que Rawls elenca para serem estruturantes da igualdade, tampouco a possibilidade de escolherem os desdobramentos de seu futuro.

¹³² Essa inserção está inserida na superação, ainda que parcial, do que Carole Pateman desenvolveu ao elaborar sua teoria do contrato sexual. Na época em que diversos filósofos contratualistas discutiam, de forma reducionista, os modelos de alienação das vontades individuais em favor de políticos e governantes que iriam assegurar a estabilidade política e econômica da sociedade, Pateman estudou a imposição feita às mulheres de um contrato sexual que estabelecia uma divisão de tarefas e de locais de ocupação, justamente para compreender de que modo a alienação de vontades transcendia discussões de governabilidade e se transformava em uma imposição às mulheres com relação à casa, aos filhos e ao cuidado. Foi ela uma das primeiras autoras a relacionar a divisão entre espaços públicos e privados, a fim de apurar as distorções de gênero existentes e compreender de que modo se perpetuava um regime de tratamento diferenciado de mulheres que as limitava e excluía. Hoje, ainda que persista essa realidade, as mulheres estão em um contexto muito diferente, e que pressupõe, ao menos em parte, algum tipo de liberdade em relação às suas escolhas pessoais. Nesse sentido: PATEMAN, Carole. *The Sexual Contract*. Stanford University Press, 1988.

Essa superação, até hoje, não se deu de forma completa, porque estatísticas não faltam para comprovar que a mulher continua desempenhando a maior parte das tarefas relacionadas à casa e ao cuidado. Apesar disso, houve uma mudança material na realidade feminina que, ao longo do tempo, também se mostrou insuficiente para assegurar a igualdade. Foi nesse momento que se difundiu a percepção de que deveria se buscar uma equiparação de oportunidades, a fim de que elas pudessem ter a chance de participar de espaços políticos e sociais diferentes. Desse modo, reconheceu-se a importância de uma verdadeira atuação positiva por parte do Estado e dos governos para que a equiparação de oportunidades também fosse assegurada às mulheres, ainda que isso pudesse implicar em um tratamento diferenciado delas em relação aos homens, mas que, ao fim, iria promover a igualdade de recursos e igualdade na valorização de todas as vidas humanas¹³³ como preconiza Dworkin.

O conceito foi amadurecido para que o tratamento diferenciado não implicasse, necessariamente, em algo positivo. Com a Declaração Universal dos Direitos, pode ter surgindo uma incorreta ideia de que todos deveria ser tratados de forma igual, mas isso implicaria em reproduzir a exclusão de determinados de realidades que lhe eram estranhas. Por isso, também foi necessário difundir a percepção de que existe uma responsabilidade coletiva na busca pela igualdade, e que presume o compartilhamento da noção fundamental de que todas as vidas valem a pena, e de que nenhuma vida deve ser desperdiçada. E isso para que, a o fim, todas e todos pudessem perseguir um objetivo final de preservar a individualidade, sem ignorar as diferenças culturais, educacionais, materiais ou biopolíticas de cada um e cada uma¹³⁴.

É a partir dessas breves considerações que se deve pensar a igualdade, como uma busca pela equiparação das oportunidades¹³⁵, da ocupação dos espaços políticos e sociais de forma justa¹³⁶, e da valorização das experiências distintas, para que se possa reconhecer a diferença na individualidade de cada um, respeitando-a, ainda assim. É reconhecendo e valorizando cada realidade distinta, compreendendo que todas as vidas

¹³³ DWORKIN, Ronald. *Sovereign Virtue*. The Theory and Practice of Equality. London, England: Harvard University Press, 2002, pp. 390.

¹³⁴ DWORKIN, Ronald. *Sovereign Virtue*. The Theory and Practice of Equality. London, England: Harvard University Press, 2002, pp. 5/6.

¹³⁵ SEN, Amartia. *The idea of justice*. Belknap Press, 2011, p. 293/295.

¹³⁶ MIGUEL, Luis Felipe; BIROLI, Flávia. *Feminismo e Política: uma introdução*. Boitempo Editorial, 2014.

importam e são essenciais para o prosseguimento da sociedade democrática¹³⁷, que se constrói uma justiça pela igualdade. E essa busca não implica em tratar todas e todos da mesma forma em todas as circunstâncias, justamente porque as distintas vivências levaram as pessoas a circunstâncias que não necessariamente lhes valoriza.

De fato, o tratamento diferenciado pode ser considerado, etimologicamente, como um tipo de discriminação, mas isso não necessariamente possui uma conotação negativa. E isso porque, por vezes, esse tratamento diferenciado pode ser a justa medida para se assegurar a igualdade das mulheres em ambientes essencialmente masculinos. Foi nesse sentido, por exemplo, que se associou o Supremo Tribunal Federal no julgamento da Ação Direta de Inconstitucionalidade 5617/DF, que abordou a questão do tratamento diferenciado de mulheres em relação à distribuição de recursos do Fundo Partidário para o financiamento de campanhas eleitorais¹³⁸:

“É procedente a presente ação direta. Se o princípio da igualdade material admite, como reconhece a jurisprudência desta Corte, as ações afirmativas, utilizar para qualquer outro fim a diferença, estabelecida com o objetivo de superar a discriminação, ofende o mesmo princípio da igualdade, que veda tratamento discriminatório fundado em circunstâncias que estão fora do controle dos indivíduos, como a raça, o sexo, a cor da pele ou qualquer outra diferenciação arbitrariamente considerada.”¹³⁹

Dada essa perspectiva, o tratamento diferenciado não será abordado como discriminação, terminologia essa que somente será aplicada quando uma conduta caminhar em sentido oposto ao sentido de igualdade que foi delineado¹⁴⁰. O tratamento diferenciado considerado como discriminação, e que deve ser combatido, é o que se associa, necessariamente, um impacto negativo para as mulheres¹⁴¹, isto é, um impacto que posiciona à mulher mais distante das equiparações necessárias para sua integração na sociedade como uma vida que importa.

É essa a definição de discriminação de gênero que também adota a Convenção Internacional sobre a Eliminação de Todas as Formas de Discriminação Contra a Mulher,

¹³⁷ RIOS, Roger Raupp; SILVA, Rodrigo da. *Democracia e Direito da Antidiscriminação: interseccionalidade e discriminação múltipla no direito brasileiro*. Revista de Ciência e Cultura, São Paulo, v. 69, n. 1, 2017, p. 44-46.

¹³⁸ STF. Ação Direta de Inconstitucionalidade 5.617/DF. Relator: Min. Edson Fachin, 2018. Disponível em: <<http://portal.stf.jus.br/processos/downloadPeca.asp?id=15338766077&ext=.pdf>>; acesso 22 out 2019.

¹³⁹ STF. Op. cit..

¹⁴⁰ FRIEDMAN; NISSENBAUM, Op. cit., 1996, p. 333.

¹⁴¹ KLEINBERG, Jon; et. al. *Discrimination in the age of algorithms*, 2019, p. 6.

incorporada no direito brasileiro, e que veda “qualquer distinção, exclusão, restrição ou preferência que tenha o propósito ou o feito de anular ou prejudicar o reconhecimento, gozo ou exercício em pé de igualdade de direitos humanos e liberdades fundamentais nos campos econômico, social, cultural ou em qualquer campo da vida pública”¹⁴².

Também, a Lei Geral de Proteção de Dados Pessoais brasileira (LGPD, Lei n. 13.709/2018), reconhece que o tratamento diferenciado não necessariamente está associado à discriminação, tanto que ele é possível em circunstâncias não especificadas na lei, desde que não ocorra de forma ilícita e abusiva, com exclusivo propósito de prejudicar algum grupo (como mulheres)¹⁴³. Também, o diploma estabelece o princípio da não discriminação como um dos norteadores de todas as etapas do tratamento de dados pessoais¹⁴⁴, o que reforça a importância de os agentes assumirem um compromisso de buscar a igualdade durante o exercício da automatização.

Portanto, a discriminação de gênero é aquele tratamento diferenciado que produz impactos negativos às mulheres, porque prejudica ou inviabiliza a busca pela igualdade material, e também de oportunidades, deixando de valorizar a diferença.

2.2.2 Mulheres e processos automatizados

Compreendida a ideia de discriminação, é importante associá-la à tecnologia e ao desenvolvimento tecnológico, justamente para que se possa compreender como, e o motivo pelo qual a tecnologia permite, e até aprofunda, a discriminação de mulheres.

A discriminação de gênero é uma situação muito antiga vivida pelas mulheres. Tanto na esfera pública, como privada, elas sofrem com a realidade de serem tratadas de forma diferente pelo simples fato de serem mulheres. E esse tratamento diferenciado resulta em impactos diretos e negativos em suas vidas, implicando menores salários, menos oportunidades, mais tempo de jornada, maiores responsabilidades com os cuidados da casa e da família, dentre tantos outros desdobramentos.

¹⁴² RIOS, Roger Raupp; SILVA, Rodrigo da. *Democracia e Direito da Antidiscriminação: interseccionalidade e discriminação múltipla no direito brasileiro*. Revista de Ciência e Cultura, São Paulo, v. 69, n. 1, p. 44-46, 2017, pp. 44/45.

¹⁴³ MULHOLLAND, Caitlin Sampaio. *Dados pessoais sensíveis e a tutela de direitos fundamentais: uma análise à luz da Lei Geral de Proteção de Dados (Lei 13.709/18)*. Revista de direitos e Garantias Fundamentais, Vitória, v. 19, n. 3, set.-dez., 2018, p. 164.

¹⁴⁴ MULHOLLAND, Caitlin Sampaio. *Dados pessoais sensíveis e a tutela de direitos fundamentais: uma análise à luz da Lei Geral de Proteção de Dados (Lei 13.709/18)*. Revista de direitos e Garantias Fundamentais, Vitória, v. 19, n. 3, set.-dez., 2018, p. 164.

No campo da ciência e da tecnologia não é diferente. Desde os primórdios, às mulheres não era oportunizada a possibilidade de participar da construção do conhecimento científico e nesse campo, a exclusão das perspectivas e realidades femininas teve início muito cedo. Aos homens, foi assegurada a possibilidade de integrar o espaço de criação e desenvolvimento, e dele participar. Além disso, de escolher de quais benefícios as mulheres iriam poder usufruir, e em quais etapas elas poderiam se inserir.

Isso fica evidente quando se percebe que um dos primeiros espaços no qual o desenvolvimento tecnológico se inseriu na vida cível foi o da casa, especificamente o da cozinha, através dos eletrodomésticos¹⁴⁵. Ocorre que, como as mulheres não participavam dessa construção de conhecimento, esses primeiros equipamentos pouco traduziam as necessidades que precisavam ser supridas naquele ambiente. Havia uma inadequação daquela tecnologia à realidade das mulheres, justamente em decorrência da falta de participação delas na vida científica¹⁴⁶.

Esse mesmo padrão iria se repetir na indústria automobilística, que tentou criar produtos que se adequassem à realidade das mulheres, sem, contudo, consultá-las antes. Foi só quando se aceitaram lideranças femininas e a efetiva participação na ocupação de relevantes postos de trabalhos, que os carros passaram a incorporar acessórios e formatos mais próximos ao das famílias com crianças pequenas, e das mulheres, com necessidades múltiplas e variadas, tão diferente da dos homens.

Também seria esse o padrão em tantos outros campos do desenvolvimento tecnológico, o que levou, desde muito cedo, as mulheres a questionarem essa construção do conhecimento. Nessa realidade, é fácil pensar na tecnologia como um vetor da promoção da discriminação, justamente porque ela mimetiza a realidade vivida, e essa realidade, em relação às mulheres, nunca foi de inclusão.

Fruto de uma irresignação com essa realidade, surgiram os FTS – *Feminist Technological Studies*¹⁴⁷, que se tratam de grupos auto organizados de mulheres, cujo objetivo é encontrar soluções para que os efeitos da desigualdade de gênero pudessem ser minimizados no (e através do) campo da ciência e da tecnologia. As primeiras preocupações a esse respeito estavam, justamente, relacionadas à sub-representação de mulheres na produção do conhecimento. Essa preocupação buscava enfrentar quais eram

¹⁴⁵ COWAN, Ruth. *More Work for Mother: The Ironies of Household Technology from the Open Hearth of the Microwave*, Basic Books: New York: 1983.

¹⁴⁶ COWAN, Ruth. *More Work for Mother: The Ironies of Household Technology from the Open Hearth of the Microwave*, Basic Books: New York: 1983.

¹⁴⁷ BRAY, Francesca. *Gender and Technology*. The Annual Review of Anthropology, 2007.

as questões que continuavam obstaculizando o ingresso das mulheres no campo tecnológico e inviabilizando a inclusão na etapa de pesquisa e desenvolvimento¹⁴⁸.

Percebeu-se logo que inexistiam estímulos à participação feminina nas áreas das ciências exatas¹⁴⁹, o que acabava decorrendo de toda uma educação sexualmente dividida, que deixava de estimular meninas e meninos para desempenharem tarefas similares no futuro. Aos meninos, as brincadeiras e a educação eram direcionadas para a construção e para o desenvolvimento da inteligência, envolvendo aspectos de liderança, imposição da opinião e curiosidade. Às meninas, direcionavam-se as brincadeiras voltadas para o cuidado, e a própria educação era, por vezes, deficitária¹⁵⁰.

Também foi possível concluir que um grande obstáculo para a sub-representação no campo da ciência era a reprodução dos estereótipos de gênero, que alcançava e prejudicava até aquelas que se interessavam pela matéria. Os atributos de liderança e criatividade, tão valorizados no espaço do desenvolvimento tecnológico, eram frequentemente associados apenas aos homens, enquanto às mulheres, associavam-se características como cuidado e submissão¹⁵¹. Também se difundiu que o campo da tecnologia prescindia de instinto, o que não era algo inerente às mulheres, mas sim aos homens¹⁵².

Assim, diversos desdobramentos da realidade discriminatória estavam inseridos dentro do contexto da produção tecnológica, e acabavam implicando na exclusão e no tratamento diferenciado, com impactos negativos às mulheres. Essa exclusão não teve suas estruturas profundamente modificadas, não só porque se perpetua a realidade discriminatória em relação ao gênero, mas também porque a participação

¹⁴⁸ Estudos produzidos ao longo do desenvolvimento dos chamados FTS – Feminist Technological Studies – apuraram que, já em 1999, apenas 9.8% da produção tecnológica era integrada por pessoas do sexo feminino. Esse dado sugere como o problema de sub-representação das mulheres na ciência era intenso, e como os avanços foram paulatinos ao longo dos anos. Nesse sentido: KASI, Balsy; DUGGER, John C. *Gender Equality in Industrial Technology: The Challenge and Recommendations*. The Official Electronic Publication of the National Association of Industrial Technology, 2000.

¹⁴⁹ BRAY, Francesca. *Gender and Technology*. The Annual Review of Anthropology, 2007.

¹⁵⁰ BRAY, Op. cit., 2007.

¹⁵¹ A lista de Schein, como ficou conhecida, foi um estudo produzido no início dos anos 70, e ficou famoso por ser um dos primeiros instrumentos que mapeou os estereótipos de gênero e a sua relação com a discriminação. Foram analisados 92 itens descritivos e as correlações de gênero feitas entre eles, para se chegar à conclusão de que os adjetivos de liderança estavam associados aos homens, enquanto às mulheres eram associados adjetivos de cuidado e submissão. Nesse sentido, cabe verificar as conclusões de KASI, Balsy; DUGGER, John C. *Gender Equality in Industrial Technology: The Challenge and Recommendations*. The Official Electronic Publication of the National Association of Industrial Technology, 2000.

¹⁵² KIRK, Mary. *Gender and Information Technology*. Moving beyond access to co-create global partnership. New York: Information Science Reference, 2009, p. 65.

feminina nesses espaços não aumentou de forma a impedir que o tratamento desigual continuasse existindo.

Caroline Criado Perez fala, por exemplo, que o descuido em relação ao gênero é tamanho que hoje existe um *gap* de dados de gênero, de modo que nem mesmo a produção científica se preocupa em buscar informações relacionadas exclusivamente às mulheres¹⁵³. Na visão da autora, a inexistência de mulheres nesses espaços de produção de conhecimento fez com que fosse adotado, de forma indiscriminada, um padrão universal masculino, o qual é utilizado desde a criação de políticas públicas, até o teste de medicamentos para serem comercializados. E isso teria causado uma total obscurização das realidades e especificidades das mulheres¹⁵⁴. Em razão disso, sequer existem dados produzidos sobre mulheres em diversas áreas, ou seja, não se sabe o efeito que as políticas públicas, os medicamentos, as estratégias de governo e até os alimentos causam em mulheres, já que a elas se adotam conclusões padrões que foram obtidas nos estudos feitos, majoritariamente, com homens¹⁵⁵.

Resultado de política discriminatória muito antiga, a própria estruturação da ciência, formada majoritariamente por homens, fez com que se perpetuasse o tratamento desigual e negativo das mulheres na sociedade, o que se reflete de diversas maneiras. Uma delas é a discussão central do presente trabalho: como se justifica o auge da produção científica e tecnológica pode acabar operando para prejudicar mulheres? Justifica-se pelo fato de que, se as mulheres não vivem uma realidade de igualdade, a ciência e a tecnologia também não poderiam viver. Justifica-se pelo fato de que, se o próprio espaço científico não se modificou até hoje, porque as mulheres ainda não conseguiram ocupar efetivamente esse campo, ou porque não conseguiram desfazer construções estereotipadas, então as decisões tomadas como fruto da ciência também irão continuar a reproduzir o padrão antigo e discriminatório.

¹⁵³ PEREZ, Caroline Criado. *Invisible Women: Data bias in a world designed for men*. Abramns Press, 2019.

¹⁵⁴ Essa discussão é tão atual que, recentemente, a NASA – Instituto de Pesquisa Especial Norte-Americano – divulgou a desistência de um projeto que buscava levar apenas mulheres para uma missão espacial, em razão da falta de trajes espaciais anatomicamente desenhados para seus corpos específicos. Ou seja, como astronautas e cientistas sempre foram homens, sequer existiu preocupação em fazer trajes que se adequassem às mulheres, tampouco se pensou nesse problema quando a intenção da missão fora divulgada. Nesse sentido: __, *Caminhada espacial feminina é cancelada por falta de trajes adequados*. Segundo comunicado da NASA, não há roupas espaciais suficientes para todas as mulheres astronautas na Estação Espacial Internacional, 2019. Disponível em: <<https://revistagalileu.globo.com/Ciencia/Espaco/noticia/2019/03/caminhada-espacial-feminina-e-cancelada-por-falta-de-trajes-adequados.html>>; acesso em 22 out 2019.

¹⁵⁵ PEREZ, Caroline Criado. *Invisible Women: Data bias in a world designed for men*. Abramns Press, 2019

Nesse sentido, alguns estudos levam a crer que uma ciência e tecnologia mais representativas poderiam ser uma realidade plausível, porque, a inserção das mulheres em diversas áreas essencialmente masculinas possibilitaram a solução de problemas de forma simples, através da diferença de perspectiva e de pensamento¹⁵⁶. A inclusão, contudo, não ocorre em razão da falta políticas efetivas para que a igualdade seja promovida. Falta da atuação positiva dos governos para que possa ocorrer equiparação de oportunidades.

Depois dos FTS, a discussão acerca da relação entre mulheres e tecnologia acabou ficando pouco difundida. E isso pode ser percebido não só pela discriminação de mulheres em processos automatizados, como também pelos problemas mapeados em menores proporções. É exemplo o descuido do legislador ao não incluir o gênero no rol exemplificativo de dados sensíveis. Ou seja, tamanha a despreocupação com a discriminação de mulheres que o gênero nem mesmo foi considerado um dado potencialmente discriminatório¹⁵⁷.

Assim, não é difícil pensar que a tecnologia pode operar em detrimento dos interesses de igualdade de mulheres, até porque essa pretensão, muitas vezes, pode nem existir nos espaços essencialmente masculinos onde é produzido o conhecimento. O presente estudo, nesse contexto, objetiva trazer um novo foco para a automatização decisória, reforçando a importância de se pensar a realidade das mulheres em decisões que podem lhes ser prejudiciais.

A discussão sobre democratização da economia digital, nesse sentido, precisa voltar à tona, principalmente sob uma perspectiva de gênero. E isso não só porque os agentes de mercado continuam se valendo de seus monopólios no campo tecnológico para manipular comportamentos humanos¹⁵⁸, mas principalmente porque a igualdade está em risco, e as mulheres – além de outros grupos minoritários – estão sendo prejudicadas¹⁵⁹.

¹⁵⁶ Nas palavras de Alice Rangel de Paiva Abreu, ao comentar os resultados do estudo promovido pela Elsevier, o *Gender in the Global Research Landscape*: “Pode parecer que se preocupar ou discutir gênero e ciência seja para melhorar a vida das cientistas. Não é isso. Discutir gênero e ciência é melhorar a forma como a ciência é feita.” ZIEGLER, Maria Fernanda. *Assegurar inclusão de mulheres melhora a qualidade da ciência*, 2018. Disponível em: <<http://agencia.fapesp.br/assegurar-inclusao-de-mulheres-melhora-a-qualidade-da-ciencia/28381/>>; acesso em 22 out 2019.

¹⁵⁷ O interessante, cabe aqui destacar, é que o projeto de lei que deu origem à LGPD era da iniciativa de um homem, foi relatado por um homem, aprovado por uma casa majoritariamente composta por homens, e também sancionado por um homem. Não é difícil perceber, nesse contexto, porque inexistente preocupação com o gênero feminino.

¹⁵⁸ ZUBOFF, Shoshana. *The age of surveillance capitalism. The fight for a human future at the new frontier of power*. New York: Public Affairs, 2019.

¹⁵⁹ MAZZUCATO, Mariana. *Como democratizar a economia digital e evitar o feudalismo digital*. Precisaremos repensar a governança de dados, desenvolver novas instituições e, dada a dinâmica da

Inclusive, como coloca Mariana Mazzucato, os monopólios de tratamento de dados que hoje discriminam mulheres também foram criados, em grande medida, através do financiamento dos contribuintes, que pagaram pelos investimentos tecnológicos feitos pelos Estados nessas empresas¹⁶⁰. Portanto, em alguma medida, as mulheres estão sendo prejudicadas pelas pesquisas que elas mesmas ajudam a financiar através de seus impostos. E não que isso seja apenas ilegal, mas é também contrário à ordem constitucional de igualdade, e à toda a construção de direitos humanos que vem sendo construída desde o fim da Segunda Guerra Mundial.

economia de plataforma, experimentar formas alternativas de propriedade, 2019. Disponível em: <<https://jornalggn.com.br/tecnologia/internet/como-democratizar-a-economia-digital-e-evitar-o-feudalismo-digital-por-mariana-mazzucato/>>; acesso em 22 out 2019.

¹⁶⁰ MAZZUCATO, Mariana. *Como democratizar a economia digital e evitar o feudalismo digital*. Precisaremos repensar a governança de dados, desenvolver novas instituições e, dada a dinâmica da economia de plataforma, experimentar formas alternativas de propriedade, 2019. Disponível em: <<https://jornalggn.com.br/tecnologia/internet/como-democratizar-a-economia-digital-e-evitar-o-feudalismo-digital-por-mariana-mazzucato/>>; acesso em 22 out 2019.

CAPÍTULO 3

TIPOLOGIA DA DISCRIMINAÇÃO DE GÊNERO EM PROCESSOS AUTOMATIZADOS

*“Big data claims to be neutral.
It isn’t.”¹⁶¹*

3.1 Considerações preliminares

Como abordado anteriormente, os processos automatizados conquistaram espaço nas mais diversas esferas do cotidiano dos usuários, das empresas e dos governos. A ciência, essencialmente masculina em sua origem, viabilizou a criação de um sistema que conseguiu se inserir em vários contextos sociais distintos, e conquistar grande adesão, principalmente, em decorrência (i) da promessa de desburocratização e celeridade com uma redução de custos; (ii) da possibilidade de sistematização de processos decisórios similares; e, o mais difundido, (iii) da eliminação de vieses.

A desburocratização e a celeridade dizem da possibilidade de se tomarem decisões de forma mais rápida, envolvendo uma cadeia menor de pessoas que precisam participar desse processo decisório. Atualmente, diversos setores que lidam com questões administrativas – desde o Estado, até as grandes empresas – dependem de seres humanos para decidir matérias simples, que são estritamente baseadas em critérios objetivos. Nessas circunstâncias, a automatização das decisões permite uma maior economia de recursos, além de uma maior celeridade no processo decisório, pois a máquina poderia resolver tais questões.

Alguns agentes se utilizam desses programas para resolverem conflitos de pouca complexidade, principalmente quando eles estão inseridos em contexto de massa, em que várias demandas se repetem e tendem a ter resultados idênticos ou similares. Um exemplo interessante a esse respeito é o do Poder Judiciário, que vem se utilizando, com frequência, de *softwares* de resolução antecipada de conflitos. Infrutífera a tentativa conciliatória, alguns Tribunais também já se utilizam de *softwares* para tomada de decisão judicial, que fazem uma análise do conteúdo pretendido na petição inicial, em

¹⁶¹ BAROCAS, Solon; SELBST, Andrew D. *Big Data's disparate impact*. California Law Review, 2016, p. 1. Tradução livre: “O *big data* alega ser neutro. Não é.”

contraposição ao repositório de jurisprudência e decisões pretéritas, para, ao fim, disponibilizarem a decisão final.

No Brasil, o uso desses mecanismos vem sendo cada vez mais difundido, de modo que as Cortes Superiores estão se valendo de diferentes mecanismos para acelerar (i) a identificação de discussões repetitivas, em consonância, ou não, com a jurisprudência pacificada¹⁶², ou (ii) os recursos que não cumprem requisitos intrínsecos e extrínsecos mínimos de admissibilidade recursal¹⁶³. Nesse mesmo sentido há empresas brasileiras que disponibilizam, em seus sítios eletrônicos, *softwares* desse gênero para recebimento de reclamações e até resoluções de conflitos¹⁶⁴, muitas vezes feitas sem quaisquer intermediações humanas. É inegável que a possibilidade de eliminar custos e de padronizar abordagens e resoluções de conflitos representem um ganho das tecnologias preditivas.

Outro ponto positivo relevante abordado em relação às decisões automatizadas diz respeito à temática central deste estudo, qual seja a eliminação de vieses. Defende-se com frequência que o uso desse tipo de programa eliminaria padrões subjetivos da mente humana, porque corresponderia à análise estritamente estatística de determinada realidade, com amostragem suficientemente relevante para coibir erros eventuais.

Contudo, essa ausência de vieses não corresponde à realidade, porque existem sólidos estudos e consensos internacionais de que os processos automatizados podem causar a discriminação de minorias. É o que se pretende discutir neste terceiro Capítulo. Sabe-se que existe essa danosa possibilidade, por isso é importante mapeá-la ao longo de todo processo automatizado, a fim de compreender de que forma a discriminação pode se perpetuar e como os agentes de mercado podem atuar para solucioná-la.

Para fazê-lo, este capítulo utilizou estudos empíricos, a serem abordados ao longo do texto, que demonstram a existência de discriminação em cada uma das fases abordadas. À luz dos conceitos desenhados no primeiro capítulo, pretende-se compreender de que modo os tipos de dados são relevantes para que essa discriminação

¹⁶² _____. *STF terá programa de inteligência artificial para tramitação de processo*, 2018. Disponível em: <<https://www.conjur.com.br/2018-jun-01/stf-programa-inteligencia-artificial-processos>>; acesso em 22 out 2019.

¹⁶³ RACANICCI, Jamile. *Judiciário desenvolve tecnologia de voto assistido por máquinas*. Justiça do Trabalho e CNJ trabalham em ferramentas de inteligência artificial, 2018. Disponível em: <https://www.jota.info/paywall?redirect_to=https://www.jota.info/justica/judiciario-desenvolve-tecnologia-de-voto-assistido-por-maquinas-05012018>; acesso em 22 out 2019.

¹⁶⁴ São exemplos bancos como Itaú, empresas de venda de passagens aéreas como a Gol e lojas de comércio como o Magazine Luiza.

existe e possa ser evitada. Com base na definição de discriminação que foi construída no segundo capítulo, criou-se uma tipologia de como ela pode ocorrer nos processos automatizados, dividida da seguinte maneira: (i) discriminação de gênero pelos dados e pelas bases; e (ii) discriminação de gênero por algoritmos.

O primeiro tipo - discriminação de gênero pelos dados e pelas bases de dados - diz respeito aos erros de imperícia no uso dos dados pessoais, utilizados como fundamento e durante o processo decisório. Existem cuidados fundamentais quanto à representatividade dos dados, à conformidade do tratamento com suas especificidades regulatórias e ao uso de conteúdos que possam refletir informações pretéritas, já estar contaminadas com vieses. Coletar e armazenar os dados, portanto, é uma etapa com potencial discriminatório que antecede o *data mining* feito pelos sistemas automatizados de processos decisórios, mas que pode impactar diretamente em seus resultados. Essa discriminação de gênero pelos dados e base de pode se dar (a) pela falta de representatividade; (b) pelo uso de dados históricos; (c) pela supressão de dados pessoais sensíveis; e (d) pela anonimização de dados pessoais.

Por outro lado, a discriminação de gênero por algoritmos foi abordada como sendo a etapa do processo decisório que, efetivamente, faz a análise estatística e que disponibiliza o resultado final. Nela, pode se utilizar dos dados pessoais contaminados por vieses, que ensejariam a discriminação de gênero, mas essa, por si só, também possui características de opacidade e não transparência que podem culminar em prejuízos à igualdade das mulheres. Ela pode se dar (a) pelo desenho algorítmico; (b) pelo treinamento do algoritmo; e/ou (c) pelas correlações e inferências estatísticas do próprio *data mining*.

3.2 Discriminação de gênero pela coleta de dados pessoais

A discriminação de gênero, retomando a ideia que foi delineada no primeiro Capítulo, diz respeito ao tratamento diferenciado de mulheres, que lhes causa impacto negativo e que lhes promove um efeito contrário à busca pela igualdade de oportunidades, pela igualdade material e pela valorização da diferença.

Diversas são as circunstâncias nas quais a realidade da discriminação de mulheres existe, seja nos espaços da casa, no emprego ou no parlamento, seja na ciência, na produção do conhecimento e no desenvolvimento tecnológico. E isso se dá por um motivo: ainda que o debate acerca da igualdade entre mulheres e homens esteja presente

no debate público e nas discussões do senso comum, diversos vieses e preconceitos fundados em estereótipos impediram que todos os campos da vida pudessem ser igualitários. Como consequência disso, muitas são decisões foram tomadas sem que exista a preocupação de igualdade de gênero. Obviamente, e ainda no sentido de igualdade anteriormente exposto, aos governos cabe uma atuação positiva para que esse contexto seja modificado, mas o que se percebeu, inclusive através das pesquisas produzidas, é que a realidade para mulheres ainda não é a mesma realidade dos homens.

Transpondo esse contexto para o campo da tecnologia e das decisões automatizadas, percebe-se que o conteúdo utilizado nos processos automatizados foi absorvido através dos dados. Contudo, considerando que muitos desses dados refletem realidades sociais atuais ou contextos pretéritos que não necessariamente foram superados, deve-se ter especial atenção em relação com o uso dessas informações, ou até a ausência delas, poderia impactar no resultado final do processo automatizado de tomada de decisão.

Nos casos que serão detalhados adiante, verifica-se que a discriminação decorre de vieses preexistentes, decorrentes das construções sociais anteriores à criação daquela plataforma automatizada¹⁶⁵. Assim, os dados carregam informações sociais anteriores que contaminam o processo automatizado com perspectivas potencialmente discriminatórias. Nesse sentido, foram mapeados os seguintes pontos de atenção que deve ter os agentes que coletam e tratam dados pessoais para fins decisórios, justamente para que o tratamento diferenciado não impacte negativamente na vida das mulheres.

3.2.1. Falta de representatividade dos dados

“A maior parte da história humana é causada por um *gap* de gênero”¹⁶⁶.

Essa foi a frase escolhida por Caroline Criado Perez para iniciar seu livro, no qual ela aborda (i) a falta de dados sobre mulheres nos mais variados campos de produção de conhecimento, e (ii) o desconhecimento geral em relação às perspectivas e às realidades exclusivas ao gênero feminino¹⁶⁷. Na visão da autora, fundamentada por vasto cruzamento de dados científicos divulgados, a adoção de um padrão de gênero universal

¹⁶⁵ FRIEDMAN, Batya; NISSENBAUM, Helen. *Bias in Computer Systems*. ACM Transactions on Information Systems, v. 14, n. 3, 1996, p. 333.

¹⁶⁶ PEREZ, Caroline Criado. *Invisible Women: Data bias in a world designed for men*. Abrams Press, 2019

¹⁶⁷ PEREZ, Caroline Criado. *Invisible Women: Data bias in a world designed for men*. Abrams Press, 2019.

– o padrão masculino – acabou invisibilizando a realidade da maior parte da população, causando-lhes prejuízos que sequer foram analisados pela ciência, porque também não existe interesse específico a esse respeito.

São múltiplos os exemplos da autora para mostrar que não foram produzidos dados suficientes que considerem a realidade das mulheres. Os estudos médicos são feitos assumindo-se como padrão os corpos masculinos, muitas vezes ignorando que as mulheres possuem órgãos e hormônios distintos. As políticas públicas são desenhadas considerando o cotidiano de um homem médio, sem pensar que as mulheres possuem uma rotina voltada para cuidado dos filhos e do lar completamente diferente. Os tamanhos de roupas consideram como padrão universal os corpos de homens; os postos de liderança são idealizados para características tipicamente masculinas; as tecnologias foram desenvolvidas com base nas pretensões cotidianas de pessoas do sexo masculino, e com base nas suas características, como tamanho de mão para segurar um celular, ou de olhos, para reconhecimento facial¹⁶⁸.

Registre-se, à ilustração, que até os aparelhos de ar condicionados das empresas são programados com base na temperatura corpórea média de um homem, sem considerar que mulheres estão nas empresas e sua temperatura média tende a ser alguns graus menor, motivo pelo qual, inclusive, a maior parte das mulheres costuma passar frio em seus locais de trabalho¹⁶⁹. Portanto, não existe produção científica suficiente em relação às mulheres, e também em outras esferas da vida, não há preocupação com o gênero não universal. Essa questão deve ser enfrentada porque o *gap* de gênero tratado por Perez também pode ser identificado na realidade dos processos automatizados de tomada de decisão, causando uma falta de representatividade de dados utilizados¹⁷⁰.

Ao pensar em mecanismos de tomada de decisão automatizada, esse problema deve ser um dos primeiros a ser enfrentado, já que todos os *softwares* utilizados se estruturam a partir de uma etapa básica: a leitura de dados. Nesse sentido que Solon Barocas e Andrew Selbst consignaram que “o algoritmo é tão bom quanto a base de dados com que ele trabalha”¹⁷¹, porque, de fato, todo o processo decisório está intimamente relacionado com a qualidade dos dados que foram coletados. Portanto, se não existem

¹⁶⁸ PEREZ, Op. cit., 2019.

¹⁶⁹ PEREZ, Op. cit., 2019.

¹⁷⁰ PEREZ, Op. cit., 2019.

¹⁷¹ BAROCAS, Solon; SELBST, Andrew D. *Big Data's disparate impact*. California Law Review, 2016, p. 1.

dados suficientes produzidos sobre as mulheres, dificilmente as decisões automatizadas conseguirão compreender a realidade feminina de forma inclusiva e não discriminatória.

É essa falta de representatividade que pode promover a discriminação de gênero em processos decisórios automatizados pois, se não há informações suficientemente relevantes sobre ao contexto das mulheres, as decisões automatizadas tomadas também não irão representar, de forma suficientemente relevante, a solução dos problemas delas. É o caso dos programas de seleção de candidatas para vagas de emprego: se as bases de dados não possuírem informações representativas das mulheres, que são a maior parte da população e são mais qualificadas que os homens, os ambientes de trabalho vão continuar sendo ocupados principalmente por homens, e as mulheres vão continuar ganhando os menores salários. O impacto negativo da falta de representatividade dos dados é evidente, e gera um distanciamento, por parte do processo automatizado, da igualdade de gênero que deve ser perseguida.

Na verdade, a discussão da representatividade abrange questão muito maior, que envolve todos os grupos marginalizados¹⁷², principalmente aqueles que ainda não foram atingidos pelo desenvolvimento tecnológico. Como visto por Perez, falta produção de conhecimento relacionado às mulheres e, em diversas circunstâncias, não se pode dizer que não há uma falta de dados pessoais coletados e armazenados apenas em relação a elas. E isso porque, em muitos países, sequer existe energia elétrica, quem dirá conexão com a internet. Essas localidades, portanto, não integram o mercado de dados, e não produzem conteúdo que poderá ser utilizado em bases a fim de assegurar a representatividade.

Há, também para esses casos, um verdadeiro *gap* de produção de dados, que ajuda a perpetuar a discriminação em relação a eles, uma vez que não será possível assegurar a representatividade de conteúdo a serem analisados pelo algoritmo. Portanto, o problema da inexistência de dados que expressem a realidade de determinados grupos é fruto do desenvolvimento tecnológico desigual mundo a fora, como foi mapeado no

¹⁷² Carolina Braga, por exemplo, detalha a importância de dados representativos a serem utilizados por programas policiais. Chamado pela autora de “polícia preditiva”, ela faz em seu estudo uma análise do potencial discriminatório dos algoritmos que se prestam a identificar suspeitos de crimes, quando não há uma base de dados suficientemente representativa das categorias, de modo que sempre haverá indução de culpados e dificilmente se conseguirá fugir do estereótipo de raça que envolve o principal alvo do monitoramento policial. Nesse sentido: BRAGA, Carolina. Discriminação nas decisões por algoritmos: Polícia Preditiva, p.685. In: FRAZÃO, Ana; MULHOLLAND, Caitlin (coord.). *Inteligência Artificial e direito: ética, regulação e responsabilidade*. São Paulo: Thomson Reuters, 2019.

segundo capítulo deste estudo. E é essa realidade que, ao fim e ao cabo, acaba sendo reproduzida pelos sistemas automatizados.

Além dessa questão, a própria qualidade e quantidade de dados importa no resultado final preditivo. É nesse sentir que, ao descrever o funcionamento do *data mining*, foi feita a diferenciação com relação aos estudos estatísticos. O *data mining* é justamente a tecnologia responsável pela obtenção das informações dos dados, e pela síntese estatística dos resultados. Ele opera através da leitura de dados previamente coletados e armazenados em uma base. Por definição, trata-se de uma tecnologia que faz a análise estatística daqueles dados, em busca de padrões comuns a eles, tendo em vista um resultado específico. Não há, contudo, critério metodológico claro e transparente acerca de como funciona a coleta de dados que serão analisados, até porque, como visto, os agentes de mercado vêm transformando todo tipo de informação e conteúdo em dado passível de ser analisado por *data mining*.

Os estudos estatísticos, por sua vez, prescindem de etapa muito importante que assegura a idoneidade dos resultados encontrados, qual seja a etapa da coleta de dados. Nela, é feito um recorte sobre qual o foco do resultado estatístico que se pretende buscar, qual o objetivo da pesquisa e a quantidade de dados que precisam ser coletados dentro de cada categoria específica para manter a representatividade e a proporcionalidade entre elas, a fim de que o resultado seja fidedigno¹⁷³. São, inclusive, produzidos estudos específicos acerca da metodologia de coleta dos dados, porque isso pode impactar o resultado do estudo¹⁷⁴.

Há uma diferença gritante entre os estudos estatísticos e o *data mining*. Enquanto um possui preocupações específicas da coleta de dados, o outro se utiliza de todo e qualquer conteúdo armazenado em uma base. Aos olhos do homem médio, os dois, possuem, supostamente, a mesma presunção científica, pois a grande propaganda

¹⁷³ KLEINBERG, Jon; et. al. *Discrimination in the age of algorithms*, 2019, p. 22.

¹⁷⁴ Essa questão foi evidenciada pela professora Debora Diniz ao realizar a Pesquisa Nacional do Aborto (PNA), que pretendia mapear quantas mulheres haviam feito abortos no Brasil, clandestinos ou não. Para que o estudo estatístico fosse o mais preciso possível, foi realizado todo um estudo para que se apurasse como seria a coleta de informações nos estados selecionados, e de que forma essa coleta de dados iria ocorrer. E isso porque, como o aborto é considerado crime no Brasil, diversas mulheres poderiam se sentir oprimidas a darem a verdadeira informação acerca de suas escolhas pretéritas, com medo de sofrerem algum tipo de sanção criminal. Ou seja, para fins de produção estatística com caráter científico, a forma de coleta dos dados, e também a representatividade desses dados importa. Nesse sentido, ver: (DINIZ, Debora; MEDEIROS, Marcelo; MADEIRO, Alberto. *Pesquisa Nacional do Aborto 2016*. Ciência e Saúde Coletiva [online], 2017, vol. 22. Disponível em: <http://www.scielo.br/scielo.php?pid=S1413-81232017000200653&script=sci_abstract&tlng=pt>; acesso em 22 out 2019.

difundida acerca do *data mining* é que o resultado oriundo do processo automatizado é matematicamente idôneo e correto.

E pode-se argumentar que o controle da qualidade dos dados, e também da representatividade de categorias é difícil de ser discutida quando se pensa em uma análise massiva de dados. Essa dificuldade, contudo, não inviabiliza um maior cuidado com a estruturação da base de dados, e segue a lógica que, de fato, deve haver um compromisso ético por parte dos agentes para que até as impossibilidades técnicas sejam superadas em benefício da conformidade em prol da igualdade.

Nesse ponto, é importante ressaltar que esse compromisso ético se justifica quando se pensa que o impacto de uma decisão automatizada pode ser muito grande e direto para a vida de uma pessoa. Não se trata apenas da escolha de quais anúncios ou publicações vão aparecer para um usuário em uma rede social. Trata-se, hoje em dia, de pessoas que podem ser condenadas ou inocentadas por máquinas; de pessoas que podem ser escolhidas para ocupar uma posição de chefia ou não serem sequer consideradas para determinado processo seletivo; de pessoas que podem ser responsabilizadas civil ou criminalmente; de recursos judiciais que poderão ser admitidos ou rejeitados. Nenhuma das decisões automatizadas, por mais triviais que sejam.

Também relacionada à qualidade dos dados utilizados, o processo decisório pode ter potencial discriminatório quando dados descontextualizados para aquela análise específica são utilizados como *inputs*, permitindo associações que não são necessariamente verdadeiras e transferindo vieses de dados que não guardam relação com o contexto¹⁷⁵. Essas associações são reproduções de estereótipos, e, como já visto, eles são especialmente prejudiciais para mulheres no contexto de inclusão.

O exemplo tradicional a esse respeito também é o de *softwares* de seleção para vagas de emprego que não utilizam apenas dados relacionados à capacidade profissional dos candidatos, mas também, aqueles referentes à capacidade de serem bons ou maus pagadores. O fato de candidatos estarem inadimplentes em nada se relaciona com a capacidade de serem bons profissionais, mas o uso desses dados durante o processo pode permitir essa associação¹⁷⁶.

Portanto, é importante compreender, de pronto, que os dados utilizados no processo automatizado podem causar impactos no resultado. Primeiro, porque existe

¹⁷⁵ SILVA, Selena; KENNEY, Martin. *Algorithms, Platforms and Ethnic Bias: An Integrative Essay*. Clark Atlanta University: Phylon, v. 55, 2018, p. 55.

¹⁷⁶ SILVA; KENNEY, Op. cit., 2018, p. 55.

pouca produção de dados acerca da realidade das mulheres, e também de diversas outras minorias, motivo pelo qual a decisão final poderá ser contaminada com a presunção de que o universal masculino se aplica à realidade feminina – o que não é verdade. Segundo, porque os dados que são coletados devem ser suficientemente representativos de determinada categoria alvo de um processo decisório. As bases de dados utilizadas em *data mining* devem buscar, ao fim, a maior proximidade possível com aquelas que são utilizadas em estudos científicos. Terceiro, porque se utilizam dados que não guardam relação com aquele processo decisório em si, para evitar transferência de vieses e associações não necessariamente verdadeiras.

3.2.2 Uso de Dados Históricos

Outra questão relacionada aos dados, que pode impactar, diretamente, o resultado do processo decisório, diz respeito ao uso de dados históricos. Por dados históricos, entende-se aqueles que retratam experiências pretéritas, e que são inseridos na base de dados com o objetivo de ensinar ao algoritmo como é a realidade que ele precisa copiar ou melhorar¹⁷⁷.

Os dados históricos são utilizados como *inputs* para que os algoritmos consigam estruturar as duas premissas que estruturam a análise de dados: a primeira, de que os dados permitem criar um modelo que reflete a realidade e que não irá sofrer alterações no futuro, quando o modelo for aplicado. Ou seja, uma eventual predição estará fundada na premissa de que se trata de análise estatística dentro de um contexto de realidade imutável¹⁷⁸. A segunda premissa é de que os dados são representativos da categoria que está sendo objeto de análise¹⁷⁹, para que essas proporções possam ser replicadas pelo modelo. Contudo, como já foi visto anteriormente, não necessariamente a representatividade é verdadeira.

Nessa perspectiva, é o uso de dados que refletem realidades pretéritas que conseguem estruturar as duas premissas do modelo utilizado pelo algoritmo¹⁸⁰. Portanto,

¹⁷⁷ KLEINBERG, Jon; et. al. Discrimination in the age of algorithms, 2019, p. 22.

¹⁷⁸ CALDERS, Toon; ŽLIOBAITĖ, Indrė. Why Unbiased Computation Process Can Lead to Discriminative Decision Procedures. In: CUSTERS, Bart et al. (Org.). Discrimination and Privacy in the Information Society. Data Mining and Profiling in Large Databases. Springer: 2013, p. 46.

¹⁷⁹ CALDERS; ŽLIOBAITĖ, Op. cit., 2013, p. 46.

¹⁸⁰ CALDERS, Toon; ŽLIOBAITĖ, Indrė. Why Unbiased Computation Process Can Lead to Discriminative Decision Procedures. In: CUSTERS, Bart et al. (Org.). Discrimination and Privacy in the Information Society. Data Mining and Profiling in Large Databases. Springer: 2013, p. 46.

uma análise preditiva automatizada sempre envolve a inserção, na base de dados, de informações que possam retratar o passado, servindo como *inputs* para os algoritmos compreenderem a formação de um modelo específico.

Ocorre que os dados históricos podem guardar, de forma inerente aos desejos do programador, os preconceitos e vieses de gênero de uma determinada realidade, o que também causa impacto no resultado final do processo decisório¹⁸¹. E isso ocorre porque, se um contexto passado for discriminatório, os dados irão carregar essa informação e transportá-la para o processo automatizado.¹⁸²

Ademais, os dados históricos frequentemente são fruto de realidades humanas não automatizadas. Representam, assim, as decisões que foram tomadas de forma deliberadamente discriminatória, ou que podem retratar preconceitos do subconsciente que impactam diretamente em tomada de decisão¹⁸³. Logo, os dados históricos refletem comportamentos pretéritos, só que esses comportamentos podem estar contaminados por vieses de gênero.

O clássico exemplo relacionado a essa questão também diz respeito aos processos automatizados que selecionam candidatas para vagas de emprego. Os cargos de liderança presumem características que são valorizadas naquela instituição, como, por exemplo, a senioridade e a experiência. Contudo, se a empresa possui um quadro de funcionários no qual os chefes são, em sua maioria, apenas homens, o algoritmo poderá interpretar que o sexo é uma característica valorizada para se alcançar a posição de poder naquela instituição, priorizando, na seleção de candidatos feita de forma automatizada, a escolha de mais homens, em detrimento de mulheres. Percebe-se, nesse caso, que os dados históricos aqui utilizados como *inputs* pelo algoritmo, os quais são as informações de quem são os chefes da empresa, podem carregar um viés de gênero que será transportando para o processo automatizado.

Pode ser que a existência de homens em cargos de chefia não seja, necessariamente, uma escolha discriminatória no passado, mas apenas uma decisão inconsciente de que, naquela época, esses eram os melhores perfis para ascender, ou mesmo mera coincidência. Contudo, essa informação será analisada e utilizada pelo algoritmo, que irá interpretar aquela realidade – majoritariamente masculina – como a realidade que deve se repetir. E aqui cabe destacar que o algoritmo, e até a tecnologia de

¹⁸¹ KLEINBERG, Jon; et. al. Discrimination in the age of algorithms, 2019, p. 22.

¹⁸² KLEINBERG, Op. cit., 2019, p. 22.

¹⁸³ KLEINBERG, Op. cit., 2019, p. 22.

data mining, não irá fazer escolhas através do subconsciente, tampouco irá presumir como uma coincidência aquela realidade pretérita. Será feita a análise meramente estatística – até porque se trata de uma máquina -, e o gênero será um fator determinante dentro da análise feita pelo *software*.

Portanto, o uso de dados históricos também possui potencial discriminatório e deve ser objeto de atenção por parte dos agentes que se propõem a tomar uma decisão por sistemas automatizados, pois ele pode transportar para o algoritmo vieses e preconceitos pretéritos, que contaminam a idoneidade do resultado final.

3.2.3 Supressão de dados pessoais sensíveis

A discriminação de gênero em processos automatizados, causada pelos dados, também pode ocorrer com a supressão de dados pessoais sensíveis.

Como visto anteriormente, os dados pessoais sensíveis são assim categorizados em razão de seu potencial discriminatório. E o gênero não foi inserido expressamente no rol de dados pessoais sensíveis da Lei Geral de Proteção de Dados, mas ele deve ser assim considerado em razão da realidade discriminatória que as mulheres vivem hoje no Brasil e no mundo.

Em razão dessa característica especial, aos dados sensíveis são assegurados critérios distintos para a coleta e o tratamento, de modo que existe uma conformidade específica para que o agente de mercado possa se valer desses conteúdos. E essa conformidade específica tem uma razão de ser, que é justamente a preocupação com a proteção da personalidade do usuário, com o intuito de evitar que ele tenha suas informações pessoais utilizadas em desfavor dele.

Naturalmente, essa conformidade específica na coleta e no tratamento de dados pessoais sensíveis impõe aos agentes de mercado um custo diferenciado, além de uma série de restrições legais que prescindem de autorização específica e expressa do usuário, e que, mesmo assim, limitam o uso do conteúdo por parte do agente. Por isso, e com o objetivo de se eximirem dessas obrigações legais específicas, pode ocorrer que os agentes deixem de coletar os dados pessoais sensíveis, ou façam uma supressão espontânea desses dados dentro de uma base, para que a análise preditiva do *data mining*

não utilize esses conteúdos, evitando gastos adicionais e, também, obrigação de conformidade¹⁸⁴.

Essa supressão espontânea, contudo, pode culminar na discriminação de gênero dentro do processo automatizado. Primeiro, em razão do potencial risco da falta de representatividade que a supressão desses dados poderá trazer para a base: se dados pessoais sensíveis não integram a base e não estão inseridos no processo decisório, não se poderá garantir a representatividade de categorias minoritárias, que possuem potencial discriminatório, como é o caso das mulheres. E isso porque, apesar de os dados pessoais sensíveis refletirem informações potencialmente discriminatórias, eles dizem respeito às características essenciais à personalidade dos indivíduos, que garantem a participação e a integração de grupos historicamente discriminados dentro de um determinado modelo e, por consequência, no resultado de uma decisão.

Cabe ressaltar que os grupos que possuem características que são categorizadas como dados pessoais sensíveis são marginalizados de alguma forma, e a simples exclusão de suas realidades do processo decisório poderá culminar na perpetuação, e até no reforço da discriminação. Além disso, deve-se considerar que, ao excluir dados pessoais sensíveis de uma base, o agente estará se eximindo de uma série de obrigações legais específicas relacionadas aqueles dados.

Ocorre que, como mencionado, o funcionamento dos algoritmos pressupõe uma certa opacidade, decorrente da capacidade da fórmula de aprender com os dados que ela analisa, fazendo correlações e inferências que não necessariamente estão dentro do controle humano. Nessas correlações e inferências, o algoritmo poderá inferir qual o conteúdo do dado sensível que foi suprimido, de modo que ele estará sendo reinserido na análise preditiva sem, contudo, ter existido a conformidade¹⁸⁵.

Essas inferências e correlações, como será explorado adiante, são corriqueiras dentro de um processo automatizado, e decorrem do cruzamento de informações e da criação da relação estatística – não necessariamente verdadeira – entre um dado e outro¹⁸⁶. Com a supressão deliberada de apenas alguns tipos de dados, como é o caso dos dados sensíveis, o algoritmo poderá fazer o cruzamento de informações para tentar suprir a

¹⁸⁴ WILLIAMS, Betsy Anne; BROOKS, Catherine F.; SHMARGAD, Yotam. *How Algorithms Discriminate Based on Data They Lack: Challenges, Solutions and Policy Implications.*, Journal of Information Policy, vol. 8, 2019, p. 78.

¹⁸⁵ WILLIAMS, Betsy Anne; BROOKS, Catherine F.; SHMARGAD, Yotam. *How Algorithms Discriminate Based on Data They Lack: Challenges, Solutions and Policy Implications.*, Journal of Information Policy, vol. 8, 2019, p. 83.

¹⁸⁶ WILLIAMS, Op. cit., 2019, pp. 78-115.

lacuna de conteúdo que não consta na base, e isso será feito através de uma inferência estatística.

Ainda, verifica-se que o problema de supressão de dados pessoais sensíveis costuma ser mais gravoso quando esses dados estão associados a outras categorias sociais¹⁸⁷, não necessariamente considerados como sensíveis. Por exemplo, características associadas à raça frequentemente também estão relacionadas às características geográficas¹⁸⁸. A partir dessa correlação, viabilizam-se inferências, por parte do algoritmo, que também transportam vieses inconscientes e preconceituosos – como o de que pessoas negras estão, necessariamente, inseridas em regiões geográficas menos desenvolvidas¹⁸⁹.

Portanto, além de causar prejuízos à representatividade da base de dados, a supressão deliberada de dados pessoais sensíveis pode culminar na realização de correlações e inferências por parte do algoritmo que não necessariamente são verdadeiras e que vão reintroduzir o conteúdo potencialmente discriminatório no processo automatizado, sem que o agente tenha se adequado às imposições legais específicas para a coleta e o tratamento desse tipo de conteúdo. E isso porque, diversas características que não são necessariamente sensíveis, podem ser consideradas como discriminatórias a depender do contexto, e elas podem ser facilmente inferidas durante o processo decisório¹⁹⁰.

Ainda cabe destacar que, à despeito da intenção negativa que está associada à supressão dos dados sensíveis, existem intenções positivas que também adotam essa estratégia, mas que podem culminar na discriminação de mulheres. Chamado por alguns autores de “cegar o algoritmo”, pode ocorrer que agentes, em boa-fé, optem pela eliminação de determinados dados sensíveis com a pretensão de retirar vieses potencialmente discriminatórios do resultado final da predição automatizada, tentando promover decisões mais justas e igualitárias que não estariam associadas às características sensíveis dos usuários¹⁹¹.

¹⁸⁷ WILLIAMS, Op. cit., 2019, p. 87.

¹⁸⁸ WILLIAMS, Op. cit., 2019, p. 87.

¹⁸⁹ WILLIAMS, Op. cit., 2019, p. 87.

¹⁹⁰ Cathy O’Neil, nesse caso, cita o exemplo de supressão de dados pessoais sensíveis relacionados à raça, mas que podem ser inferidos através de marcadores geográficos, por exemplo. Ou seja, a simples retirada do dado sensível de raça de um programa que faz monitoramento de vigilância não impediria a verificação, através de outros proxies, como o geográfico, de que determinada pessoa é negro/a ou não. Nesse sentido: O’Neil, Cathy. *Weapons of Math Destruction*. How Big Data increwases inequality and threatens democracy. New York: Ed. Crown, 2016, p. 87.

¹⁹¹ KLEINBERG, Jon, et. al.. *Algorithmic Fairness*. AEA Papers and proceedings, v. 108, 2018.

Contudo, também essas circunstâncias se sujeitam aos dois problemas ora mapeados, de que a supressão espontânea prejudica a representatividade de dados e, ainda, permite a realização de correlações e inferências não necessariamente verídicas, sem a conformidade legal necessária. Ademais, estudos que mostram que a técnica de “cegar o algoritmo” não acompanha a pretensão positiva de não discriminar¹⁹². E isso porque, como será detalhado no capítulo 04, o uso dos dados sensíveis é fundamental, dentro de um processo automatizado, para que seja coibida a discriminação, porque ele impõe ao agente determinados cuidados legais em relação às características potencialmente discriminatórias, mas também porque ele pode ser utilizado pelo agente para manipular um processo específico no sentido contrário ao da discriminação.

Independente das circunstâncias, percebe-se que a supressão dos dados sensíveis não é o melhor caminho para evitar o tratamento diferenciado de mulheres, com impacto negativo em suas vidas.

3.2.4 Anonimização de dados pessoais

outro momento que pode ocorrer a discriminação de mulheres através dos dados, dentro do processo decisório automatizado, é durante a anonimização dos dados pessoais¹⁹³.

A anonimização de dados foi descrita no Capítulo 01 e diz respeito à eliminação das características identificadoras dos dados pessoais, justamente para que, dentre outros motivos, os agentes escapem da conformidade legal em relação a eles. Ocorre que a ideia de anonimização como uma forma de eliminar completamente as características identificadoras de um dado pessoal representa, hoje em dia, uma visão ultrapassada dos alcances da tecnologia¹⁹⁴ e da capacidade de, através de correlações estatísticas e inferências, restabelecerem-se, dentro do processo de tratamento de dados, as características que foram supostamente eliminadas¹⁹⁵.

¹⁹² ŽLIOBAITE, Indre; CUSTERS, Bart. *Using sensitive personal data may be necessary for avoiding discrimination in data-driven decision models*. Springer Science + Business Media Dordrecht, 2016.

¹⁹³ SCHWARTZ, Paul M.; SOLOVE, Daniel J. *The PII Problem: Privacy and a new concept of personally identifiable information*. New York University Law Review, v. 86, 2011.

¹⁹⁴ VIOLA, Mario; DONEDA, Danilo; ANDRADE, Norberto N. G. de. Dados anônimos e tratamento de dados para finalidades distintas: a proteção de dados pessoais sob uma ótica civil-constitucional. In: TEPEDINO, Gustavo; FACHIN, Luiz E. (Org.). *Pensamento crítico do direito civil brasileiro*. Curitiba: Juruá, 2011. p. 198.

¹⁹⁵ SCHWARTZ, Paul M.; SOLOVE, Daniel J. *The PII Problem: Privacy and a new concept of personally identifiable information*. New York University Law Review, v. 86, 2011.

O problema associado à discriminação de mulheres em decorrência dessa anonimização, portanto, é resultado dessa concepção não atualizada dos alcances da capacidade preditiva do *big data*. E ele diz respeito, principalmente, às questões de privacidade. Como também mencionado no primeiro Capítulo, a ideia de privacidade deve estar associada a uma moderna concepção de respeito aos deveres éticos de não compartilhamento de dados de forma desautorizada. Contudo, e para poder divulgar e vender bases de dados, alguns agentes de mercado anonimizam dados pessoais, para que aqueles conteúdos não precisem ser retirados.

Em decorrência da capacidade de correlações estatísticas e inferências dos sistemas de *data mining*, contudo, os algoritmos identificam quais as características anonimizadas, e a quem aquelas informações dizem respeito¹⁹⁶. Trata-se de um problema similar ao desenhado em relação à supressão de dados pessoais sensíveis, porque pode implicar em correlações não necessariamente verdadeiras, além de disponibilizar a informação sem a devida conformidade. Assim, os agentes conseguem identificar a qual usuário aquele dado diz respeito, apesar de não cumprir os requisitos legais para que aquele conteúdo fosse tratado ou compartilhado.

E se um dado, que diz respeito à personalidade de um usuário, foi compartilhado indevidamente, há violação à privacidade dele, ainda que a intenção do agente, no primeiro momento, fosse de compartilhar aquele conteúdo na qualidade de dado anonimizado. Especificamente em relação às mulheres, o risco discriminatório é o mesmo quando há supressão de dados pessoais sensíveis, pois pode implicar em correlações estatísticas e inferências que não são verídicas e que reproduzem estereótipos prejudiciais à igualdade e à representatividade das categorias no tratamento de conteúdo.

Em contrapartida, cabe ressaltar as considerações de Shawn Helms acerca da importância do anônimo para o exercício da liberdade e da própria personalidade e privacidade na internet. Argumenta o autor que o desenvolvimento de tecnologias de identificação – como aquelas que permitem desanonimizar um dado pessoal – criaram um “cyber-panoptico”, onde todas e todos são monitorados em tempo real, armazenados eletronicamente e posteriormente analisados na condição de dados estatísticos¹⁹⁷.

Apesar disso, é importante destacar que a anonimidade guarda aspectos controversos em relação à responsabilidade e ao exercício da democracia, sendo, em diversas circunstâncias, inclusive vedada pelo ordenamento jurídico brasileiro. Nesse

¹⁹⁶ SCHWARTZ, Op. cit., 2011.

¹⁹⁷ HELMS, Shawn C. *Translating privacy values with technology*. Boston University, 2001.

sentir, é necessário encontrar equilíbrio para que (i) a anonimização de dados possa ser efetiva e possa proteger a liberdade dos usuários, não implicando em potencial identificação posterior por parte dos agentes, e, ainda, (ii) possa assegurar que os usuários não vão se valer do anônimo para se eximirem de eventual responsabilização.

3.3 Discriminação de gênero por algoritmos e *data mining*

A segunda subdivisão aqui delineada diz respeito às possibilidades de discriminação de gênero em processos automatizados quando da estruturação e do funcionamento dos algoritmos, e quando do uso das tecnologias do tipo *data mining*. Trata-se, portanto, de uma discussão sobre a possibilidade de discriminação através de vieses técnicos, ou seja, aqueles que surgem em decorrência da existência de uma determinada tecnologia¹⁹⁸.

É importante destacar que o processo automatizado em si é resultado de uma série de escolhas e orientações do programador e dos agentes que manipulam aquelas estruturas, e isso ficará evidente quando se pensa no desenho algorítmico e no uso das tecnologias de *data mining*. Toda a estrutura automatizada em si funciona de forma coesa, de modo que a qualidade dos dados utilizados, como exposto anteriormente, também é fundamental e pode impactar todo o resultado decisório.

Contudo, a estrutura matemática em si e a manipulação da tecnologia preditiva podem interferir diretamente no potencial discriminatório das decisões automatizadas. Por vezes, os agentes se eximem de responderem pelos resultados obtidos através desses processos, sob o argumento de que a tecnologia opera por si só, de forma opaca e pouco controlável. É frequente a obtenção de resultados discriminatórios que são justificados pelos agentes como sendo resultados que não poderiam ter sido previstos ou esperados, já que foram frutos de elementos alheios à programação em si, como as correlações estatísticas.

Com o advento da Lei Geral de Proteção de Dados, que responsabiliza o agente que trata dados pessoais pelos resultados discriminatórios obtidos desse tratamento, esses argumentos possuem pouca aderência. Não se nega a impossibilidade técnica, mas fato é que existe um grau de perícia que ainda pode ser desenvolvido em relação aos processos automatizados, e que está associado à maior capacidade de controle

¹⁹⁸ FRIEDMAN, Batya; NISSENBAUM, Helen. *Bias in Computer Systems*. ACM Transactions on Information Systems, v. 14, n. 3, 1996, p. 335.

dos usuários em relação às etapas de tratamento de dados. Assim, o agente precisa controlar as ferramentas que desenvolve, mantendo-se atento aos resultados e às etapas em que a discriminação pode ocorrer, a fim de evitar resultados que criem impactos negativos nos grupos minoritários, principalmente nas mulheres.

Não suficiente, essa discussão apenas reforça a premissa central que este estudo pretende desconstituir em relação à automatização decisória: não há pretensão exclusiva de neutralidade nesses processos, somente porque eles envolvem estudo estatístico em massa. Ao contrário, diversas etapas da automatização preditiva podem ser manipuladas e estão sujeitas à vieses.

3.3.1 Discriminação inserida no desenho algorítmico

A discriminação no desenho algorítmico é aquela que opera através da inserção, na própria estrutura matemática, de vieses e preconceitos que prejudicam mulheres. E essa preocupação pode ocorrer de diferentes formas.

A primeira delas diz respeito à dificuldade que essa fórmula matemática possui de diferenciar circunstâncias diferentes. Em vez de analisar a realidade de cada caso concreto, o algoritmo, é desenhado para estruturação de dados em massa e é capaz de produzir apenas resultados genéricos¹⁹⁹. Um exemplo nesse sentido é o de avaliação de trabalhos de alunos. O algoritmo tende a avaliar os alunos aplicando a todos eles critérios gerais com base na média de todos os trabalhos. Contudo, deixa de considerar a realidade específica do trabalho e de cada um, além de ignorar o progresso individual e as dificuldades, o que, por sua vez, costuma ocorrer quando os professores fazem a avaliação, e não as máquinas²⁰⁰.

Essa questão é especialmente relevante quando se pensa na discriminação de gênero. Se as mulheres forem avaliadas de forma genérica, ou forem alvo de processos decisórios nos quais os algoritmos apenas aplicam a elas o padrão médio, toda a realidade específica por elas vividas, de jornada dupla, com salários menores, maiores qualificações, carreiras mais longas e maiores esforços não reconhecidos, seria desconsiderada. Considerar as circunstâncias vividas pelos grupos que sofrem

¹⁹⁹ SILVA, Selena; KENNEY, Martin. *Algorithms, Platforms and Ethnic Bias: An Integrative Essay*. Clark Atlanta University: Phylon, v. 55, 2018, p. 54.

²⁰⁰ SILVA, Op. cit., 2018, p. 54.

discriminação cotidiana – como é o caso das mulheres – é fundamental para que se possa assegurar o ideal de justiça que foi aqui desenhado²⁰¹.

Segundo, porque, por se tratarem de estruturas matemáticas, com frequência os algoritmos são associados aos ideais de neutralidade. Construiu-se o ideal de que o algoritmo é algo excessivamente complexo e intangível ao intelecto da maior parte das pessoas, motivo pelo qual são consideradas fórmulas idôneas, criadas com exclusivo propósito de operacionalizar uma determinada função. Em verdade, diversas tecnologias (as vezes não tão rudimentares assim) operam através de algoritmos, e essas estruturas são as grandes ferramentas matemáticas responsáveis por conseguirem ler modelos e produzirem resultados.

Contudo, essas fórmulas não são necessariamente neutras²⁰². Como define a autora Cathy O’Neil, os algoritmos como meras transcrições matemáticas dos desejos pessoais, que podem ser utilizados como máquinas que traduzem todo o tipo de interesse e pretensão humana, seja ela discriminatória, ou não²⁰³. Essa definição, inclusive, alinha-se ao que foi abordado no primeiro Capítulo, na parte de definição, no sentido de que os algoritmos são estruturas que se organizam a partir de modelos matemáticos repetitivos criados por programadores²⁰⁴, e que analisam informações previamente inseridas (*inputs*)²⁰⁵, para gerarem um resultado específico²⁰⁶ (*output*).

Ou seja, há interferência e participação humana direta em diversas etapas da estruturação algorítmica, desde o seu desenho, passando pela criação dos modelos em linguagem matemática, até o controle dos *inputs* inseridos para que aquele algoritmo seja

²⁰¹ Em uma analogia perfeitamente aplicável ao caso, Cathy O’Neil diz que, no futuro próximo, os ricos serão avaliados por seres humanos, ao passo que as massas, serão avaliadas por máquinas. E isso justamente dentro da lógica de reprodução dos privilégios – que também é o caso da discriminação de gênero – porque se sabe que é um privilégio poder ser avaliado e julgado por um ser humano, que vai considerar sua realidade específica, em contraposição à máquina, que irá aplicar a você o resultado padronizado. “The privileged, we’ll see time and again, are processed more by people; the masses by machines” O’NEIL, Cathy. *Weapons of math destruction. How big data increases inequality and threatens democracy*. New York: Crown Publishers, 2016, p. 8.

²⁰² LINDOSO, Maria Cristine. O processo decisório na era do Big Data: como novos mecanismos de processamento de dados através de algoritmos interferem nas tomadas de decisão., p. 374. In: FERNANDES, Ricardo Vieira de Carvalho; CARVALHO, Angelo Gamba Para (Coord.). *Tecnologia jurídica & direito digital: II Congresso Internacional de Direito, Governo e Tecnologia*. Belo Horizonte: Fórum, 2018.

²⁰³ O’NEIL, Cathy. *Weapons of math destruction. How big data increases inequality and threatens democracy*. New York: Crown Publishers, 2016.

²⁰⁴ O’NEIL, Op. cit., 2016.

²⁰⁵ DONEDA, DANILO ; Almeida, Virgilio A.F.. *What Is Algorithm Governance?*. IEEE Internet Computing, v. 20, p. 60-63, 2016, p. 60.

²⁰⁶ GOETTENAUER, Carlos Eduardo. Algoritmos, Inteligência Artificial, Mercados. Desafios ao arcabouço jurídico. In: FRAZÃO, Ana; CARVALHO, Angelo Gamba Prata de. *Empresa, Mercado e Tecnologia*. Belo Horizonte: Fórum, 2019, p. 270.

treinado. Por esse motivo que, antes de qualquer discussão acerca do potencial discriminatório em decorrência do *data mining*, deve-se considerar que os próprios algoritmos carregam subjetividades que podem ser a eles transportadas, e que isso pode ocorrer em diversos momentos de manipulação algorítmica, principalmente no momento do desenho da fórmula matemática em si.

E veja que essa inserção de vieses não é, necessariamente, consciente, com o propósito de prejudicar grupos específicos²⁰⁷. Objetivamente falando, esse transporte de vieses para dentro da fórmula matemática ocorre, no caso dos algoritmos, através dos *proxies* que são utilizados pelo programador, que são os critérios inseridos diretamente na fórmula matemática e que deverão identificar o padrão pretendido²⁰⁸.

Ao utilizar determinados *proxies*, o programador poderá interferir diretamente no resultado do processo decisório de maneira prejudicial às mulheres, pois fará constar, no próprio algoritmo, as preferências, os preconceitos e os vieses em relação a elas, bem como a outros grupos. Esse tipo de interferência, na verdade, é difícil de ser verificada pela autoridade fiscalizatória e até pelo usuário final atingido pela decisão, tendo em vista que essas estruturas matemáticas são protegidas como segredos de indústria e não costumam ser divulgadas pelos agentes de mercado²⁰⁹. Com frequência, inclusive, essa verificação ocorre depois que o resultado discriminatório é constatado, sem que os prejuízos eventualmente decorrentes dele possam ser evitados²¹⁰.

Essa preocupação em relação ao momento de estruturação do algoritmo é importante porque se vive em uma sociedade preconceituosa com mulheres. Portanto, não seria difícil imaginar que um programador, ainda que de forma não intencional, pudesse transportar seus vieses de gênero para o momento de criação da fórmula matemática.

Nesse contexto que se discute a opacidade dos algoritmos, e a falta de transparência dessas estruturas. A opacidade, como delineado no Capítulo 1, diz respeito à capacidade que a estrutura matemática tem de se autodesenvolver e se aprimorar sem comandos humanos, simplesmente através da leitura massiva de dados. De fato, essa opacidade permite resultados que podem exceder as expectativas dos programadores em

²⁰⁷ SILVA, Selena; KENNEY, Martin. *Algorithms, Platforms and Ethnic Bias: An Integrative Essay*. Clark Atlanta University: Phylon, v. 55, 2018, p. 55.

²⁰⁸ BAROCAS, Solon; SELBST, Andrew D. *Big Data's disparate impact*. California Law Review, 2016, p. 21.

²⁰⁹ SILVA, Selena; KENNEY, Martin. *Algorithms, Platforms and Ethnic Bias: An Integrative Essay*. Clark Atlanta University: Phylon, v. 55, 2018, p. 55.

²¹⁰ SILVA, Op. cit., 2018, p. 55.

relação ao funcionamento e aos limites de desempenho do algoritmo dentro daquele processo decisório, mas não elimina, tampouco justifica, os possíveis vieses mapeados acima, como será melhor detalhado no Capítulo 04.

Portanto, o importante é verificar que o desenho algorítmico pode ser responsável pelos resultados discriminatórios em relação às mulheres e que a estrutura criada pelos programadores influencia no processo decisório.

3.3.2 Discriminação através do treinamento do algoritmo e criação do modelo

A fórmula matemática utilizada nos processos decisórios também pode ser contaminada com vieses prejudiciais às mulheres no momento em que ela está “aprendendo” sua função preditiva futura. Esse é o momento de treinamento do algoritmo e de criação do modelo segundo o qual ela deverá se espelhar.

Como explicado anteriormente, principalmente nas *screening decisions* há uma etapa fundamental no processo decisório que diz respeito à fase de ensinar a fórmula matemática qual o problema será por ela resolvido e quais padrões deverão ser identificados para serem alcançados ou descartados durante esse processo. Trata-se da etapa de treinamento do algoritmo, que conta com a participação direta do programador, o qual, por sua vez, possui papel fundamental de selecionar quais são as categorias de dados que terão mais ou menos importância no processo decisório como um todo²¹¹.

A etapa de treinamento do algoritmo é essencial para o funcionamento da automatização decisória, e ela conta com a participação e influência direta do ser humano, que será o responsável pelo ensinamento que o algoritmo perseguirá ao longo desse processo. É nessa etapa que os vieses humanos, conscientes e inconscientes, são transportados para o algoritmo, porque o programador definirá, através da sua percepção, quais são as características louváveis ou não, benéficas ou não, que serão ensinadas ao algoritmo.²¹² Novamente, percebe-se que a automatização não é essencialmente neutra pelo simples fato de possuir fórmulas matemáticas e análise de dados em massa, já que momentos fundantes e estruturais desses processos prescindem da participação humana.

O tradicional exemplo a esse respeito também é o da seleção de candidatas através de *softwares*. Durante o processo de treinamento do algoritmo, o programador ensinará à estrutura matemática quais são as características do funcionário ideal são

²¹¹ KLEINBERG, Jon; et. al. *Discrimination in the age of algorithms*, 2019, p. 22.

²¹² KLEINBERG, Op. cit., 2019, p. 22.

perseguidas pela empresa. Aqui, poderão ser inseridos dados históricos, que trazem ao algoritmo experiências pretéritas e dados que não se relacionam àquele processo decisório específico, mas que podem traduzir valores morais que o programador acredita serem importantes para aquela seleção. Também, nessa etapa, pode-se optar por cegar o algoritmo, para que ele não leve em consideração os dados pessoais sensíveis. Assim, nessa etapa, diversos são os problemas anteriormente mapeados que podem se inserir. Além disso, o simples exercício deliberativo do programador pode contaminar e ensinar à estrutura matemática aquilo que ele bem entender como importante, o que, por si só, já pode ensejar a discriminação.

As próprias características que o programador selecionar para treinar o algoritmo poderão traduzir vieses inconscientes. É o exemplo citado por Kleiberg et al., quando se opta por valorizar os currículos de candidatos formados em faculdades renomadas, mesmo sabendo, ou não, que esses espaços são historicamente segregados, e apenas parte elitizada da população os frequentava²¹³.

Para além das *screening decisions*, que prescindem dessa etapa de treinamento, existem outros tipos de algoritmos que operam por tecnologias diferentes, mas seguindo o modelo previamente desenhado pelo programador²¹⁴. A criação desse modelo, por si só, guarda os mesmos problemas que o treinamento dos algoritmos, e nele também podem ser transportados vieses de gênero, que podem produzir impactos negativos para mulheres²¹⁵.

Logo, a esse respeito, é importante considerar que a própria forma de aprendizagem da estrutura algorítmica, ainda que tenha sido desenhada e estruturada de maneira idônea, pode implicar potencial discriminação de gênero ao final. E isso porque, nessa etapa, seja ela através de treinamento de algoritmos, ou da criação de modelos, são transportados os vieses do programador acerca de como deve operar a estrutura matemática.

²¹³ KLEINBERG, Jon; et. al. *Discrimination in the age of algorithms*, 2019, p. 22.

²¹⁴ BAROCAS, Solon; SELBST, Andrew D. *Big Data's disparate impact*. *California Law Review*, 2016, p. 2.

²¹⁵ BAROCAS, Solon, et. al. *Big data, Data Science, and Civil Rights*. *Computing Community Consortium Catalyst*, 2017.

3.3.3 Discriminação no *data mining* por correlações e inferências estatísticas

“O *data mining* constitui uma forma objetiva de discriminação, porque desenha uma incorreta inferência de determinado comportamento, afetando a forma como empresas vão ver e tratar determinado indivíduo.”²¹⁶.

Essa frase reflete um dos principais problemas associados à discriminação algorítmica, que consiste nas correlações e inferências estatísticas inerentes ao processo de *data mining*. Por correlações e inferências estatísticas, entende-se a capacidade do algoritmo de presumir a existência de informações e o conteúdo que, não necessariamente, existem nas bases de dados²¹⁷. Isso ocorre através da leitura de dados e da análise dos conteúdos que existem na base. A partir disso, considerando os padrões estatísticos verificados, presume a existência de uma informação que não existe, ou então, realiza-se uma associação de padrões e informações não necessariamente verdadeira, mas estatisticamente viável.

Verificou-se, ao longo deste estudo, que a falta de dados ou a inserção de dados desnecessários para aquela decisão específica permitiriam ao algoritmo fazer correlações e inferências estatísticas. A preocupação em relação a isso ocorre pelo mesmo motivo: nem sempre essas correlações e inferências são verdadeiras. E, se falsas, elas podem estar associadas à reprodução de estereótipos discriminatórios, que prejudicarão mulheres e outras minorias no resultado final.

Essas correlações e inferências podem ocorrer em vários momentos distintos, mas elas costumam ser mais comuns na etapa do *profiling*, quando se está mapeando características para criação de um perfil que sintetiza aquilo que o processo decisório final está buscando²¹⁸. A realização de correlações e inferências decorre da análise massiva de dados, e trata, na verdade, de uma chance estatística de aquelas informações serem verdadeiras. Contudo, apesar de se tratar de uma quantidade incalculável de dados analisados dentro de uma base, em razão do *big data*, ainda assim aquele algoritmo não

216 BAROCAS, Solon. *Data mining and the discourse on discrimination*. Proceedings of the Data Ethics Workshop, Conference on Knowledge Discovery and Data Mining, 2014.

217 Frequentemente, a capacidade de correlações estatísticas, inferências e até produção de diagnósticos e identificação de padrões é denominada *big analytics*. Nesse sentido, ver: FRAZÃO, Ana. Big Data, Plataformas Digitais e Principais Impactos sobre o Direito da Concorrência. In: FRAZÃO, Ana; CARVALHO, Angelo Gamba Prata de. *Empresa, Mercado e Tecnologia*. Belo Horizonte: Fórum, 2019, p. 182.

218 ROMEI, Andrea; RUGGIERI, Salvatore. Discrimination Data Analysis: A multi-disciplinary Bibliography. In: CUSTERS, Bart et al. (Org.). *Discrimination and Privacy in the Information Society*. Data Mining and Profiling in Large Databases. Springer: 2013, p. 115.

possui acesso a todas as informações sobre determinado usuário. Desse modo, aquela correlação pode ser estatisticamente verdadeira para a realidade daquela base de dados, mas não necessariamente o será para a realidade daquele usuário.

Além disso, foi mapeado que as bases de dados podem possuir diversos problemas, dentre eles o da falta de representatividade de dados, e também o da falta de qualidade dos dados que estão ali inseridos. Isso reforça que as correlações e inferências podem fazer sentido quando inseridas na base de dados, mas elas podem não se mostrar verdadeiras quando se chega ao resultado final do processo decisório.

E, a esse respeito, existem diversos exemplos²¹⁹. O *marketing* digital²²⁰ vem utilizando essas técnicas através do direcionamento personalizado de produtos que, por correlações estatísticas e inferências criadas através da análise do perfil de cada usuário, possuem maiores chances de serem adquiridos²²¹. Em verdade, o uso dessas técnicas trata da capacidade dos agentes de manipularem e induzirem os usuários a adquirirem produtos que lhes são direcionados através de correlações obtidas por *data mining*²²².

Ao analisar as questões específicas, tem-se que, nos Estados Unidos as empresas de seguro de saúde estavam negando a prestação de serviços para mulheres ou estavam cobrando valores excessivos delas porque, ao analisarem as bases públicas de saúde, constataram que os índices de violência doméstica poderiam lhes causar prejuízos²²³. Ocorre que nem todas as mulheres foram ou são vítimas de violência doméstica, motivo pelo qual a diferenciação de preço não poderia se aplicar. Além disso, as mulheres não podem ser responsabilizadas por serem vítimas, já que os índices de violência doméstica não crescem ou diminuem de acordo com suas intenções. Trata-se,

²¹⁹ Recentemente, as correlações estatísticas ficaram famosas pela atuação da empresa Cambridge Analytica em dois processos decisórios de relevância mundial, quais sejam a eleição dos Estados Unidos e a votação do Brexit, no Reino Unido. A empresa, através do mapeamento de perfil dos eleitores, conseguiu alcançar pelo marketing digital e personalizado diversos usuários, valendo-se de correlações que permitiam direcionar a detentores de características específicas, as notícias e projetos específicos que fossem de seu interesse. FLORES, Paulo. *O que a Cambridge Analytica, que ajudou a eleger Trump, quer fazer no Brasil*. Empresa de marketing que atuou na eleição americana de 2016 direciona propaganda de acordo com a personalidade dos eleitores, 2017. Disponível em: <<https://www.nexojournal.com.br/expresso/2017/12/08/O-que-a-Cambridge-Analytica-que-ajudou-a-eleger-Trump-quer-fazer-no-Brasil>>; acesso em 22 out 2019.

²²⁰ TURROW, Joseph. *Niche Envy*. Marketing Discrimination in the Digital Age. Cambridge: The MIT Press, 2006.

²²¹ Inclusive, alguns estudos já fizeram um mapeamento da discriminação promovida pelos agentes de mercado no momento da entrega do anúncio, o que também ocorre por correlações estatísticas e criação de perfis de usuários. Nesse sentido: SWEENEY, Latanya. *Discrimination in Online Ad Delibery*. Harvard University, 2013.

²²² RICHARDS, Niel M.; KING, Jonathan H. Big Data Ethics. *Wake Forest L. Rev.* 393, vol. 49, 2014.

²²³ MULHOLLAND, Caitlin Sampaio. *Dados pessoais sensíveis e a tutela de direitos fundamentais: uma análise à luz da Lei Geral de Proteção de Dados (Lei 13.709/18)*. *Revista de direitos e Garantias Fundamentais*, Vitória, v. 19, n. 3, set.-dez., 2018, p. 167.

nesse caso, de uma correlação não verdadeira, que associou a característica de gênero ao potencial de uma mulher ser vítima, apenas para justificar a cobrança excessiva ou a recusa na prestação do serviço.

Fora o fato que a violência de gênero é estrutural no mundo e a ela, são os homens que dão causa, não as mulheres, que são vítimas frequentes dos abusos masculinos das posições de poder dentro de casa. Por isso, caso a inferência ou a correlação fossem feitas de maneira correta, elas deveriam aumentar o preço cobrado dos homens, pois eles possuem chances de fazerem mulheres de vítimas, e não o contrário.

As correlações estatísticas também são muito utilizadas por programas que fazem análise de crédito (*credit scoring*), através do ranqueamento de bons e maus pagadores. Nelas, são verificadas as mais diversas características – muitas vezes desnecessárias para a decisão específica – como endereço, fonte de renda, emprego, e até raça e gênero²²⁴. A partir disso, as estruturas de *data mining* conseguem correlacionar a probabilidade de adimplemento de determinada pessoa com base nas características dela e do local onde ela frequenta, compra, mora, trabalha, ou com base na sua cor, gênero, idade, ou quaisquer outras características. E ainda que exista alguém que se enquadre na estatística calculada pela seguradora, podem existir tantas outras pessoas que apresentam características de maus pagadores, mas não necessariamente os são.

Diversas dessas características carregam estereótipos discriminatórios e muitos desses dados podem permitir correlações estatísticas que são fruto de preconceito estrutural. Foi o que ocorreu com um jovem negro nos Estados Unidos²²⁵, bem empregado e sempre adimplente, mas que residia em um subúrbio. Pelo simples fato de morar onde morava, ele foi vítima de uma correlação estatística espúria e inverídica, que reduziu seu limite de cartão de crédito abruptamente, sob a justificativa de que ele possivelmente não iria conseguir pagar seu limite anterior²²⁶.

Em verdade, nos Estados Unidos e na Europa a discussão sobre correlações estatísticas e decisões automatizadas é tamanha que a Suprema Corte Norte-Americana também decidiu, no caso *Griggs v. Duke Power Co.*, que é proibida a discriminação,

²²⁴ HURLEY, Mikella; ADEBAYO, Julios. *Credit Scoring in the Era of Big Data*. Yale Journal of Law and Technology, 2016, v. 148.

²²⁵ ALLOWAY, Tracy. *Big Data: Credit Where credit's due*. The Big Data Read, 2015.

²²⁶ Dentro desse debate, também cabe discutir a edição do Equal Credit Opportunity Act, segundo o qual as análises estatísticas feitas pelas empresas não podem se sobrepor ao direito de todos os indivíduos terem iguais oportunidades de concessão de crédito. A análise de crédito, de fato, é uma prática muito antiga, (como demonstram HSIA, David C.. *Credit Scoring and the Equal Credit Opportunity Act*. Hastings Law Journal, 1978). Contudo, em tempos de *big data*, é necessário discutir os limites dessa análise, justamente para não fazer do Equal Credit Opportunity Act letra morta.

tratamento diferenciado com impacto negativo, de raça em processos automatizados, ainda que o proxy de raça não tenha sido explicitamente utilizado²²⁷. E isso porque, as correlações estatísticas viabilizam decisões racistas através da análise geográfica, por exemplo, o que se mostra igualmente gravoso.

Essa decisão da Suprema Corte é importante porque a forma como são feitas as correlações estatísticas e as inferências é pouco transparente até para os programadores que estruturaram aquele algoritmo, justamente porque há pouco controle sobre as análises estatísticas massivas. Apesar disso, é dos programadores a responsabilidade pelos frutos que são obtidos dessas correlações, cabendo a eles mapear ou não as que são feitas com base em reprodução de estereótipos preconceituosos.

Ainda deve-se destacar que as discussões acerca da forma de funcionamento das estruturas que viabilizam a existência dessas correlações e inferências estatísticas está sujeita à proteção dos segredos de indústria, já que, para vários agentes de mercado, a capacidade de produzir essas correlações é o grande diferencial de seu trabalho²²⁸. Isso também dificulta algumas discussões acerca do potencial discriminatório dessas plataformas, justamente porque se trata de algo valorizado pelos agentes e importante para o desenvolvimento de suas atividades. Apesar disso, a eles cabe assegurar que essas correlações e inferências não sejam feitas de forma discriminatória, em prejuízo de grupos minoritários para o benefício de seus lucros.

²²⁷ FELDMAN, Michael et al. *Certifying and Removing Disparate Impact*. In: Proceedings of International Conference on Knowledge Discovery and Data Mining, 2014, p. 259-268.

²²⁸ Nesse sentido: REDDIX-SMALLS; Brenda. *Credit Scoring and Trade Secrecy: Na Algorithmic Quagmire of How the Lack of Transparency in Complex Financial Models Scuttled the Finance Market*. UC Davis Business Law Journal, 2011, v. 12.

CAPÍTULO 4

POSSÍVEIS SOLUÇÕES PARA ELIMINAÇÃO DA DISCRIMINAÇÃO DE GÊNERO EM PROCESSOS DECISÓRIOS AUTOMATIZADOS

4.1 Considerações preliminares

Feitas as primeiras considerações acerca da forma de funcionamento dos processos decisórios automatizados, da relação entre gênero e tecnologia e também tendo sido mapeados os momentos em que pode ocorrer a discriminação de mulheres através do uso dessas tecnologias, faz-se mister analisar a viabilidade prática e jurídica de se pensar soluções para eliminar esse potencial discriminatório.

A elaboração deste trabalho objetivou, até aqui, desconstruir a ideia de que as decisões automatizadas são neutras e não se sujeitam a vieses. Percebeu-se, ao longo do estudo, que o fato de essas decisões tratarem de análises matemáticas de dados não afasta a possibilidade de os agentes de mercado influenciarem no resultado final, o que pode ocorrer desde a organização da base de dados e do desenho algorítmico, até o treinamento da estrutura de *data mining*. A idoneidade dessas decisões automatizadas, portanto, não pode ser presumida, porque os *softwares* preditivos carecem de critérios técnicos mais robustos e de transparência acerca de seu funcionamento.

Como já dito por Cathy O’Neil, as máquinas operam a favor dos desejos humanos, e os algoritmos nelas inseridos apenas respeitam suas pretensões, reproduzem seus preconceitos e permitem sistematizar, através de um modelo, todas as discriminações, escolhas, subjetividades, interesses e desejos do consciente e do subconsciente humano²²⁹. E isso não se modifica pelo simples fato de ser feito por fórmulas matemáticas humanas de estrutura mais complexa.

Agora, pretende-se introduzir a percepção de que os agentes de mercado efetivamente possuem o controle dessas estruturas e que elas operam a seu favor e em seu benefício. Essa percepção é uma consequência lógica da realidade de não inclusão de mulheres no campo da ciência: se somente os homens participam da produção científica e tecnológica, eles não se importariam com os prejuízos causados às mulheres, motivo

²²⁹ O’NEIL, Cathy. *Weapons of math destruction*. How big data increases inequality and threatens democracy. New York: Crown Publishers, 2016.

pelo qual não se preocupam, ao longo do processo automatizado como um todo, com as questões que poderiam promover a discriminação.

Ainda que exista opacidade nos algoritmos e que falte controle dos rumos preditivos do *data mining*, fato é que essas estruturas operam em favor de alguém. E esse alguém é, em verdade, o agente de mercado monopolista, o qual aumenta seus lucros às custas do tratamento discriminatório de mulheres, porque não se preocupa com essas questões e, por consequência, não investe em soluções para combatê-las. Por esse motivo, é necessário que os agentes de mercado passem a assumir responsabilidades éticas e legais para que a discriminação deixe de ocorrer.

Veja-se que não é a pretensão deste estudo aprofundar as discussões regulatórias acerca da possibilidade de o Estado exercer algum tipo de controle, ou viabilizar o controle do usuário, em relação às decisões automatizadas. Até porque, adotando-se a concepção delineada depois do *Lex Informática*, e também abordada por Lessig, tudo indica que a própria tecnologia é a forma mais eficaz de regulação dela mesma. Nesse sentido, o presente estudo está focado nas etapas da automatização que foram delineadas no terceiro Capítulo, e na forma segundo a qual os agentes, assumindo um compromisso de cuidado com a discriminação (que, inclusive, lhes é legalmente imposto), poderiam mitigar os riscos de prejudicarem mulheres.

A esse respeito, cabe mencionar, preliminarmente, algumas diretrizes que estão sendo discutidas à nível mundial e que podem orientar a busca por soluções para acabar com a discriminação em processos automatizados. Tratam-se de diretrizes genéricas que se aplicam ao processo automatizado e que devem ser perseguidas pelos agentes não nas etapas especificamente delineadas anteriormente, mas na automatização decisória em si considerada. O desenho de uma ética de automatização decisória, de tratamento de dados pessoais e até de inteligência artificial, pode trazer inúmeros benefícios às mulheres, principalmente à luz da luta pela não discriminação.

A primeira delas diz respeito às Diretrizes Éticas para Inteligência Artificial Confiável, elaboradas em 2019 pela Comissão Europeia. Seu objetivo principal era de tutelar grupos vulneráveis (como crianças, pessoas com deficiência e minorias) e grupos em situações de assimetria (como empregados e consumidores). Também aqui, não foi especificada a discussão de gênero, mas elas se aplicam no contexto de minorias que se pretendem proteger. Essas diretrizes envolvem (i) respeito pela autonomia humana; (ii)

prevenção de dados; (iii) justiça; e (iv) explicabilidade²³⁰. Através dessas diretrizes, pretende-se valorizar a preservação da dignidade da pessoa humana nos processos automatizados, a fim de que as decisões sejam justas e tenham sido obtidas assegurando-se algum tipo de controle humano do resultado produzido pela máquina.²³¹

Através dessas diretrizes, a Comissão também adotou como linha política a busca pela não discriminação e pela preservação da diversidade²³², mantendo a coesão com a Declaração Universal dos Direitos e com todas as Constituições que valorizam a autonomia humana e a busca pela igualdade. Trata-se da reprodução de princípios contemporâneos à democracia, que devem ser reafirmados em processos automatizados, porque reforçam o resgate constante que os agentes precisam ter dessas questões.

Em sentido similar, a Organização para a Cooperação e Desenvolvimento Econômico (OECD) editou princípios a serem perseguidos em relação à inteligência artificial, que também se aplicam aos processos de tomada de decisão automatizada. Especificamente aos interesses deste trabalho, destaca-se (i) a transparência da tecnologia, para viabilizar mecanismo de controle das estruturas automatizadas; e (ii) o compromisso com a informação, para que a população compreenda o funcionamento dos processos automatizados e a importância dos dados pessoais nas decisões automatizadas²³³. É preciso eliminar a barreira que foi criada em relação à tecnologia, para que possa haver uma compreensão verdadeira acerca de seus limites, benefícios e riscos.

O Grupo das 20 maiores economias do mundo (G20), na mesma seara, estabeleceu diretrizes específicas a serem perseguidas em razão da digitalização dos variados processos. Elas envolvem (i) um fluxo de dados seguro e confiável; (ii) o desenvolvimento de uma inteligência artificial centrada no ser humano e nos seus interesses; (iii) um compromisso dos Estados com o desenvolvimento tecnológico, com definição e políticas públicas flexíveis, mas robustas, em relação à temática; (iv) um pacto de aprimorar a segurança dos dados e dos usuários na economia digital; e (v) um compromisso de inclusão geográfica, para que outros países possam ter acesso à quarta revolução industrial, bem como de minorias, para que a economia digital seja de livre

²³⁰ EU - Europe Union. *Ethics guidelines for trustworthy AI*. 2019. Disponível em: <<https://ec.europa.eu/digital-single-market/en/news/ethics-guidelines-trustworthy-ai>>; acesso em 22 out 2019.

²³¹ EU Op. cit., 2019.

²³² EU Op. cit., 2019.

²³³ OECD. *OECD Principles on AI*, 2019. Disponível em: <<https://www.oecd.org/going-digital/ai/principles/>>; acesso em 22 out 2019.

acesso, permitindo a participação de diferentes grupos nas variadas etapas dessa economia²³⁴.

O interessante a esse respeito é que o grupo de mulheres do G20 também consolidou diretrizes específicas para o combate da discriminação de gênero e para a promoção da igualdade de mulheres a partir do uso dos mecanismos automatizados. Criou-se um compromisso dos Estados-membros de (i) estabelecerem regulações objetivando a primazia da transparência no processamento de dados pessoais; (ii) incentivarem a criação de bancos de dados abertos e neutros em relação ao gênero; e (iii) criarem políticas públicas e pesquisas que busquem critérios equitativos que poderiam ser inseridos nos algoritmos para corrigir as distorções da vida real quanto à desigualdade de gênero²³⁵.

Assim, existe uma orientação global relevante para que os agentes de mercado possam pensar a ética nos processos automatizados, e grande parte dessa orientação pode ser aplicada à circunstância específica das mulheres. Percebe-se que essa orientação está voltada para a transparência dos processos, e também para a valorização da vida humana, assegurando o controle e a possibilidade de fiscalização em todas as etapas do processo. Há um pacto que está sendo firmado à nível global pela inclusão e pela igualdade na tecnologia, que veda a discriminação na economia digital e que busca compromissos positivos para eliminar uma distorção que ainda ocorre na realidade. Muitos desses compromissos não vem sendo adotados pelos agentes, tampouco pelos Estados que não assumem a atuação positiva que lhes é devida. Mas a simples existência do debate é relevante para que a inclusão de mulheres seja um caminho a ser trilhado de forma efetiva.

Na sequência, serão abordadas as soluções específicas a serem discutidas para cada um dos problemas mapeados, que foram descritas no Capítulo 03. Por óbvio, os princípios e as orientações aqui delineados se aplicam a todas essas etapas, mas pretende-se, neste momento, trazer as questões que podem ser enfrentadas pelos agentes de mercado, pelos agentes regulatórios e também pelos usuários, para coibir a discriminação de mulheres nesses momentos da automatização decisória.

²³⁴ ____, G20 Ministerial Statement on Trade and Digital Economy. Japan, 2019. Disponível em: <<https://www.mofa.go.jp/files/000486596.pdf>> . Acesso em 20, out., 2019.

²³⁵ AVILA, Renata, *et al.*. *Artificial Intelligence: Open Questions about Gender Inclusion*. In: policy Brief w20, Argentina, 2018.

4.2 Possíveis soluções para a discriminação de gênero pela coleta de dados pessoais

Foi possível verificar, no Capítulo 03, que a discriminação de gênero não decorre, apenas, de questões técnicas relacionadas ao uso de algoritmos, mas que ela pode ser fruto do descuido na coleta, armazenamento e tratamento de dados pessoais. Essa ideia afasta um determinismo algorítmico, já que muitos autores costumam atribuir apenas à fórmula matemática a responsabilidade por resultados potencialmente lesivos.

Nesse sentido, as soluções gerais para as questões relacionadas aos dados demandam maior perícia por parte dos agentes de mercado, quando da coleta dos dados, para que o rigor utilizado nos estudos estatísticos, por exemplo, possa ser transportado para o processo decisório automatizado. É o que se passa a discutir, em relação a cada tópico suscitado no Capítulo 03.

4.2.1 Falta de representatividade dos dados

A primeira questão mapeada neste estudo diz respeito à qualidade dos dados utilizados no processo decisório automatizado. Foi introduzida a percepção de que a base de dados pode ser estruturada de forma enviesada, prejudicando o resultado final do processo decisório. E isso se daria (i) pela inexistência de dados produzidos acerca da realidade feminina; (ii) pela insuficiência de dados suficientemente representativos da categoria, e, ainda, (iii) pelos vieses podem surgir em razão do uso de dados que não guardam relação direta com o processo decisório em si. Viu-se, ao fim, que a qualidade dos dados, e também a forma como ocorre a coleta, afastam a presunção de idoneidade científica desses sistemas.

Nesse contexto, a questão que mais se discute como forma de solucionar esse problema é o fato de que os agentes de mercado podem – e devem – assumir o compromisso de estruturarem bases com dados qualitativamente relevantes, nas quais as realidades das diferentes categorias analisadas sejam representadas de forma proporcional e justa, com a amostragem condizente com o percentual de participação desse determinado grupo naquela realidade²³⁶.

Um exemplo interessante que reflete essa perspectiva são as pesquisas feitas para apurar se o sistema de reconhecimento facial da Apple era discriminatório, porque,

²³⁶ CALDERS, Toon; CUSTERS, Bart. What is Data Mining and How Does It Work? In: CUSTERS, Bart *et al.* (Org.). *Discrimination and Privacy in the Information Society*. Data Mining and Profiling in Large Databases. Springer: 2013, p. 46.

muitas vezes, o sistema não conseguia diferenciar rostos chineses. Em sua defesa, a empresa sustentou que esse problema decorreu de um erro estatístico então mapeado, mas que era altamente improvável de acontecer. Contudo, ao fazer novos estudos, apurou-se que o simples compromisso da empresa de buscar representatividade na base dados poderia resolver o problema: se o algoritmo fosse treinado com multiplicidade de dados representativos das diferentes etnias do mundo, a capacidade de diferenciação teria sido melhor aprimorada e os diferentes rostos chineses poderiam ser reconhecidos²³⁷.

Ou seja, bastava, nesse caso, o compromisso do agente de organizar bases de dados de forma mais justa e representativa, o que poderia ter eliminado um problema grande para uma parte relevante da população. Esse compromisso, se adotado também no exemplo dado no Capítulo 03, em relação à seleção de candidatas mulheres, poderia diminuir as distorções salariais de mulheres, que, mesmo mais qualificadas, ganham menos e ocupam postos de trabalho menos relevantes²³⁸. Ao contrário, se o cuidado com os dados inexistente, o algoritmo simplesmente irá reproduzir o padrão existente, que é, essencialmente, prejudicial às mulheres.

Novamente, retoma-se a ideia de que a análise massiva pode dificultar o processo. Contudo, considerando que esses agentes comercializam o serviço de predição estatística por eles feito, é dever assegurar que essas predições sejam apuradas, e isso não é possível sem uma base de dados suficientemente representativa. Controlar as fontes de coleta de dados, fazer uma seleção cuidadosa de conteúdo relacionado ao processo decisório, mapear a realidade da situação que será analisada, dentre outros cuidados, não são questões que impõem excessivos custos ao processo decisório e que podem se mostrar fundamentais para evitar prejuízos às mulheres.

Aqui, reforça-se a importância de ter mulheres participando da manipulação e do desenvolvimento dessas tecnologias. Primeiro, porque elas poderiam ajudar a produzir dados sobre elas mesmas, diminuindo o *gap* de gênero existente nas produções científicas. Segundo, porque existem menos chances de não haver representatividade nos

²³⁷ SILVA, Selena; KENNEY, Martin. Algorithms, Platforms and Ethnic Bias: An Integrative Essay. California: Un Phylon (1960-), Vol. 55, No. 1 & 2, Special Volume: *Remembering the 150th Anniversary of the Birth of W.E.B. Du Bois and the 50th Anniversary of the Death of Martin Luther King, Jr.* (SUMMER/WINTER 2018), pp. 9-37

²³⁸ 2013, p. 46.

²³⁸ GANDRA, Alana. IBGE: Mulheres ganham menos que homens mesmo sendo maioria com ensino superior. Agência EBC Brasi. Disponível em: <<http://agenciabrasil.ebc.com.br/geral/noticia/2018-03/ibge-mulheres-ganham-menos-que-homens-mesmo-sendo-maioria-com-ensino-superior>>. Acesso: 20, out, 2019.

dados se as mulheres participarem da seleção e da organização das informações para análise preditiva.

Produzir decisões discriminatórias não é uma saída para os agentes, já que a obrigação legal de não causar impactos negativos às mulheres se trata, inclusive, de um dever constitucional. Parte desse comprometimento ético, inclusive, é legalmente imposto, e a simples conformidade com a LGPD pode assegurar isso, além melhor controle das bases de dados. Ao fim, é de fácil percepção que não é inviável exigir esse compromisso por parte dos agentes, a fim de assegurar, ao menos no mínimo possível, uma melhor idoneidade à decisão final.

4.2.2 Uso de Dados Históricos

Também foi mapeado o risco no uso de dados históricos, porque eles podem transportar, para dentro do sistema automatizado, uma realidade discriminatória e contaminada com vieses de gênero. O impacto no uso desses dados, como visto, pode ser especialmente prejudicial para mulheres, já que, ainda hoje se luta contra uma realidade de discriminação e o tratamento diferenciado de mulheres é uma constante nos variados mercados. Por esse motivo, diversas são as realidades que, se transportadas para um sistema automatizado, serão contaminadas por dados históricos com vieses de gênero.

Para esse caso, a solução envolve um cuidado do agente de mercado ao estruturar a base de dados que será utilizada no processo decisório, e ao selecionar adequadamente quais dados serão utilizados como *inputs* para criação de um modelo. Como visto, o modelo funciona através de presunções de veracidade, e a preocupação com as minorias durante a sua criação é fundamental para que se possa eliminar esse risco de discriminação de mulheres²³⁹.

Outra questão que se discute é sobre a necessidade de uso de dados históricos em determinados contextos, com objetivo de evitar que uma determinada realidade seja perpetuada. Pode-se pensar, por exemplo, na possibilidade de criação de um modelo com dados que não são verdadeiros, mas que foram produzidos pelo agente com o objetivo de forjar uma realidade utópica que seria desejável, e que se pretende que seja reproduzida pelo algoritmo. Para tanto, o agente construiria dados que se passassem por históricos

²³⁹ BAROCAS, Solon, *et. al. Big data, Data Science, and Civil Rights*. Computing Community Consortium Catalyst, 2017, p. 2.

para auxiliar na criação do modelo e para garantir *inputs* não discriminatórios para os algoritmos.

Como lado negativo dessa proposta, percebe-se que o usuário final que será atingido por essa decisão automatizada estará à mercê das intenções do agente, que poderá forjar dados históricos benéficos ou não, sem que se tenha controle a esse respeito. A garantia de um compromisso ético do agente pode não ser suficiente para assegurar um resultado final idôneo, e isso é algo que precisa ser objeto de preocupação por parte dos legisladores. Veja que a Lei Geral de Proteção de Dados Pessoais não estabelece critérios para estruturação de controle das bases de dados, desconsiderando a importância dessa etapa na automatização e no tratamento de conteúdo em geral.

Apesar disso, e ainda que essa preocupação não seja imposição legal, a não discriminação deve ser, tanto pela LGPD, quanto também pela Constituição Federal, que veda o tratamento diferenciado com impacto negativo. Portanto, se a organização das bases de dados e se o uso de dados históricos podem culminar em resultado discriminatório, há um dever legal do agente de tomar providências para evitar que isso aconteça.

4.2.3 Supressão de dados pessoais sensíveis

O Capítulo 03 apontou que a supressão deliberada de dados pessoais sensíveis, ainda quando feita de boa-fé, para “cegar o algoritmo”, pode culminar em dois problemas, quais sejam (i) a falta de representatividade de dados; e (ii) a reinserção dos conteúdos potencialmente discriminatórios para o processo decisório, através de correlações e inferências estatísticas, sem a necessária conformidade legal inerente à coleta e ao tratamento dos dados pessoais sensíveis.

Antes de adentrar as questões específicas acima apontadas, deve-se destacar que, em um cenário ideal, a supressão dos dados sensíveis não deve ser considerada como uma alternativa quando se pensa em coibir a discriminação de mulheres em processos automatizados. Como delineado anteriormente, todas as diferentes características são importantes para que se assegure a representatividade dentro de uma análise por *data mining*, e a supressão desse tipo de conteúdo não iria promover essa proposta. A conformidade com os critérios legais, por outro lado, se mostra uma primeira saída importante para que a análise de dados sensíveis seja feita de forma consciente, cuidadosa

e não discriminatória, garantindo ao usuário o controle e a participação ativa no processos, inclusive, com direito de oposição ao resultado produzido²⁴⁰.

Para além da conformidade, que será uma questão para os outros problemas mapeados, é importante perceber que estudos recentes demonstram a inefetividade da supressão de dados pessoais sensíveis, ainda quando o propósito é positivo, ao se tentar neutralizar o processo preditivo das características potencialmente discriminatórias. Foi o que concluíram Indre Žliobaite e Bart Custers em um estudo empírico de uma Universidade, quando suprimiram os dados pessoais sensíveis de uma base de dados – nesse caso, o gênero foi considerado um dado sensível – que seria analisada por um algoritmo disposto a fazer previsões salariais. Na oportunidade, o objetivo não era propriamente mapear o potencial discriminatório desse tipo de análise, mas de testar os riscos da supressão dos dados pessoais sensíveis, analisando-se como *proxies* apenas informações relacionadas ao nível da carreira (assistente, professor associado e professor titular), à escolaridade (doutorado e mestrado) e aos anos de formado (indicador de experiência profissional)²⁴¹.

Depois de testar cinco modelos diferentes²⁴², percebeu-se que a eliminação da característica de gênero das bases de dados apenas sugestionava maior neutralidade,

²⁴⁰ A esse respeito, cabe mencionar as considerações de Ana Frazão, Mila Donato Oliva e Vivianne da Silveira Abilio acerca de uma das formas importantes de conformidade normativo, que diz respeito aos programas de *compliance*. Especificamente em relação à questão do tratamento de dados pessoais, e de dados pessoais sensíveis, a adoção de programas de *compliance* – que “*relacionam-se à fixação de controles internos que, em reforço à regulação estatal, auxiliam os agentes econômicos a se manterem em conformidade com a lei*” – é uma saída interessante, já que ajuda a complementar o diploma da LGPD, o qual é dotado de grande plasticidade e possui conceitos ainda abertos, que precisam se contextualizar para a realidade de cada agente específico. Nesse sentido, ver: FRAZÃO, Ana; OLIVA, Milena Donato; ABILIO, Vivianne da Silveira. *Compliance de dados pessoais*. In: FRAZÃO, Ana; TEPEDINO, Gustavo; OLIVA, Milena Donato (coord.). *A Lei Geral de Proteção de Dados Pessoais e Suas Repercussões no Direito Brasileiro*. Revista dos Tribunais: São Paulo, 2019.

²⁴¹ ŽLIOBAITE, Indre; CUSTERS, Bart. *Using sensitive personal data may be necessary for avoiding discrimination in data-driven decision models*. Springer Science + Business Media Dordrecht, 2016, p. 193.

²⁴² Foram testados os seguintes modelos: um padrão, treinado com dados de homens e mulheres; um treinado só com dados de homens; um só com dados mulheres; um modelo cego, treinado sem qualquer dado identificador de gênero; e um modelo denominado *fixed*, ou seja, ajustado para tentar coibir a discriminação de gênero com a inserção do marcador de gênero. A partir disso, a cada uma das características analisadas – nível de carreira, escolaridade e anos de formado – foi atribuído um coeficiente remuneratório, e o resultado final seria a previsão salarial a partir do somatório de cada coeficiente. Nos resultados, percebeu-se que os modelos padrão, o modelo só de homens e o só de mulheres, têm uma tendência de serem vistos como neutros, mas são altamente discriminatórios, já que indicam previsões salariais mais baixas para mulheres do que para os homens. Especificamente para os modelos separados, inclusive, percebeu-se que a base salarial das mulheres era substancialmente menor que a dos homens, mesmo as mulheres tendo um coeficiente maior relacionado à escolaridade. Os modelos treinados sem dados identificadores de gênero também se mostraram prejudiciais às mulheres, na medida em que às características de escolaridade fora atribuído um coeficiente de remuneração base menor. E as mulheres são a categoria mais qualificada, mas acabaram sendo prejudicadas em desfavor do nível de carreira, que é maior entre os homens. No modelo *fixed*, no qual foram inseridos os proxies de gênero com o objetivo de

mas acabava fazendo previsões salariais mais baixas para mulheres do que para os homens, ainda quando elas possuíam um coeficiente maior relacionado à escolaridade²⁴³. Percebeu-se, portanto, que os modelos nos quais os dados pessoais sensíveis foram suprimidos acabavam reproduzindo os estereótipos discriminatórios, reforçando, ainda, que mulheres mais qualificadas de fato tendem a ganhar menos²⁴⁴.

Por outro lado, quando foram reinseridos os proxies de gênero com o objetivo de ajustar as distorções, percebeu-se uma diferença salarial menor entre homens e mulheres²⁴⁵, reforçando a importância dos dados pessoais sensíveis para a análise específica. Conclusões similares em relação à importância da coleta de dados pessoais sensíveis também foram obtidas em estudos relacionados à outras características, como a de raça²⁴⁶, e também em estudos sobre a alocação de recursos públicos feita por algoritmos²⁴⁷.

Ou seja, além da conformidade normativa, a inserção de dados pessoais sensíveis no tratamento de dados é imprescindível. Cabe destacar, nesse sentido, que a própria LGPD enseja contradição a esse respeito. E isso porque, se por um lado elas restringem a coleta e o tratamento de dados pessoais sensíveis, impondo obrigações e limitando o uso através de condicionantes de autorização por parte dos usuários, por outro, a ausência desses dados pode aumentar o potencial discriminatório das decisões automatizadas²⁴⁸.

Há, nesse sentido, um conflito relevante, porque a autorização para tratamento de dados pessoais sensíveis é imprescindível, mas muitas vezes o usuário também desconhece os riscos que podem estar associados à supressão desses conteúdos. E, especificamente às mulheres, é importante que elas estejam seguras em autorizar o

ajustar as distorções, percebeu-se uma diferença salarial menor entre homens e mulheres, e os autores entendem que a mudança só não foi tão significativa porque a quantidade de dados analisado era pouca (e como mencionado no início, um algoritmo é tão bom quanto a base com que ele trabalha).

²⁴³ ŽLIOBAITE, Indre; CUSTERS, Bart. *Using sensitive personal data may be necessary for avoiding discrimination in data-driven decision models*. Springer Science + Business Media Dordrecht, 2016, p. 195.

²⁴⁴ ŽLIOBAITE; CUSTERS, Op. cit., 2016, p. 195.

²⁴⁵ ŽLIOBAITE; CUSTERS, Op. cit., 2016, p. 195

²⁴⁶ Ver: GIILIS, Talia B.; SPIESS, Jann L. *Big Data and discrimination*. The Harvard John M. Olin Fellow's Discussion Paper Series, n. 84, 2019.

²⁴⁷ O'NEIL, Cathy. *Before the Office of the Assistant Secretary For Fair Housing and Equal Opportunity, HUD*. Comment regarding Docket No. FR 6111-P-02, 2019.

²⁴⁸ ŽLIOBAITE, Indre; CUSTERS, Bart. *Using sensitive personal data may be necessary for avoiding discrimination in data-driven decision models*. Springer Science + Business Media Dordrecht, 2016, p. 185.

tratamento de suas informações pessoais sensíveis, ao mesmo tempo em que se sentem seguras com uma decisão automatizada, que não lhes será discriminatória.

4.2.4 Anonimização de dados pessoais

A anonimização de dados pessoais trás um debate muito similar à questão da supressão. Para que se assegure a representatividade nas bases, esse tipo de conteúdo também é imprescindível. À despeito disso, há uma questão da privacidade, que é de suma importância quando se pensa no tratamento e compartilhamento de dados pessoais.

Foi delineado no Capítulo 01 que a questão da privacidade, e da própria natureza dos dados pessoais, enseja muita controvérsia quando se pensa na dinâmica de compartilhamento de informações na rede. Os dados até poderiam ser entendidos como bens jurídicos, mas o ordenamento brasileiro confere a eles o status de extensão da personalidade jurídica, pois são potenciais identificadores do usuário e de suas características.

Essa escolha, como foi dito, prestigia a proteção da privacidade, que vem se tornando um dos maiores conflitos em relação ao desenvolvimento tecnológico. Essa escolha trás ao ordenamento jurídico, e a todas as etapas do tratamento de dados pessoais, destaque à proteção da privacidade, que precisa ser preservado até mesmo quando se pensa em anonimização de dados pessoais. Se a definição da natureza do dado beneficia o direito de o usuário controlar suas informações, então esse valor ético deve estar presente nas ações dos agentes de mercado.

É por isso que, independente do motivo que enseje a anonimização, os agentes de mercado não podem mais se associar à visão ultrapassada de que as características pessoais não serão posteriormente mapeadas n o *data mining*, ou que não serão objeto de correlações estatísticas ou inferências. Essa ingenuidade foge da realidade das empresas que dominam a tecnologia, e também não atende aos parâmetros legais da LGPD, que, novamente, valoriza a privacidade como norte em todos os aspectos e momentos.

Assim, a anonimização de dados pessoais pressupõe risco assumido pelo agente, no sentido de que ele terá que desenvolver mecanismos suficientemente concretos de que as características identificadoras daquele dado serão, efetivamente, apagadas, o que não vem se mostrando possível. Caso contrário, estará o agente assumindo um risco de violar a privacidade dos usuários, e, também, de contribuir para tomadas de decisões

discriminatórias, já que esses dados poderão ser utilizados de forma indevida durante o processo preditivo.

Percebe-se que a possibilidade de anonimização de dados não é vedada pela LGPD, mas há expressa ressalva no art. 12, *caput* e parágrafo primeiro, que o dado será considerado pessoal quando o processo de anonimização puder ser revertido, seja por meios próprios, ou através de esforços razoáveis, a serem apurados de acordo com as tecnologias disponíveis no momento. E pode-se dizer que, de alguma forma, o próprio diploma atribuiu ao agente essa responsabilidade em proteger a privacidade, porque confere a ele o risco de se responsabilizar pela possível reversão da anonimização, e pela eventual não conformidade do dado que poderá ser novamente convertido em pessoal.

4.3 Possíveis soluções para a discriminação de gênero por algoritmos e *data mining*

A segunda etapa do potencial discriminatório dos algoritmos foi mapeada no terceiro Capítulo à luz do desenho algorítmico e do uso e manipulação das tecnologias de *data mining*. Como foi possível perceber, com frequência a opacidade das estruturas autônomas e a capacidade de desenvolvimento próprio através de correlações e inferências estatísticas são utilizadas como justificativa para que os agentes não se responsabilizem pelos resultados potencialmente discriminatórios.

Em relação às mulheres, especificamente, a preocupação é ainda maior, porque o gênero não se encontra expresso como um tipo de dado sensível por si só, que tem potencial discriminatório. Assim, a questão da desigualdade entre homens e mulheres, por vezes, só é abordada quando se percebem resultados abruptamente díspares, que não permitem dúvidas acerca do impacto negativo. A mera perpetuação de um comportamento discriminatório, por sua vez, nem sempre chama a atenção, de modo que mulheres que são submetidas a processos decisórios automatizados continuam sendo vítimas de estereótipos prejudiciais, continuam não sendo selecionadas para vagas de emprego com salários mais altos, dentre outras questões, que não são necessariamente enfrentadas.

Assim, ao analisar potenciais soluções para os problemas mapeados no Capítulo 03 acerca do desenho algorítmico e do uso de *data mining*, é possível perceber que é necessário, além de tudo, um compromisso ético e de conformidade legal por parte dos agentes de mercado. Essa ideia já foi delineada em relação ao potencial discriminatório dos dados, quando se viu que o simples compromisso de respeito à LGPD,

no caso brasileiro, poderia mitigar diversos riscos discriminatórios. Aqui, contudo, essa questão vai além.

O compromisso ético para evitar discriminação de gênero nessas etapas específicas não demanda, apenas, o respeito à lei, já que, por diversas vezes, os sistemas automatizados irão reproduzir realidades discriminatórias. A doutrina mais recente vem falando de um verdadeiro compromisso positivo por parte dos agentes, à luz da ideia de responsabilidade social empresarial²⁴⁹, para que eles adotem medidas corretivas da realidade discriminatória nessa etapa de desenho do algoritmo e de *data mining*, sendo essa uma das melhores formas para mitigar o risco discriminatório. É o que se passa a discutir.

4.3.1 Discriminação inserida no desenho algorítmico

O primeiro tipo de discriminação técnica mapeado neste trabalho diz respeito à discriminação no desenho algorítmico, que pode ocorrer (i) pela promoção de resultados padronizados e não específicos em relação a cada uma das realidades; ou (ii) pela inserção de proxies na estrutura matemática em si, os quais podem privilegiar, ou não, determinadas categorias. Também foi introduzida a percepção de que a falta de transparência acerca do funcionamento das estruturas algorítmicas é uma questão que vem sendo discutida, mas que, com frequência, confunde-se com a opacidade delas.

A respeito dessas questões, inicialmente cabe retomar uma percepção delineada no Capítulo 02, acerca da relação entre gênero e tecnologia. Como foi demonstrado, esse relacionamento conturbado foi muito prejudicado, e ainda o é, em razão da falta de representatividade das mulheres nos espaços de produção do conhecimento científico, justamente porque a elas não foi oportunizada a chance de integrar e participar das etapas de criação da ciência.

Ao se pensar em discriminação de mulheres pelo desenho algorítmico, é fácil perceber que a presença de mulheres enquanto programadoras poderia ter uma forte influência para que esse problema fosse eliminado. E isso ocorreria porque o desenho do algoritmo seria melhor pensado, levando-se em consideração que (i) a estrutura precisa respeitar as diferentes circunstâncias vividas pelas mulheres – motivo pelo qual não

²⁴⁹ VOGUEL, David. *The Market for virtue: the potential and limits of corporate social responsibility*. Brookings Institution Press, 2015.

poderia apenas reproduzir resultados que traduzem a média para todos os casos -, e que (ii) a criação da fórmula matemática não pode ser contaminada.

Uma maior presença de mulheres no campo da ciência poderia ajudar a diminuir a capacidade de inserção de proxies discriminatórios nas estruturas algorítmicas, viabilizando melhores resultados em busca da igualdade. Obviamente essa conclusão parte dos resultados produzidos por pesquisas²⁵⁰, nos quais se verificou que a inserção das mulheres, de forma representativa, no campo da ciência, poderia ajudar a dirimir distorções como um todo. Quando se pensa diretamente no desenho algorítmico, é evidente que essa relação, de fato, poderia ser benéfica.

Outra questão importante a ser adotada como potencial solução para coibir a discriminação no desenho algorítmico diz respeito à falta de transparência que se tem em relação a essas estruturas. Com frequência, as distorções existentes no próprio algoritmo somente são verificadas com a análise dos resultados discriminatórios. Mas, até que isso ocorra, pode ser que os danos causados já sejam irreparáveis à luz da ideia de igualdade.

A opacidade dos algoritmos – característica intrínseca ao seu funcionamento – é utilizada pelos agentes de mercado como justificativa em relação à falta de transparência, esquivando-se eles do compromisso de se responsabilizarem pelos resultados produzidos. Por esse motivo, antes de discutir a viabilidade das soluções para coibir a discriminação em relação a esse ponto, é importante diferenciar a opacidade e a transparência, e analisar se esse pleito realmente ajuda a coibir o problema que vem sendo aqui analisado.

De fato, a opacidade nos algoritmos existe e dificulta a explicação, por parte dos programadores, de alguns resultados produzidos, que lhes fugiram do controle previsto. Essa opacidade, como já foi anteriormente mencionado, decorre da capacidade de desenvolvimento autônomo do algoritmo, e é uma questão inerente ao funcionamento dessas estruturas²⁵¹. Contudo, a opacidade dos algoritmos também possui natureza não técnica, e decorre dos interesses dos próprios agentes de mercado de não revelarem os códigos por eles utilizados. Assim, a opacidade acaba se justificando à luz dos segredos

²⁵⁰ ELSEVIER. *Gender in the Global Research Landscape*. Analysis of research performance through a gender lens across 20 yeas, 12 geographies and 27 subject areas, 2017. Disponível em: <https://www.elsevier.com/data/assets/pdf_file/0008/265661/ElsevierGenderReport_final_for-web.pdf>; acesso em 22 out 2019.

²⁵¹ DONEDA, DANILO ; ALMEIDA, Virgilio A.F. . *What Is Algorithm Governance?*. IEEE Internet Computing, v. 20, p. 61.

de negócios, justamente para que os algoritmos não possam ser estudados e superados, implicando desvantagens concorrenciais para os seus desenvolvedores²⁵².

Portanto, a falta de transparência em relação aos códigos existe, e não é consequência apenas da opacidade dos algoritmos, mas dos interesses dos agentes de mercado que fazem a escolha à luz da proteção de seus interesses individuais. Ocorre que, ainda que essa proteção dos segredos de negócios seja uma garantia que deve ser assegurada, o compromisso de transparência é, hoje em dia, estabelecido em lei, e é um dos princípios a ser perseguido e valorizado.

Na Lei Geral de Proteção de Dados brasileira, por exemplo, uma das vertentes da atuação de boa fé dos agentes que tratam dados pessoais é o compromisso com a transparência (art. 6º, VI), que impõe a garantia, aos titulares, “*de informações claras, precisas e facilmente acessíveis sobre a realização do tratamento e os respectivos agentes de tratamento, observados os segredos comercial e industrial*”. A transparência também aparece como obrigação quando o consentimento do titular dos dados é necessário, como princípio a ser perseguido pela Autoridade Nacional de Proteção de Dados, e como um dos fundamentos da confiança entre o agente de tratamento de dados e o usuário.

A Lei não determina a divulgação dos códigos e estruturas matemáticas, mas impõe o dever de assegurar ao usuário as informações necessárias para que ele tenha conhecimento de como estão sendo tratados seus dados pessoais. Assim, pensando-se na discriminação pelo desenho algorítmico, pode ser que o agente de mercado seja obrigado a divulgar partes de sua estrutura, ou proxies utilizados, sem que isso viole os seus segredos comerciais, a fim de permitir o conhecimento efetivo por parte do usuário sobre como aqueles resultados foram alcançados.

A necessidade de transparência também assegura ao usuário determinadas obrigações por parte do provedor. Por exemplo, no diploma europeu (Regramento Geral de Proteção de Dados – RGPD), o usuário pode requerer informações sobre a lógica subjacente do tratamento de seus dados pessoais, até para se opor à decisão automatizada²⁵³. Desse modo, a própria explicação da lógica do tratamento de dados é

²⁵² DONEDA, Danilo ; ALMEIDA, Virgilio A.F. . *What Is Algorithm Governance?*. IEEE Internet Computing, v. 20, p. 61.

²⁵³ VERONESE, Alexandre. Os direitos de explicação e de oposição frente às decisões totalmente automatizadas: comparando a RGPD da União Europeia com a LGPD Brasileira, p. 406. In: FRAZÃO, Ana; TEPEDINO, Gustavo; OLIVA, Milena Donato (coord.). *A Lei Geral de Proteção de Dados Pessoais e Suas Repercussões no Direito Brasileiro*. Revista dos Tribunais: São Paulo, 2019.

uma obrigação de transparência, e isso pode se relacionar com a estrutura algorítmica, na medida em que o desenho da fórmula pode implicar em resultados potencialmente diferentes.

A LGPD também adotou esse processo, estabelecendo a transparência como um norte de atuação, tanto dos agentes, como da Autoridade. Ainda estabeleceu a possibilidade de o usuário solicitar a revisão das decisões automatizadas a ele relacionadas, além de esclarecimentos sobre os critérios e os procedimentos utilizados (art. 20, parágrafo 1º)²⁵⁴. E isso é transparência, é a própria obrigação do agente de informar seu *modus operandi*.

Além de legal, o pleito de transparência é uma demanda legítima: se todo um processo decisório ocorre através de uma fórmula matemática, seria justo que ela fosse de acesso as usuárias, ou, ao menos, das Autoridades de controle, as quais poderiam garantir que o desenho algorítmico em si considerado não possui a pretensão expressa de beneficiar um grupo em detrimento do outro²⁵⁵.

Pasquale, nesse sentido, argumenta que os algoritmos e os processos automatizados adquiriram tamanha autoridade em termos de tomada de decisão, que a verdadeira transparência, também em relação à sua estrutura, seria a única forma de se legitimar essa autoridade²⁵⁶. Na perspectiva de Frazão, essa transparência é impositiva, pois sem ela “*é muito provável que a programação possa estar permeada de vieses e preconceitos dos programadores, intencionais ou não, que podem levar a erros de diagnóstico ou graves de discriminações*”²⁵⁷. Assim, o compromisso com a transparência também é uma forma de se solucionar o potencial discriminatório dos algoritmos.

Contudo, alguns autores discutem a efetividade jurídica dessa questão, e se, de fato, o pleito de transparência seria plausível e eficaz. Primeiro, porque a transparência é um mero ideal associado à falsa premissa de que, quanto mais informação for relevada, mais conhecimento as pessoas poderão ter acerca das estruturas que as controlam²⁵⁸.

²⁵⁴ VERONESE, Alexandre. Os direitos de explicação e de oposição frente às decisões totalmente automatizadas: comparando a RGPD da União Europeia com a LGPD Brasileira, p. 406. In: FRAZÃO, Ana; TEPEDINO, Gustavo; OLIVA, Milena Donato (coord.). *A Lei Geral de Proteção de Dados Pessoais e Suas Repercussões no Direito Brasileiro*. Revista dos Tribunais: São Paulo, 2019.

²⁵⁵ PASQUALE, Frank. *Restoring transparency to automated authority*. Telecommunications and High Technology Law, v. 9, No. 235, 2011.

²⁵⁶ PASQUALE, Op. cit., 2011.

²⁵⁷ FRAZÃO, Ana. Fundamentos da Proteção dos Dados Pessoais. In: In: FRAZÃO, Ana; TEPEDINO, Gustavo; OLIVA, Milena Donato (Org.). *A Lei Geral de Proteção de Dados Pessoais e Suas Repercussões no Direito Brasileiro*. Revista dos Tribunais: São Paulo, 2019, p. 40.

²⁵⁸ ANANNY, M. and CRAWFORD, K. *Seeing without knowing: Limitations of the transparency ideal and its application to algorithmic accountability*. New Media & Society, 2016, p. 5.

E isso é um ideal porque, a divulgação de códigos, os quais são objeto de grande desconhecimento por parte da população em geral, e até por parte dos agentes regulatórios²⁵⁹, poderia ser utilizado como escudo para a não divulgação de outras informações mais relevantes para se discutir o potencial discriminatório dessas estruturas. Nesse sentido, os críticos dizem que a quantidade de informações divulgadas, muitas delas incompreensíveis, não implicam em maior conhecimento, e que isso se trata, na verdade, de uma manobra visual que pode ser utilizada pelos agentes, priorizando o ver no lugar do entender²⁶⁰.

Essa idealização da transparência para dentro do contexto da tecnologia, segundo argumentam alguns autores, é tamanha que acaba carregando significados diferentes para a discussão de processos decisórios automatizados e de estruturas algorítmicas. São feitas associações no sentido de que a divulgação traz *accountability*, é sinônimo de boa governança e de decisões mais justas, mas isso não é necessariamente verdadeiro²⁶¹. Assume-se que a obscuridade é ruim, e representa uma obstrução na relação de confiança que se estabelece entre duas partes²⁶².

À luz dessas críticas, percebe-se que, para ser efetivo, o pleito de transparência deve se associar à uma ética de proteção de dados, bem como a um compromisso, o qual é estabelecido constitucionalmente, de que a automatização não será discriminatória. E esse compromisso ético pode ser estabelecido de várias maneiras, sem inviabilizar as atividades principais dos agentes que tratam dados, e sem divulgar informações técnicas excessivas que prejudiquem a compreensão da população sobre o funcionamento da automatização decisória. Para que as pessoas se sintam seguras em relação a esses sistemas, é necessário construir uma relação de confiança, regulada e fiscalizada por Autoridades competentes e técnicas²⁶³.

Existem diversas formas de se estabelecer essa relação de confiança, e uma delas é à luz da responsabilidade social empresarial, por meio da qual os agentes de mercado tentarão se beneficiar da divulgação de ideais valorizados na sociedade, a fim

²⁵⁹ PASQUALE, Frank. *The Black Box Society: The Secret Algorithms That Control Money and Information*, Harvard University Press, 2015, p. 7.

²⁶⁰ ANANNY, M.; CRAWFORD, K. *Seeing without knowing: Limitations of the transparency ideal and its application to algorithmic accountability*. New Media & Society, 2016.

²⁶¹ ANANNY; CRAWFORD, Op. cit., 2016, p. 4

²⁶² ANANNY; CRAWFORD, Op. cit., 2016, p. 4

²⁶³ RICHARDS, Niel M.; KING, Jonathan H. Big Data Ethics. *Wake Forest L. Rev.* 393, vol. 49, 2014, p. 421.

de alcançarem mercados diferentes²⁶⁴. Os programas de *compliance* são outra forma, e se prestam a aumentar a confiança do usuário em relação ao comprometimento do agente em manter a conformidade legal em relação ao uso dos dados, o que pode ser um verdadeiro indicativo de que as decisões automatizadas naquele nível não serão discriminatórias.

A auditoria de algoritmos também vem sendo abordada como saída diferente em relação à transparência de algoritmos, e como solução possível para coibir a discriminação nas estruturas algorítmicas. Parte-se da premissa de que, de fato, os algoritmos podem ser manipulados socialmente, e de que os resultados produzidos nos processos automatizados podem estar sujeitos aos vieses inconscientes e conscientes dos programadores²⁶⁵.

A partir disso, a auditoria de algoritmos compreende o estudo de campo feito por pesquisadores externos ou internos ao agente que elaborou o algoritmo, quando se suspeita que o processo automatizado foi corrompido. O propósito do estudo é verificar um potencial discriminatório, criando situações com perguntas fictícias que devem ser respondidas pelo algoritmo a fim de testá-lo²⁶⁶. Assim, as auditorias de algoritmos seriam experimentos controlados desses sistemas, com propósito inicial e final definido e que permitiram resultados científicos acerca do potencial discriminatório dessas estruturas. Para que a auditoria seja realizada, não necessariamente é necessária a divulgação das estruturas algorítmicas, das bases de dados utilizadas, tampouco dos proxies que são inseridos na fórmula.

O que se chama auditoria de algoritmos hoje, em verdade, remonta a uma ideia ainda da década de 70, quando alguns pesquisadores utilizavam pesquisas de campo controladas para identificarem discriminação de raça em determinadas unidades do governo norte-americano. Todo o estudo era feito sem que a pessoa soubesse que estava sendo testada, e os resultados, obtidos costumavam refletir com precisão a realidade discriminatória dos locais. Com o tempo, a auditoria passou a se associar à contabilidade,

²⁶⁴ FRAZÃO, Ana; PRATA DE CARVALHO, Ângelo. Responsabilidade Social Empresarial, in FRAZÃO, Ana, *Constituição, Empresa e Mercado* (org.), Brasília, 2017.

²⁶⁵ SANDVIG, Christian, et al.. Auditing algorithms: Research Methods for Detecting Discrimination on Internet Platforms. Paper presented to “Data and Discrimination: Converting Critical Concerns into Productive Inquiry,” a preconference at the 64th Annual Meeting of the International Communication Association. May 22, 2014; Seattle, WA, USA.

²⁶⁶ SANDVIG, Op. cit., 2014, p. 5.

mas ela acabou se estruturando em estudos com propósitos exclusivos de identificar a discriminação, consolidando-se como uma estrutura de controle confiável²⁶⁷.

A própria Lei Geral de Proteção de Dados Pessoais estabelece a auditoria como uma das possíveis formas de controle das estruturas automatizadas, e ela é apresentada como uma alternativa para que a Autoridade Nacional de Proteção de Dados possa apurar o potencial discriminatório no tratamento dos dados pessoais (art. 20, parágrafo 2º). Há, portanto, um reconhecimento legal de que esse mecanismo pode mapear o mal ferimento das estruturas aos princípios que devem nortear todo a automatização na leitura de dados pessoais.

O modelo mais conhecido de auditoria diz respeito ao controle de perfis de teste, segundo o qual algumas estruturas específicas são selecionadas e testadas com objetivos previamente determinados, muitas vezes sem saber que estão sendo alvo desse tipo de análise. Através do controle dos resultados, é possível mapear a ocorrência, ou não, de discriminação através daquele sistema específico²⁶⁸. Também é possível fazer auditorias do código algorítmico através da criação de outros algoritmos. Nessas circunstâncias, os próprios agentes de mercado divulgam algumas partes de seus códigos, e, através de uma regressão de resultados, as fórmulas da auditoria conseguem fazer testes para mapear processos discriminatórios²⁶⁹.

A contrapartida desse tipo de auditoria é que nem sempre aquela parte do código que foi disponibilizada para teste possui relevância ou é determinante para o resultado discriminatório, principalmente quando inserida no contexto completo do processamento de dados²⁷⁰. Além disso, ela pressupõe uma atuação positiva por parte dos agentes, que teriam que disponibilizar uma parte, ainda que pequena, de suas estruturas, como foi sugerido por Frank Pasquale em uma de suas propostas de efetivação do pleito de transparência²⁷¹.

Um outro modelo de auditoria envolve pesquisas dos usuários que estão submetidos àqueles processos decisórios. A estrutura decisória em si não é testada, mas o processo todo é feito através de uma pesquisa de campo indireta, juntamente com coleta

²⁶⁷ SANDVIG, Christian, et al.. Auditing algorithms: Research Methods for Detecting Discrimination on Internet Platforms. Paper presented to “Data and Discrimination: Converting Critical Concerns into Productive Inquiry,” a preconference at the 64th Annual Meeting of the International Communication Association. May 22, 2014; Seattle, WA, USA, p. 4/6.

²⁶⁸ SANDVIG, Op. cit., 2014, p. 12.

²⁶⁹ SANDVIG, Op. cit., 2014, p. 12.

²⁷⁰ SANDVIG, Op. cit., 2014, p. 12.

²⁷¹ PASQUALE, Frank. “Beyond Innovation and Competition: The Need for Qualified Transparency in Internet Intermediaries,” 104 Northwestern University Law Review 105, 2010.

de resultados. Por um lado, elimina-se a atuação direta do agente de mercado que manipula aquela estrutura algorítmica, evitando que a auditoria não seja contaminada. Por outro, toda a auditoria está submetida a alguns erros característicos das pesquisas feitas por formulários, como a amostragem, a divergência de entendimentos no preenchimento dos formulários e até à opinião pessoal do usuário, que não necessariamente reflete o potencial discriminatório²⁷².

Os próprios testes diretos e controlados das estruturas algorítmicas podem ser feitos de formas diversas. As vezes por programas de computador que criam perfis diferentes e submetem-se ao processo decisório, as vezes pela contratação de um grupo de usuários que esteja disposto a compartilhar os resultados dos processos aos quais eles foram submetidos²⁷³. Ao fim, percebe-se que existem várias formas de auditoria de algoritmos, e que permitem um maior controle do usuário e das próprias agências em relação à estrutura que é utilizada para embasar todo o processo decisório.

Na maior parte das circunstâncias, os resultados produzidos não irão indicar exatamente em que etapa do processo decisório ocorreu a discriminação. Mas, sabendo que a Lei Geral de Proteção de Dados Pessoais impõe uma atuação de boa-fé e ainda veda qualquer tipo de discriminação através do uso de dados pessoais (art. 6º, IX), a partir dos indicativos apurados pelas auditorias é juridicamente viável impor aos agentes de mercado a obrigação de produzirem investigações mais profundas para verificarem o verdadeiro potencial discriminatório daquela estrutura, e viabilizarem resultados que estejam em conformidade legal.

Há uma outra forma mais inovadora de coibir a discriminação, que avança muito mais na perspectiva de responsabilidade social empresarial delineada anteriormente, e assume uma atuação positiva por parte dos agentes para também tentar reverter o quadro discriminatório. Essa solução vem sendo aventada pelos otimistas em relação à automatização, que defendem que o uso de máquinas para tomada de decisões realmente pode ensejar muitos benefícios, já que as estruturas são, de fato, mais controláveis que o subjetivo do consciente (e subconsciente) humano.

É o que entende Kleiberg *et al.*, por exemplo, ao assumir que a interferência direta no design dos algoritmos, associado a um intenso controle das estruturas

²⁷² SANDVIG, Christian, et al.. Auditing algorithms: Research Methods for Detecting Discrimination on Internet Platforms. Paper presented to “Data and Discrimination: Converting Critical Concerns into Productive Inquiry,” a preconference at the 64th Annual Meeting of the International Communication Association. May 22, 2014; Seattle, WA, USA, p. 15.

²⁷³ SANDVIG, Op. cit., 2014, p. 15.

algorítmicas e de seu funcionamento, pode viabilizar a eliminação das distorções discriminatórias²⁷⁴. E isso se daria através da inserção dos chamados proxies positivos. Como visto, os proxies são as características constantes no algoritmo que correlacionam comandos específicos do mundo real para aquela estrutura matemática.

Segundo entende o autor, seria possível inserir comandos específicos na estrutura do algoritmo para que ele atuasse beneficiando positivamente os grupos minoritários, a fim de lhes assegurar a igualdade²⁷⁵. Essa ideia também é convergente com a percepção que foi delineada no segundo capítulo, e que também vem sendo adotada pelo ordenamento jurídico brasileiro, segundo o qual a efetiva busca pela igualdade material pressupõe uma atuação positiva por parte dos agentes, para que, através do tratamento diferenciado, grupos minoritários – incluindo mulheres – possam se inserir na sociedade.

Os proxies positivos, nesse sentido, poderiam assegurar esse tratamento diferenciado, obrigando as estruturas decisórias a beneficiarem esses grupos em decisões, à luz das concepções mais modernas de igualdade. Nesse sentido, Friedman e Nissenbaum entenderiam os proxies positivos como os vieses emergentes que elas defendem em seus estudos: aqueles vieses não negativos, que se mostram como formas de alterar comportamentos sociais relevantes em razão dos resultados que podem produzir²⁷⁶.

Percebe-se, nesse sentido, que a capacidade do algoritmo é um mundo a parte que envolve as pretensões de cada programador. Contudo, à despeito da opacidade inerente a essas estruturas, o controle é viável e pode ser feita a partir de diversas soluções distintas. O fundamental em relação ao potencial discriminatório dos algoritmos é não o ignorar, adotando uma atuação positiva de sempre testar as estruturas para evitar prejuízos às mulheres.

4.3.2 Discriminação através do treinamento do algoritmo e criação do modelo

A discriminação através do treinamento do algoritmo ou da criação de modelo é decorrente do transporte de vieses, por parte do programador, ao algoritmo em um

²⁷⁴ KLEINBERG, Jon; et. al. *Discrimination in the age of algorithms*, 2019.

²⁷⁵ KLEINBERG, Op. cit., 2019.

²⁷⁶ FRIEDMAN, Batya; NISSENBAUM, Helen. *Bias in Computer Systems*. ACM Transactions on Information Systems, v. 14, n. 3, 1996, p. 336.

momento crucial de sua estruturação, qual seja a etapa em que a estrutura matemática está aprendendo, por assim dizer, como ela deverá operar.

A forma principal de coibir esse problema envolve o compromisso de transparência dos agentes de mercado²⁷⁷. Quais foram os critérios utilizados pelos programadores para treinarem o algoritmo, ou quais foram as características constantes no modelo, são questões que podem ser divulgadas quando se pretende assegurar a idoneidade das decisões que serão tomadas por aquelas estruturas. Trata-se, em alguma medida, de divulgar a metodologia segundo o qual aquela decisão estará sendo tomada, e isso não viola segredos industriais, tampouco prejudica, sob a perspectiva da concorrência, o modelo de negócios dos agentes²⁷⁸.

Novamente, aqui se insere a perspectiva de que o agente de mercado, para ser transparente sobre como funciona a automatização de suas estruturas, não precisa, necessariamente, divulgar seus códigos. Ele pode divulgar quais são os critérios que estão sendo objeto de análise, qual a metodologia de funcionamento daquela estrutura, e quais os tipos de dados vão ser considerados pelo algoritmo, que, para mapeamento desse tipo de discriminação, poderá ser suficiente.

Trata-se, ao fim e ao cabo, da adoção de uma ética de não discriminação nos processos decisórios, que envolve desde a coleta de dados até a produção de um resultado final, a fim de que se possa garantir que as mulheres não estão, efetivamente, sendo prejudicadas²⁷⁹. Essa ética persegue ideais de transparência²⁸⁰, juntamente com todos os princípios que vem sendo delineados pela comunidade internacional acerca de um tratamento de dados em massa feito de forma justa e comprometida com a igualdade.

4.3.3 Discriminação no *data mining* por correlações e inferências estatísticas

²⁷⁷ Aqui, cabe destacar o entendimento de Solon Barocas et. al, ao dizer que o controle decisório dos sistemas automatizados presume não apenas a compreensão dos modelos que são utilizados, mas também porque os modelos utilizados são como são: “More deeply, in order truly to understand the civil rights implications of data-driven systems, we don’t only need to understand the models and the decisions that they make, but we also need to understand why the models are as they are! [Tradução livre: Mais profundamente, a fim de entender as implicações dos direitos humanos nos sistemas automatizados, nós não precisamos apenas entender quais os modelos e decisões que são utilizados, mas também entender por que os modelos são como são.] BAROCAS, Solon, et. al. *Big data, Data Science, and Civil Rights*. Computing Community Consortium Catalyst, 2017, p. 5.

²⁷⁸ BAROCAS, Solon, et. al. *Big data, Data Science, and Civil Rights*. Computing Community Consortium Catalyst, 2017.

²⁷⁹ BAROCAS, Solon, et. al. *Big data, Data Science, and Civil Rights*. Computing Community Consortium Catalyst, 2017.

²⁸⁰ RICHARDS, Neil M.; KING, Jonathan H. *Big Data Ethics*. Wake Forest Law Review, No. 393, 2014.

Por fim, foi verificado que a própria tecnologia de *data mining* pode permitir a realização de correlações e inferências estatísticas que não são necessariamente verdadeiras, e que podem ser fruto, muitas vezes, de associações estereotipadas preconceituosas, que prejudicam mulheres.

Como essas correlações são feitas com base nos dados que são utilizados no processamento do conteúdo, o primeiro passo para tentar solucionar esse problema é, retomando a ideia anteriormente delineada, garantir a representatividade e a qualidade dos dados que vão ser tratados. Assim, a base de dados poderá se aproximar mais de uma representação da realidade, e eventuais correlações e inferências poderão ser mais precisas e próximas da realidade.

Uma segunda questão relevante diz respeito ao fato de que essas correlações são fruto, também, da opacidade de funcionamento dos algoritmos, e muitas vezes são produzidas sem o controle dos programadores. Ainda assim, essa questão já foi enfrentada neste trabalho, e, para que ela seja resolvida, é importante que o compromisso de transparência se sobreponha às dificuldades técnicas que decorrem do desenvolvimento tecnológico²⁸¹. Portanto, mesmo que os programadores e agentes de mercado não consigam controlar a existência de correlações, eles são responsáveis diretos pelos resultados que elas irão produzir, e cabe a eles a auditoria completa dos códigos e das estruturas que foram utilizadas, a fim de assegurar a conformidade legal que veda a discriminação²⁸².

Esse vem sendo o posicionamento adotado pelo poder judiciário ao decidir questões nesse sentido. Além do exemplo da Suprema Corte Americana que foi citado, o Superior Tribunal de Justiça (STJ) decidiu, recentemente, que a Google deveria ser obrigada a criar critérios de desindexação de resultados, justamente para neutralizar resultados potencialmente discriminatórios causados pelo algoritmo de busca²⁸³. No

²⁸¹ CHEN, Daizhuo, *et. al. Enhancing Transparency and Control when Drawing Data-Driven Inferences about individuals*. New York, 2016, ICLML Workshop on human interpretability in machine learning (WHI 2016), nesse sentido, produziu um estudo a fim de apurar as correlações estatísticas feitas pela rede social Facebook através dos likes dos usuários. Como conclusão final do trabalho, foi possível verificar que não há qualquer controle ou transparência da plataforma em relação à como essas correlações e inferências são feitas, a fim de produzir os resultados que mostram ao usuário todas as interações às quais ele tem acesso na rede, desde anúncios, até páginas de interesses. A partir disso, o estudo suscita uma discussão acerca da necessidade de transparência dessas plataformas, justamente para que o controle final do processo decisório seja do usuário.

²⁸² BAROCAS, Solon, *et. al. Big data, Data Science, and Civil Rights*. Computing Community Consortium Catalyst, 2017, p. 5.

²⁸³ STJ. Recurso Especial 1.660.168/RJ. Relatora: Min. Nancy Andrighi, 2018. Disponível em: <<https://stj.jusbrasil.com.br/jurisprudencia/595923405/recurso-especial-resp-1660168-rj-2014-0291777-1/inteiro-teor-595923409?ref=juris-tabs>>; acesso 22 out 2019.

juízo do Recurso Especial nº 1.660.168, a Corte teve a preocupação de não obstar a produção do resultado, a fim de não caracterizar o cerceamento do direito de informação quando uma busca fosse realizada. Contudo, a preocupação com o resultado discriminatório – ainda que não fosse exatamente essa a discussão objeto de debate – fez com que o agente de mercado fosse obrigado a adotar uma conduta positiva de controle dos seus resultados, mesmo que eles tivessem sido produzidos de forma alheia ao seu controle, através de correlações e inferências, à luz da opacidade de funcionamento do algoritmo.

Ao fim, percebe-se que, cada vez menos, os argumentos de impossibilidade técnica vêm sendo aceitos pelos legisladores e juízes como tentativa de justificar a produção de resultados discriminatórios. Os algoritmos são opacos, os dados são produzidos em grandes quantidades, o *data mining* funciona sem controle dos programadores e as correlações e inferências são fruto de resultados estatísticos não previstos. Todas essas questões são verdadeiras, mas também é verdadeiro o fato que são produzidos resultados, e eles podem prejudicar diretamente a vida dos usuários.

No contexto da discriminação da mulher, sabendo as dificuldades que são enfrentadas por esse grupo, é fundamental que os agentes assumam a responsabilidade e o compromisso ético de produzirem resultados em atenção ao ideal democrático contemporâneo de justiça. E correlações e inferências que são produzidas alheias à verdade real não podem ser obstáculos desse processo.

CONCLUSÃO

A busca pela igualdade de gênero é uma constante. Ela demanda, dentre outras coisas, pressão política intensa, para que os governos tenham atuação positiva e possam promover a equiparação das oportunidades e pesquisas nas mais variadas áreas do conhecimento, a fim de medir os impactos do machismo em relação às mulheres.

O presente trabalho se insere nesse contexto, e objetiva trabalhar uma análise conjunta do direito e da tecnologia, a fim de medir os impactos do desenvolvimento na realidade das mulheres. A revisão bibliográfica elaborada permitiu concluir que as decisões automatizadas podem reproduzir discriminação de minorias, dentre as quais se enquadra a discriminação de gênero. Por isso, o agente de mercado precisa se munir de diversos mecanismos de controle, desde e a elaboração da base de dados, até a produção do resultado decisório, para diminuir os riscos dessa discriminação.

Frise-se que o agente tem a obrigação legal de não discriminar, não só em decorrência da LGPD, mas da Constituição que estabelece a igualdade de todos. Assim, não se trata apenas de boa-fé, mas sim de uma obrigação necessária para evitar que as mulheres sejam prejudicadas com a automatização.

No Capítulo 01 foram detalhadas definições para a compreensão adequada de como se dá o funcionamento dessas estruturas automatizadas. Foi definido o que é o dado pessoal e quais as suas principais categorias a ele relacionadas: os dados pessoais sensíveis e os anonimizados. Foi detalhado que o gênero deve ser considerado um dado pessoal sensível, em razão do seu potencial discriminatório e que os dados anonimizados não necessariamente eliminam características identificadoras dos usuários.

Também foram detalhadas no Capítulo 01 as definições de *big data*, algoritmo e *data mining*. A respeito do *big data*, foi possível perceber que seu surgimento esteve associado à quarta revolução industrial, representando o auge da capacidade humana de tratamento de dados em massa. Contudo, esse não foi um desenvolvimento tecnológico democrático, não só porque muitos países sequer tiveram acesso à essa tecnologia, mas também porque ela foi, e vem sendo, utilizada para perpetuar preconceitos em relação às mulheres. Sobre os algoritmos, foi detalhado que se tratam de simples transcrições matemáticas dos desejos dos programadores, e que, por esse motivo, podem ser contaminados com vieses conscientes e inconscientes dos programadores. Por fim, em relação ao *data mining*, através da definição, foi possível compreender que se

trata da análise matemática que culmina numa predição estatisticamente plausível, mas que não possui presunção de neutralidade, tampouco é cientificamente idôneo.

No Capítulo 02 foi detalhada a relação entre o gênero e a tecnologia, com o objetivo de compreender por qual motivo a discriminação de gênero ainda é realidade no tratamento de dados em massa. Foi possível perceber que nunca houve uma verdadeira ocupação das mulheres no campo da ciência e do desenvolvimento tecnológico, o que é apenas mais um reflexo da discriminação histórica vivida por elas. Além disso, as poucas que conseguiam adentrar esse campo sofriam com estereótipos de gênero que obstaculizavam a verdadeira participação feminina na produção técnica. Por esse motivo, as tecnologias poucas vezes consideravam, e pode-se dizer que até hoje é assim, a realidade das mulheres, o que acaba reforçando a situação de discriminação.

Também no Capítulo 02 foi construída uma definição de discriminação de gênero. Essa construção é importante porque, considerando que o *data mining* trata, por natureza, de um tipo de análise estatística de discriminação de resultados, era necessário compreender os limites da conduta negativa que causa prejuízo às mulheres. Nesse sentido, a definição foi elaborada a partir da ideia de que a discriminação de gênero, com conotação negativa, diz respeito ao tratamento diferenciado de mulheres, que distancia esse público minoritário da ideia de igualdade. Essa igualdade deve ser feita a partir da valorização da diferença de cada uma, considerando as realidades específicas inerentes a elas. Ao fim, qualquer decisão que distancie as mulheres dessa inclusão, e que lhes cause impacto negativo, seria entendida como discriminação de gênero.

Já no Capítulo 03, com base na compreensão de como se dá a automatização e na definição de discriminação de gênero, foi construída uma tipologia da discriminação em processos decisórios automatizados. Essa tipologia compreendeu dois momentos distintos dos processos, considerando a importância específica de cada um deles: (i) discriminação de gênero pelos dados e bases de dados, que ocorre em relação aos conteúdos que vão ser tratados pelos algoritmos; e (ii) discriminação de gênero por algoritmos e *data mining*, que dizem respeito à técnica da análise de conteúdo.

O primeiro tipo, discriminação de gênero pelos dados e bases de dados, pode se dar (a) pela falta de representatividade de dados, que é quando as bases não retratam grupos de forma proporcional à realidade, seja por descuido do agente de mercado, seja pela inexistência de dados; (b) pelo uso de dados históricos, porque, valendo-se de informações que retratem realidades pretéritas, os sistemas automatizados poderão reproduzir padrões discriminatórios; (c) pela supressão de dados pessoais sensíveis,

quando, com o objetivo de se esquivar da conformidade em relação ao tratamento de dados pessoais, ou até com a positiva iniciativa de tentar confundir o algoritmo em relação às informações potencialmente discriminatórias, o agente permite que a estrutura deixe de levar em consideração os dados sensíveis; e (d) pela anonimização de dados pessoais, que ocorre quando as características pessoais retiradas dos dados, para fins de não conformidade legislativa, são novamente inseridas no processo de tratamento de conteúdo através de inferências e correlações estatísticas não necessariamente verdadeiras.

Já a discriminação de gênero por algoritmos e por *data mining*, o segundo tipo de discriminação analisado, pode se dar (a) pelo desenho algorítmico, quando os agentes de mercado estruturam as fórmulas matemáticas com proxies discriminatórios, de forma intencional ou não; (b) pelo treinamento do algoritmo, que ocorre no momento da criação de modelos discriminatórios e no ensinamento da estrutura matemática de padrões enviesados em relação às mulheres; e (c) pelas correlações e inferências estatísticas do próprio *data mining*, que são as conclusões adotadas pela estrutura automatizada, através de análises matemáticas, não são necessariamente verdadeiras.

Através desse mapeamento realizado no Capítulo 03, foi possível compreender que o desenho algorítmico é apenas uma parte na qual pode ocorrer o tratamento diferenciado de mulheres. O agente comprometido com a lei e com a Constituição precisa adotar rigor científico na coleta de dados, e monitorar atentamente todas as etapas da automatização, para que a representatividade dos dados, os algoritmos e os resultados produzidos sejam passíveis de controle para evitar a discriminação.

Por esse motivo, o Capítulo 04 aborda discussões centrais para o processo automatizado como um todo, como a necessidade de se adotarem diretrizes éticas amplamente difundidas pelo mundo, além de ideias específicas para cada uma das etapas desses processos. Em relação às orientações gerais, são mencionados os valores éticos que precisam ser perseguidos pelos agentes, como a maior transparência de estruturas, o respeito à finalidade da coleta de dados e a garantia do controle do processo ao usuário, além da valorização da dignidade da pessoa humana em cada etapa.

Para as etapas específicas da automatização, foram abordadas ideais específicas, como (i) a busca pela conformidade legal, que envolve o respeito aos diplomas legais, mas também aos princípios adotados pela comunidade internacional que norteiam o tratamento de dados em massa; (ii) a atuação positiva dos agentes de mercado, à luz da responsabilidade social empresarial, com objetivo de assegurar um compromisso ético e honesto, baseado em uma relação de confiança legítima estabelecida entre o

usuário e o agente, que permita atuar em busca da não discriminação e também da reversão da situação discriminatória hoje vivida pelas mulheres; (iii) a adoção de critérios de transparência efetivos, que não impliquem na simples divulgação de informações excessivas e inteligíveis para a maior parte das pessoas, mas que permitam compreender a metodologia utilizada no tratamento de conteúdo, os critérios valorados pelos algoritmos, os proxies utilizados e a forma de produção decisória; e (iv) o uso de auditorias, não apenas na forma legalmente prevista, mas também como ferramenta de assegurar a transparência da automatização decisória; e (v) os proxies positivos, como formas de se inserirem elementos na estrutura algorítmica que vão coibir a discriminação.

No Capítulo 04, foi possível perceber que as impossibilidades técnicas atinentes aos processos decisórios não devem ser uma barreira na busca pelo fim da discriminação, principalmente porque os agentes devem se responsabilizar pelos resultados produzidos. Não suficiente, percebeu-se que a transparência não pode ser um ideal utópico de divulgação irrestrita de informações, mas sim representar a criação de uma relação de confiança entre os agentes e o usuário, pautada na fiscalização por parte de Autoridades competentes, e na valorização do ser humano e da dignidade da pessoa humana.

Ao fim, percebe-se que a luta pela não discriminação de mulheres em processos automatizados irá envolver uma batalha para que as questões técnicas inerentes ao uso de algoritmos e tecnologias do tipo *data mining*, como a opacidade, não sejam utilizadas como barreiras para coibir o avanço da igualdade. Trata-se de uma questão que ainda precisa ser muito debatida, e que envolve um compromisso direto dos agentes de mercado, dos usuários, e também dos governos para que a automatização ocorra em benefício da igualdade e da dignidade, e não dos interesses monopolistas dos agentes de mercado.

REFERÊNCIAS

- AFFELT, Amy. *Big Data, Big Opportunity*. Australian Law Librarian, vol. 21, No. 2, 2013.
- ALLOWAY, Tracy. *Big Data: Credit Where credit's due*. The Big Data Read, 2015.
- ALMEIDA, Virgílio A.F.. Privacy Problems in the Online World. IEEE Internet Computing, v. 16, p. 4-6, 2012.
- ANANNY, M. and CRAWFORD, K. *Seeing without knowing: Limitations of the transparency ideal and its application to algorithmic accountability*. New Media & Society, 2016.
- AVILA, Renata, et al. *Artificial Intelligence: Open Questions about Gender Inclusion*. In: policy Brief w20, Argentina, 2018.
- BAROCAS, Solon; SELBST, Andrew D. *Big Data's disparate impact*. California Law Review, 2016.
- BAROCAS, Solon, et al. *Big data, Data Science, and Civil Rights*. Computing Community Consortium Catalyst, 2017.
- BAROCAS, Solon. *Data mining and the discourse on discrimination*. Proceedings of the Data Ethics Workshop, Conference on Knowledge Discovery and Data Mining, 2014.
- BEAUMONT, Claudine. *Bill Gates's Dream: A computer in every home*. Telegraph, 27 jun 2008.
- BRAGA, Carolina. Discriminação nas decisões por algoritmos: Polícia Preditiva, p.685. In: FRAZÃO, Ana; MULHOLLAND, Caitlin (coord.). *Inteligência Artificial e direito: ética, regulação e responsabilidade*. São Paulo: Thomson Reuters, 2019.
- BRAY, Francesca. *Gender and Technology*. The Annual Review of Anthropology, 2007.
- CALDERS, Toon; CUSTERS, Bart. What is Data Mining and How Does It Work? In: CUSTERS, Bart et al. (Org.). *Discrimination and Privacy in the Information Society*. Data Mining and Profiling in Large Databases. Springer: 2013.
- CALDERS, Toon; ŽLIOBAITĖ, Indrė. Why Unbiased Computation Process Can Lead to Discriminative Decision Procedures. In: CUSTERS, Bart et al. (Org.). *Discrimination and Privacy in the Information Society*. Data Mining and Profiling in Large Databases. Springer: 2013
- CASTELLS, Manuel. *Networks of Outrage and Hope*. Social movements in the internet age. Cambridge: Polity Press, 2a ed. 2015.
- CHEN, Daizhuo, et al. Enhancing Transparency and Control when Drawing Data-Driven Inferences about individuals. New York, 2016, ICLML Workshop on human interpretability in machine learning (WHI 2016).
- CHRISTIN, Angèle; ROSENBLAT, Alexa; BOYD Danah. Courts and Predictive Algorithms. Nova Iorque: New York University, Criminal Justice Policy Program, 27 de outubro de 2015. Disponível em: <http://www.law.nyu.edu/sites/default/files/upload_documents/Angele%20Christin.pdf>; acesso em 22 out 2019.
- CORMEN, T.H. *Algorithms Unlocked*. MIT Press, 2013.
- COCKBURN, Cynthia. *Male Dominance and Technological Change*. Pluto press: London, 1983.
- COWAN, Ruth. *More Work for Mother: The Ironies of Household Technology from the Open Hearth of the Microwave*, Basic Books: New York: 1983.
- DINIZ, Debora; MEDEIROS, Marcelo; MADEIRO, Alberto. *Pesquisa Nacional do Aborto 2016*. Ciência e Saúde Coletiva [online], 2017, vol. 22. Disponível em: <http://www.scielo.br/scielo.php?pid=S1413-81232017000200653&script=sci_abstract&tlng=pt>; acesso em 22 out 2019.

- DONEDA, Danilo; SCHERTEL MENDES, Laura. *Marco jurídico para a cidadania digital: uma análise do projeto de lei 5.276/2016*. Revista de Direito Civil Contemporâneo, vol. 9, p.35-48, out-dez 2016.
- DONEDA, Danilo; ALMEIDA, Virgílio A.F. . *What Is Algorithm Governance?*. IEEE Internet Computing, v. 20, p. 60-63, 2016.
- DUMBILL, Edd. *What Is Big Data?: An Introduction to the Big Data Landscape*, O'Reilly, 2012. Disponível em:< <https://www.oreilly.com/ideas/what-is-big-data>>; acesso em 21 jul 2019.
- DWORKIN, Ronald. *Sovereign Virtue. The Theory and Practice of Equality*. London, England: Harvard University Press, 2002.
- ELSEVIER. *Gender in the Global Research Landscape*. Analysis of research performance through a gender lens across 20 years, 12 geographies and 27 subject areas, 2017. Disponível em: <https://www.elsevier.com/data/assets/pdf_file/0008/265661/ElsevierGenderReport_final_for-web.pdf>; acesso em 22 out 2019.
- EU - Europe Union. *Ethics guidelines for trustworthy AI*. 2019. Disponível em: <<https://ec.europa.eu/digital-single-market/en/news/ethics-guidelines-trustworthy-ai>>; acesso em 22 out 2019.
- FINN, Ed. *What Algorithms Want*. Imagination in the age of Computing. Cambridge: MIT Press, 2017.
- FLORES, Paulo. *O que a Cambridge Analytica, que ajudou a eleger Trump, quer fazer no Brasil*. Empresa de marketing que atuou na eleição americana de 2016 direciona propaganda de acordo com a personalidade dos eleitores, 2017. Disponível em:< <https://www.nexojornal.com.br/expresso/2017/12/08/O-que-a-Cambridge-Analytica-que-ajudou-a-eleger-Trump-quer-fazer-no-Brasil>>; acesso em 22 out 2019.
- FELDMAN, Michael et al. *Certifying and Removing Disparate Impact*. In: Proceedings of International Conference on Knowledge Discovery and Data Mining, 2014.
- FUSTER, Gloria González. *The Emergence of Personal Data Protection as a Fundamental Right of the EU*. Law, Governance and Techonolgy Series, v. 16, Springer International Publishing Switzerland: Belgica, 2014.
- FRAZÃO, Ana. Big Data, Plataformas Digitais e Principais Impactos sobre o Direito da Concorrência. In: FRAZÃO, Ana; CARVALHO, Angelo Gamba Prata de. *Empresa, Mercado e Tecnologia*. Belo Horizonte: Fórum, 2019, p. 182.
- FRAZÃO, Ana; OLIVA, Milena Donato; ABILIO, Vivianne da Silveira. Compliance de dados pessoais. In: FRAZÃO, Ana; TEPEDINO, Gustavo; OLIVA, Milena Donato (coord.). *A Lei Geral de Proteção de Dados Pessoais e Suas Repercussões no Direito Brasileiro*. Revista dos Tribunais: São Paulo, 2019.
- FRAZÃO, Ana. Fundamentos da Proteção dos Dados Pessoais. In: In: FRAZÃO, Ana; TEPEDINO, Gustavo; OLIVA, Milena Donato (Org.). *A Lei Geral de Proteção de Dados Pessoais e Suas Repercussões no Direito Brasileiro*. Revista dos Tribunais: São Paulo, 2019.
- FRAZÃO, Ana; PRATA DE CARVALHO, Ângelo. Responsabilidade Social Empresarial, in FRAZÃO, Ana, *Constituição, Empresa e Mercado* (org.), Brasília, 2017.
- FRIEDMAN, Batya; NISSENBAUM, Helen. *Bias in Computer Systems*. ACM Transactions on Information Systems, v. 14, n. 3, 1996.
- GANDRA, Alana. IBGE: Mulheres ganham menos que homens mesmo sendo maioria com ensino superior. Agência EBC Brasi. Disponível em: <<http://agenciabrasil.ebc.com.br/geral/noticia/2018-03/ibge-mulheres-ganham-menos-que-homens-mesmo-sendo-maioria-com-ensino-superior>>. Acesso: 20, out, 2019.

- GILIS, Talia B.; SPIESS, Jann L. *Big Data and discrimination*. The Harvard John M. Olin Fellow's Discussion Paper Series, n. 84, 2019.
- GOETTENAUER, Carlos Eduardo. Algoritmos, Inteligência Artificial, Mercados. Desafios ao arcabouço jurídico. In: FRAZÃO, Ana; CARVALHO, Angelo Gamba Prata de. *Empresa, Mercado e Tecnologia*. Belo Horizonte: Fórum, 2019.
- GOLDSMITH, Jack; WU, Tim. *Who Controls the Internet? Illusions of Borderless World*. Oxford University Press, 2006.
- HELMS, Shawn. *Translating privacy values with technology*, 2001.
- HSIA, David C.. *Credit Scoring and the Equal Credit Opportunity Act*. Hastings Law Journal, 1978.
- HU, Margaret, *Big Data Blacklisting*, Florida: Florida Law Review, 2015, v. 67.
- HURLEY, Mikella; ADEBAYO, Julios. *Credit Scoring in the Era of Big Data*. Yale Journal of Law and Technology, 2016, v. 148.
- IBGE - Instituto Brasileiro de Geografia Estatística. *Estatísticas de gênero. Indicadores sociais das mulheres no Brasil*, 2018. Disponível em: <https://biblioteca.ibge.gov.br/visualizacao/livros/liv101551_informativo.pdf>; acesso em 22 ago 2019.
- JOHNSON, David R.; POST, David. *Law and Borders*. The rise of Law in Cyberspace. In: Stanford Law Review, v. 48, 1996.
- KAHNEMAN, Daniel. *Thinking, Fast and slow*. Ferrar, Straus & Giroux, 2011.
- KASI, Balsy; DUGGER, John C. *Gender Equality in Industrial Technology: The Challenge and Recommendations*. The Official Electronic Publication of the National Association of Industrial Technology, 2000.
- KLEINBERG, Jon; et. al. *Discrimination in the age of algorithms*, 2019.
- KLEINBERG, Jon, et. al.. *Algorithmic Fairness*. AEA Papers and proceedings, v. 108, 2018.
- KIRK, Mary. *Gender and Information Technology*. Moving beyond access to co-create global partnership. New York: Information Science Reference, 2009, p. 113.
- KONDER, Carlos Nelson. O tratamento de dados sensíveis à luz da Lei 13.709/2018. In: FRAZÃO, Ana; TEPEDINO, Gustavo; OLIVA, Milena Donato (Org.). *A Lei Geral de Proteção de Dados Pessoais e Suas Repercussões no Direito Brasileiro*. Revista dos Tribunais: São Paulo, 2019.
- LERMAN, Jonas. *Big data and Its Exclusions*. Stanford Law Review, v. 66, 2013.
- LESSIG, Lawrence. *The Architecture of Privacy*, 1998.
- LESSIG, Lawrence. *Code*. Version 2.0. New York: Basic Books, 2009.
- LINDOSO, Maria Cristine. O processo decisório na era do Big Data: como novos mecanismos de processamento de dados através de algoritmos interferem nas tomadas de decisão., p. 373. In: FERNANDES, Ricardo Vieira de Carvalho; CARVALHO, Angelo Gamba Para (Coord.). *Tecnologia jurídica & direito digital: II Congresso Internacional de Direito, Governo e Tecnologia*. Belo Horizonte: Fórum, 2018.
- LEURS, Koen; SHEPHERD, Tamara. Datafication & Discrimination. In: SCHÄFER, Mirko Tobias; ES, Karin Van. *The Datafield Society*. Studying Culture Through Data. Amsterdam University Press, 2017.
- LEVY, Pierre. *Cibercultura*. Editora 34, 2010.
- MAYER-SCHONBERGER, Viktor; CUKIER, Kenneth. *Big data*. Como extrair volume, variedade, velocidade e valor da avalanche de informação cotidiana. 1. ed., Rio de Janeiro: Elsevier, 2013.
- MAYER-SCHÖNBERGER, V. and CUKIER, K. *The Rise of Big Data: How It's Changing the Way We Think*. Foreign Affairs, vol. 92, no. 3, May/June, 2013.

- MAGRANI, Eduardo. *Entre dados e robôs. Ética e privacidade na era da hiperconectividade*. Porto Alegre: Arquipélago Editorial, 2019.
- MARINHO, Julia. *Google muda algoritmo para que 'lésbica' não seja mais sinônimo de 'pornô'*, 2019. Disponível em: <<https://www.tecmundo.com.br/internet/144805-google-muda-algoritmo-lesbica-nao-seja-sinonimo-porno.htm>>; acesso em 22 out 2019.
- MAZZUCATO, Mariana. *Como democratizar a economia digital e evitar o feudalismo digital*. Precisaremos repensar a governança de dados, desenvolver novas instituições e, dada a dinâmica da economia de plataforma, experimentar formas alternativas de propriedade, 2019. Disponível em: <<https://jornalggn.com.br/tecnologia/internet/como-democratizar-a-economia-digital-e-evitar-o-feudalismo-digital-por-mariana-mazzucato/>>; acesso em 22 out 2019.
- MENDES, Laura Schertel. *Privacidade, proteção de dados e defesa do consumidor. Linhas gerais de um novo direito fundamental*. ed. Saraiva, Série IDP, 2014.
- MIGUEL, Luis Felipe; BIROLI, Flávia. *Feminismo e Política: uma introdução*. Boitempo Editorial, 2014.
- MORAES, Tadeu. *Só 14% da Academia Brasileira de Ciências é hoje integrada por mulheres*. Estudo analisou a diversidade de gênero e a regional na instituição brasileira, 2018. Disponível em: <<https://www1.folha.uol.com.br/ciencia/2018/08/so-14-da-academia-brasileira-de-ciencias-e-hoje-integrada-por-mulheres.shtml>>; acesso em 22 ago 2019.
- MULHOLLAND, Caitlin Sampaio. *Dados pessoais sensíveis e a tutela de direitos fundamentais: uma análise à luz da Lei Geral de Proteção de Dados (Lei 13.709/18)*. Revista de direitos e Garantias Fundamentais, Vitória, v. 19, n. 3, set.-dez., 2018.
- MULHOLLAND, Caitlin; FRAJHOF, Isabella Z. Inteligência Artificial e a Lei Geral de Proteção de dados pessoais: Breves anotações sobre o direito à explicação perante a tomada de decisões por meio de *machine learning*, p. 269. In: FRAZÃO, Ana; MULHOLLAND, Caitlin (coord.). *Inteligência Artificial e direito: ética, regulação e responsabilidade*. São Paulo: Thomson Reuters, 2019.
- MULLER, Léo. *Tay: Twitter conseguiu corromper a IA da Microsoft em menos de 24 horas*, 2016. Disponível em: <<https://www.tecmundo.com.br/inteligencia-artificial/102782-tay-twitter-conseguiu-corromper-ia-microsoft-24-horas.htm>>; acesso em 22 ago 2019 .
- NAKAMURA, Lisa. *Gender and Race Online*. In: GRAHAN, Mark; DUTTON, William H. *Society and the Internet: How Networks of information and Communication are Changing Our Lives*. Oxford Scholarship Online, 2014.
- NISSENBAUM, Helen. *Ethics*. In NISSENBAUM, Helen, *Information Technology and Ethics*, Berkshire Encyclopedia of Human-Computer Interaction, BerkShire Publishing Group, 2004.
- NOBLE, Sofiya Umoja. *Algorithms of Oppression. How Search Engines Reinforce Racism*. New York University Press, 2018.
- OECD *Exploring the Economics of Personal Data*. Paris: OECD Publishing, 2013, p. 12. Disponível em: <<https://doi.org/10.1787/5k486qtxldmq-en>>, acesso em 21 ago 2019.
- OECD. *OECD Principles on AI*, 2019. Disponível em: <<https://www.oecd.org/going-digital/ai/principles/>>; acesso em 22 out 2019.
- O'NEIL, Cathy. *Weapons of math destruction. How big data increases inequality and threatens democracy*. New York: Crown Publishers, 2016.
- O'NEIL, Cathy. *Before the Office of the Assistant Secretary For Fair Housing and Equal Opportunity, HUD*. Comment regarding Docket No. FR 6111-P-02, 2019.
- ONU. *"Universal Declaration of Human Rights"*, 1948. Disponível em: <<http://www.un.org/en/universal-declaration-human-rights/>>, acesso em 22 out 2019.

- PASQUALE, Frank. *The Black Box Society: The Secret Algorithms That Control Money and Information*, Harvard University Press, 2015.
- PASQUALE, Frank. *Restoring transparency to automated authority*. Telecommunications and High Technology Law, v. 9, No. 235, 2011.
- PASQUALE, Frank. "Beyond Innovation and Competition: The Need for Qualified Transparency in Internet Intermediaries," 104 Northwestern University Law Review 105, 2010.
- PATEMAN, Carole. *The Sexual Contract*. Stanford University Press, 1988.
- PARADELLA, Rodrigo. *Diferença cai em sete anos, mas mulheres ainda ganham 20,5% menos que homes*. Agência IBGE Notícias, 2019. Disponível em: <<https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-de-noticias/noticias/23924-diferenca-cai-em-sete-anos-mas-mulheres-ainda-ganham-20-5-menos-que-homens>>; acesso 22 ago 2019.
- PERET, Eduardo. *Mulher estuda mais, trabalha mais e ganha menos do que o home*. Agência IBGE Notícias, 2018. Disponível em: <<https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-de-noticias/noticias/20234-mulher-estuda-mais-trabalha-mais-e-ganha-menos-do-que-o-homem>>; acesso em 22 ago 2019.
- PEREZ, Caroline Criado. *Invisible Women: Data bias in a world designed for men*. Abramns Press, 2019.
- RACANICCI, Jamile. *Judiciário desenvolve tecnologia de voto assistido por máquinas*. Justiça do Trabalho e CNJ trabalham em ferramentas de inteligência artificial, 2018. Disponível em: <https://www.jota.info/paywall?redirect_to=//www.jota.info/justica/judiciario-desenvolve-tecnologia-de-voto-assistido-por-maquinas-05012018>; acesso em 22 out 2019.
- RAWLS, John. *A Theory of Justice*. United States: Beklnap, 1971.
- REDDIX-SMALLS; Brenda. *Credit Scoring and Trade Secrecy: Na Algorithmic Quagmire of How the Lack of Transparency in Complex Financial Models Scuttled the Finance Market*. UC Davis Business Law Journal, 2011, v. 12.
- REIDENBERG, Joel. *Lex informatica*. The formulation of policy rules through technology, 1998.
- RICHARDS, Neil M.; KING, Jonathan H. *Big Data Ethics*. Wake Forest Law Review, No. 393, 2014.
- RIOS, Roger Raupp; SILVA, Rodrigo da. *Democracia e Direito da Antidiscriminação: interseccionalidade e discriminação múltipla no direito brasileiro*. Revista de Ciência e Cultura, São Paulo, v. 69, n. 1, p. 44-46, 2017.
- RIJMENAM, Mark Van. *A short story of Big Data*, 2018. Disponível: <<https://datafloq.com/read/big-data-history/239>> acesso em 22 out 2019.
- RODOTÀ, Stefano. *A vida na sociedade de vigilância: privacidade hoje*. Rio de Janeiro: Renovar, 2008.
- ROMEI, Andrea; RUGGIERI, Salvatore. *Discrimination Data Analysis: A multi-disciplinary Bibliography*. In: CUSTERS, Bart et al. (Org.). *Discrimination and Privacy in the Information Society*. Data Mining and Profiling in Large Databases. Springer: 2013.
- ROSS, Alec. *Industries of the Future*. New York: Simon & Shuster, 2016.
- SANDVIG, Christian, et al.. *Auditing algorithms: Research Methods for Detecting Discrimination on Internet Platforms*. Paper presented to "Data and Discrimination: Converting Critical Concerns into Productive Inquiry," a preconference at the 64th Annual Meeting of the International Communication Association. May 22, 2014; Seattle, WA, USA.

- SCHROEDER, Ralph. *Social Theory After the Internet*. Media, Technology and Globalization. UCL Press, 2018.
- SCHWAB, Klaus. *A quarta revolução industrial*. São Paulo: Edipro, 2016.
- SCHWARTZ, Paul M.; SOLOVE, Daniel J., *The PII Problem: Privacy and a new personally identifiable information*. N.Y.U L. Rev., 86^aed., 2011.
- SEN, Amartia. *The ideia of justice*. Belknap Press, 2011.
- SILVA, Selena; KENNEY, Martin. *Algorithms, Platforms and Ethnic Bias: An Integrative Essay*. Clark Atlanta University: Phylon, v. 55, 2018.
- STJ. Recurso Especial 1.660.168/RJ. Relatora: Min. Nancy Andrighi, 2018. Disponível em: < <https://stj.jusbrasil.com.br/jurisprudencia/595923405/recurso-especial-resp-1660168-rj-2014-0291777-1/inteiro-teor-595923409?ref=juris-tabs>>; acesso 22 out 2019.
- STF. Ação Direta de Inconstitucionalidade 5.617/DF. Relator: Min. Edson Fachin, 2018. Disponível em: <<http://portal.stf.jus.br/processos/downloadPeca.asp?id=15338766077&ext=.pdf>>; acesso 22 out 2019.
- STUCKE, Maurice E.; GRUNES, Allen P. *Big Data and Copetition Policy*. Oxford University Press, 2016.
- STRIPHAS, Ted. Algorithmic culture. In: *European Journal of Cultural Studies*, 2015, vol. 18.
- SWEENEY, Latanya. *Discrimination in Online Ad Delibery*. Harvard University, 2013.
- TEPEDINO, Gustavo. A Tutela da Personalidade no Ordenamento Civil-constitucional Brasileiro. Temas de Direito Civil, 3a ed., Renovar, 2004.
- TURING, Alan M.. *Computing Machinery and Intelligence*, 1950.
- TURROW, Joseph. *Niche Envy*. Marketing Discrimination in the Digital Age. Cambridge: The MIT Press, 2006.
- VERONESE, Alexandre. Os direitos de explicação e de oposição frente às decisões totalmente automatizadas: comparando a RGPD da União Europeia com a LGPD Brasileira, p. 406. In: FRAZÃO, Ana; TEPEDINO, Gustavo; OLIVA, Milena Donato (coord.). *A Lei Geral de Proteção de Dados Pessoais e Suas Repercussões no Direito Brasileiro*. Revista dos Tribunais: São Paulo, 2019.
- VIOLA, Mario; DONEDA, Danilo; ANDRADE, Norberto N. G. de. Dados anônimos e tratamento de dados para finalidades distintas: a proteção de dados pessoais sob uma ótica civil-constitucional. In: TEPEDINO, Gustavo; FACHIN, Luiz E. (Org.). *Pensamento crítico do direito civil brasileiro*. Curitiba: Juruá, 2011.
- VOGUEL, David. *The Market for virtue: the potential and limits of corporate social responsibility*. Brookings Institution Press, 2015.
- WARREN, Samuel D.; BRANDEIS, Louis D. *The right to privacy*. Harvard Law Review, vol. 4, No 5, 1890.
- WILLIAMS, Betsy Anne; BROOKS, Catherine F.; SHMARGAD, Yotam. *How Algorithms Discriminate Based on Data They Lack: Challenges, Solutions and Policy Implications.*, Journal of Information Policy, vol. 8, 2019.
- ZIEGLER, Maria Fernanda. *Assegurar inclusão de mulheres melhora a qualidade da ciência*, 2018. Disponível em: <<http://agencia.fapesp.br/assegurar-inclusao-de-mulheres-melhora-a-qualidade-da-ciencia/28381/>>; acesso em 22 out 2019.
- ŽLIOBAITE, Indre; CUSTERS, Bart. *Using sensitive personal data may be necessary for avoiding discrimination in data-driven decision models*. Springer Science + Business Media Dordrecht, 2016, p. 193.
- ZUBOFF, Shoshana. *The age of surveillance capitalism. The fight for a human future at the new frontier of power*. New York: Public Affairs, 2019.

____. *Estatística de gênero: responsabilidade por afazeres afeta inserção das mulheres no mercado de trabalho*. Agência IBGE Notícias, 2018. Disponível em: <<https://agenciadenoticias.ibge.gov.br/agencia-sala-de-imprensa/2013-agencia-de-noticias/releases/20232-estatisticas-de-genero-responsabilidade-por-afazeres-afeta-insercao-das-mulheres-no-mercado-de-trabalho>>; acesso em 22 ago 2019.

____, *Relatório Final Quantitativo*. Pesquisa Eles por Elas, 2016. Disponível em: <http://www.onumulheres.org.br/wp-content/uploads/2018/04/Relatorio_ONU_ElesporElas_PesquisaQuantitativa2016.pdf>; acesso em 22 ago 2019.

____, *Caminhada espacial feminina é cancelada por falta de trajes adequados*. Segundo comunicado da NASA, não há roupas espaciais suficientes para todas as mulheres astronautas na Estação Espacial Internacional, 2019. Disponível em: <<https://revistagalileu.globo.com/Ciencia/Espaco/noticia/2019/03/caminhada-espacial-feminina-e-cancelada-por-falta-de-trajes-adequados.html>>; acesso em 22 out 2019.

____. *STF terá programa de inteligência artificial para tramitação de processo*, 2018. Disponível em: <<https://www.conjur.com.br/2018-jun-01/stf-programa-inteligencia-artificial-processos>>; acesso em 22 out 2019.

____, G20 Ministerial Statement on Trade and Digital Economy. Japan, 2019. Disponível em: <<https://www.mofa.go.jp/files/000486596.pdf>> . Acesso em 20, out., 2019.

AVILA, Renata, *et al.*. *Artificial Intelligence: Open Questions about Gender Inclusion*. In: policy Brief w20, Argentina, 2018.