

FACULDADE DE TECNOLOGIA DE SÃO PAULO

LUCIANE CRISTINA NAGAY MARTINS

Vieses algorítmicos de gênero: melhores práticas para redução de danos às mulheres na tomada de decisão automatizada.

SÃO PAULO

2022

FACULDADE DE TECNOLOGIA DE SÃO PAULO

LUCIANE CRISTINA NAGAY MARTINS

Vieses algorítmicos de gênero: melhores práticas para redução de danos às mulheres na tomada de decisão automatizada.

Trabalho submetido como exigência parcial para a
obtenção do Grau de Tecnólogo em Análise e
Desenvolvimento de Sistemas.

Orientadora: Profa. Me. Grace Anne Pontes Borges

SÃO PAULO

2022

FACULDADE DE TECNOLOGIA DE SÃO PAULO

LUCIANE CRISTINA NAGAY MARTINS

Vieses algorítmicos de gênero: melhores práticas para redução de danos às mulheres na tomada de decisão automatizada.

Trabalho submetido como exigência parcial para a obtenção do Grau de Tecnólogo em Análise e Desenvolvimento de Sistemas.

Parecer da Professora Orientadora

Conceito/Nota Final: _____

Atesto o conteúdo contido na postagem do ambiente TEAMS pela aluna e assinada por mim para avaliação do TCC.

Orientadora: Orientadora: Profa. Me. Grace Anne Pontes Borges

SÃO PAULO, 27 de junho de 2022.

Assinatura da Orientadora

Luciane C. N. Martins

Assinatura da aluna

“Nós percebemos a importância de
nossas vozes quando somos silenciadas.”

Malala Yousafzai

RESUMO

Este trabalho abordou como os algoritmos estão longe de serem estruturas neutras, mas ao contrário estão carregadas de vieses que prejudicam as mulheres e são resultados tanto da base de dados utilizados pelos algoritmos quanto pelas vivências e crenças de programadores que desenham esses algoritmos. Ao longo do trabalho, vimos como os algoritmos e os bancos de dados são formulados e utilizados. E como, se não houver nenhuma interferência, irão perpetuar a situação discriminatória vivida pelas mulheres ao longo dos tempos. Concluimos que as empresas de tecnologia têm sim o poder de mudar este cenário com algumas práticas que podem ser aplicadas para aumentar a equidade de gênero nas decisões automatizadas feitas pelos algoritmos.

Palavras-chave: Algoritmos. Mulheres. Vieses.

ABSTRACT

This paper addressed how algorithms are far from being neutral structures, but on the contrary, they are loaded with biases that harm women and are the result of both the database used by the algorithms and the experiences and beliefs of programmers who design these algorithms. Throughout the work, we could see how algorithms and databases are formulated and used. And if we do not interfere, it will perpetuate the discriminatory situation experienced by women over the times. We conclude that all companies do have the power to change this scenario with some practices that can be applied to increase gender equity in the automated decisions made by algorithms.

Keywords: Women, bias, algorithms.

LISTAS DE FIGURAS

Figura 1 - Os 5 V's da *big data* e suas associações

15

SUMÁRIO

1. INTRODUÇÃO	9
1.1. Problema	10
1.2. Hipóteses	10
1.3. Objetivos	11
1.4. Justificativa	11
1.5. Metodologia de pesquisa	12
2. ALGORITMOS E DADOS	13
2.1. Algoritmos	13
2.2. <i>Big Data</i> e coleta de dados	14
2.3. Mineração de dados	19
2.4. Dados pessoais	21
3. DESIGUALDADE DE GÊNERO	29
3.1. Gênero	29
3.2. Tecnologia e mulheres	30
4. VIESES DE GÊNERO NO TRATAMENTO DE DADOS	34
4.1. Dados e base de dados	35
4.2. Estruturação dos algoritmos e mineração de dados	38
5. POSSÍVEIS SOLUÇÕES PARA A DIMINUIÇÃO DE VIESES NOS ALGORITMOS	41
5.1. Dados e base de dados	43
5.2. Estruturação dos algoritmos e mineração de dados	45
6. CONCLUSÃO	48
7. REFERÊNCIAS	51

1. INTRODUÇÃO

Os setores público e privado estão cada vez mais utilizando sistemas de Inteligência Artificial (IA) e algoritmos de *machine learning* para automatizar processos simples e complexos de tomada de decisão (CHODOSH, 2018; KEARNS, 2021). A digitalização de dados em grande escala e as tecnologias emergentes que os utilizam estão afetando a maioria dos setores econômicos, incluindo seleção de candidatos para vagas de emprego, direcionamento de anúncios, abertura de crédito e apólices de seguro, monitoramento policial, dentre tantos outros exemplos. Elas são, na verdade, estudos estatísticos primorosos, feitos por fórmulas matemáticas, com objetivo de prever 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 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. Nestes estudos foram analisados 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 (LINDOSO, 2021).

As mulheres já vivem em situação desigual, porém o espanto ocorre por causa da difusão de percepção de que esses programas, 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 seriam neutras agora é questionada, e poucas pessoas têm o conhecimento adequado para apurar se os resultados produzidos estão corretos (LINDOSO, 2021).

1.1. Problema

Hoje existe uma falta generalizada de dados de gênero, de modo que nem mesmo a produção científica se preocupa em buscar informações relacionadas exclusivamente às mulheres. A inexistência de mulheres nesses espaços de produção de conhecimento fez com que fosse adotado, de forma indiscriminada, um padrão universal masculino, o que teria causado um total desconhecimento das realidades e especificidades das mulheres (PEREZ, 2019).

Se as mulheres não vivem uma realidade de equidade, a ciência e a tecnologia também não poderiam viver. O espaço científico não se modificou até hoje, as mulheres ainda não conseguiram ocupar efetivamente esse campo, e não conseguiram desfazer construções estereotipadas, então as decisões tomadas como fruto da ciência também irão continuar a reproduzir o padrão antigo e discriminatório (LINDOSO, 2021). Assim, podemos verificar que a tecnologia opera colocando a equidade em risco prejudicando as mulheres – além de outros grupos minoritários.

1.2. Hipóteses

Diante do cenário apresentado, levantamos as seguintes hipóteses:

- É possível que o aumento da quantidade de mulheres que trabalham na construção desses algoritmos de forma representativa impactem nesses processos, diminuindo as distorções e atingindo melhores resultados em busca da equidade de gênero.
- O uso correto de dados históricos para evitar que uma determinada realidade discriminatória seja reproduzida e até potencializada pelos algoritmos.
- Uma maior transparência acerca do funcionamento das estruturas algorítmicas, junto com a alfabetização algorítmica generalizada dado o aumento do uso de algoritmos em muitos aspectos do dia a dia, todos se beneficiariam do conhecimento de como esses sistemas funcionam.

1.3. Objetivos

Objetivo geral

Pretende-se introduzir a percepção de que as empresas efetivamente possuem o controle sobre os algoritmos e que eles operam a seu favor e em seu benefício. Muitas vezes esses algoritmos são construídos por uma parcela específica da população em seu próprio benefício, em detrimento de outras populações que não tem a mesma representatividade nos setores tecnológicos como, por exemplo, as mulheres.

Objetivo específico

Apresentar um conjunto de recomendações de práticas que promovem a implantação justa e ética de IA e tecnologias de aprendizado de máquina para redução de danos às mulheres na tomada de decisão automatizada.

1.4. Justificativa

No mundo pré-algoritmo, os humanos e as organizações costumavam tomar decisões sobre contratações, publicidade, condenações criminais e empréstimos. Essas decisões geralmente eram regidas por leis federais, estaduais e locais que regulamentavam os processos de tomada de decisão em termos de justiça, transparência e equidade. Hoje, algumas dessas decisões são inteiramente tomadas ou influenciadas por máquinas cuja escala e rigor estatístico prometem eficiências sem precedentes. Os algoritmos estão aproveitando volumes de macro e micro dados para influenciar as decisões que afetam as pessoas em uma variedade de tarefas, desde fazer recomendações de filmes até ajudar os bancos a determinar a qualidade de crédito dos indivíduos. No aprendizado de máquina, os algoritmos contam com vários conjuntos de dados, ou dados de treinamento, que especificam quais os *outputs*, ou resultados, corretos para algumas pessoas ou objetos. A partir desses dados de treinamento, ele aprende um modelo que pode ser aplicado a outras pessoas ou objetos e faz previsões sobre quais devem ser os *outputs* para eles.

No entanto, como as máquinas podem tratar pessoas e objetos em situações semelhantes de maneira diferente, pesquisas revelam alguns exemplos preocupantes nos quais a realidade da tomada de decisão algorítmica fica aquém de nossas expectativas. Diante disso, alguns algoritmos correm o risco de replicar e até mesmo amplificar vieses humanos, particularmente aqueles que afetam minorias (CHODOSH, 2018).

Neste exemplo, a decisão gera "viés", um termo que definimos amplamente no que se refere a resultados que são sistematicamente menos favoráveis para os indivíduos de um determinado grupo e onde não há diferença relevante entre os grupos que justifique tais danos. O enviesamento nos algoritmos pode advir de dados de treinamento não representativos ou incompletos ou informações incorretas que refletem as desigualdades históricas. Se não forem verificados, os algoritmos tendenciosos podem levar a decisões que podem ter um impacto coletivo e díspar em certos grupos de pessoas, mesmo sem a intenção do programador de discriminar. A exploração das consequências pretendidas e não pretendidas dos algoritmos é necessária e oportuna, especialmente porque a legislação atual pode não ser suficiente para identificar, mitigar e remediar os impactos ao consumidor.

Com algoritmos aparecendo em uma variedade de aplicações, as partes interessadas devem ser cuidadosas em abordar proativamente os fatores que contribuem para o viés. Fazer-se notar e responder ao enviesamento algorítmico antecipadamente pode potencialmente evitar impactos prejudiciais aos usuários e responsabilidades pesadas contra os operadores e criadores de algoritmos, incluindo programadores de computador, governo e líderes da indústria.

1.5. Metodologia de pesquisa

Para a revisão bibliográfica, foram usados os sistemas de base de dados do Google Acadêmico sem limite de data. Os artigos foram filtrados com combinações dos termos “vieses”, “algorítmicos”, “gênero” e “mulheres” em português e inglês, além de livros sobre o assunto.

2. ALGORITMOS E DADOS

Neste capítulo pretende-se introduzir alguns conceitos como Algoritmos, *Big Data* e Mineração de dados para posterior análise em relação a vieses de gênero.

2.1. Algoritmos

Um algoritmo é qualquer procedimento computacional bem definido que toma algum valor ou conjunto de valores como *entrada* e produz algum valor ou conjunto de valores como *saída*. Ou seja, uma sequência de etapas computacionais que transformam a *entrada* em *saída* (CORMEN, 2021).

Também podem ser vistos como ferramentas para resolver problemas computacionais específicos. A declaração do problema determina a relação desejada entre a entrada e a saída. O algoritmo descreve um procedimento computacional específico para se conseguir atingir essa relação (CORMEN, 2021).

Um algoritmo é dito correto se ele retorna a *saída* correta para cada instância da *entrada*. Ele pode ser especificado em linguagem comum como um programa de computador ou mesmo como um projeto de hardware. O único requisito é que a especificação deve fornecer uma descrição precisa do procedimento computacional a ser seguido (CORMEN, 2021).

Como o próprio autor diz, os algoritmos são as estruturas matemáticas que permitem organizar a automação de processos e possibilitar a análise de dados, para que sejam feitas previsões e, conseqüentemente, decisões sejam tomadas de forma automatizada.

O funcionamento desses algoritmos se dá através da leitura matemática da repetição (O'NEIL, 2021), analisando informações previamente inseridas que permitem a identificação de um comportamento em comum a todos os dados analisados com base em um modelo previamente estruturado pelo ser humano por trás da fórmula matemática e que deverá ser seguido (BAROCAS, 2016). Esse modelo é justamente o reflexo de intenções e desejos humanos, sendo muitas vezes também, a ponte para vieses e direcionamento no tratamento de

dados, já que ele será observado para que o processamento do conteúdo possa gerar resultados semelhantes a ele (LINDOSO, 2021).

Existem vários tipos de algoritmos distintos, a exemplo dos preditivos, que objetivam antecipar fatos futuros com base na análise de dados históricos, ou dos algoritmos de otimização, que se prestam a reduzir os custos de transação e produção de determinada atividade econômica (GOETTENAUER, 2019).

Entendendo que o algoritmo é uma estrutura matemática, é preciso ensiná-lo a analisar os modelos e a identificar quais são os padrões que se pretende mapear. Na maior parte das vezes, isso é feito pelos próprios programadores através de um processo de aprendizagem de espelhamento de informações onde dois algoritmos distintos trabalham em conjunto para selecionar um resultado esperado dentre tantos possíveis para atender a uma finalidade específica (KLEINBERG, 2019). Outra forma de aprendizagem do algoritmo é através da leitura de modelos previamente desenhados por um ser humano (BAROCAS, 2016), quando um programador insere os conteúdos e ensina quais são os resultados esperados (LINDOSO, 2021).

A tomada de decisões automáticas viabilizada pelos algoritmos e pela inteligência artificial tem influenciado o cotidiano de toda a população em razão da velocidade que permitiu que as predições estatísticas ganhassem 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 de um ser humano comum (LINDOSO, 2021).

2.2. *Big Data* e coleta de dados

Big data é um termo utilizado para definir gigantescos conjuntos de dados com estruturas variadas e complexas grandes demais para serem analisados por sistemas tradicionais.

O processo de pesquisa em grandes quantidades de dados para revelar padrões e correlações são úteis para empresas ou organizações para obter percepções profundas e vantagens sobre a concorrência. (SAGIROGLU, 2013)

Big data permite reunir diversos conteúdos variados em um único sistema. Seu diferencial reside, justamente, na sua capacidade de ser tratado de forma célere e menos custosa (DUMBILL, 2012).

O seu surgimento é decorrência do aprimoramento da capacidade humana de coleta de dados. 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. (LINDOSO, 2021)

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 (MAYER-SCHONBERGER, 2013).

Desde então, empresas pioneiras dedicaram parte do desenvolvimento tecnológico para criação de mecanismos de leitura de dados de forma mais rápida para que pudessem ser feitas automatizações, e conseqüentemente mais dados estavam sendo produzidos e poderiam ser analisados por essas empresas que consolidaram seus monopólios em coleta e tratamento de dados pessoais através da *big data*.

Estudos acerca da *big data*, o caracterizam pelos seus “5Vs”:

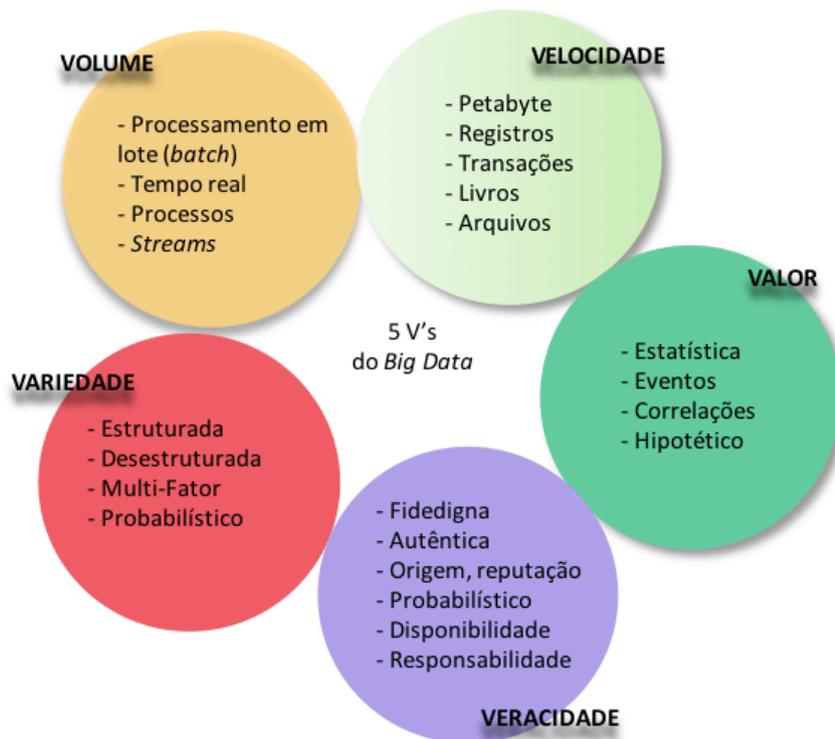


Figura 01 - Os 5 V's da *big data* e suas associações (SANTOS-D'AMORIM et al, 2020)

Volume: apresenta o desafio mais imediato às estruturas convencionais de processamento de dados, diz respeito à densidade dos dados, e sua importância está associada justamente ao grande crescimento de conteúdo processável atualmente. O benefício obtido com a capacidade de processar grandes quantidades de informações é o principal atrativo da análise de *big data* (ANURADHA, 2015).

Velocidade: refere-se à velocidade crescente na qual esses dados são criados, ou seja, a velocidade crescente na qual os dados podem ser processados, armazenados e analisados por bancos de dados relacionais. A velocidade refere-se à velocidade com que novos dados são gerados e a velocidade com que os dados se movem (ANURADHA, 2015). 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 esperados (RICHARDS, 2014,). 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 (LINDOSO, 2021).

Variedade: em *Big Data* nem sempre são dados estruturados e nem sempre é fácil colocar *big data* em um banco de dados relacional. Isso significa que a categoria à qual o *Big Data* pertence também é um fato muito essencial que precisa ser conhecido pelos analistas de dados. 90% dos dados gerados são dados não estruturados (ANURADHA, 2015). A variedade também diz respeito à quantidade de conteúdos distintos que podem ser reunidos de uma só vez. Essa característica da *big data* fez perceber que os agentes também desenvolveram melhores capacidades de coleta de dados diversos dos indivíduos (STUCKE, 2016), 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, que diz respeito a esse processo de transformar as interações em dados e que culminou na migração dos relacionamentos para a realidade virtual (MAYER-SCHÖNBERGER, 2013). A variedade permitiu que um único dado agregasse nele próprio diversas informações distintas, promovendo maior conhecimento em relação à realidade e aos desejos de cada um.

Veracidade: Um em cada 3 líderes não confiam nos dados que recebem. Para colher bons frutos do processo do *Big Data* é necessário obter dados verídicos, de acordo com a realidade. O conceito de velocidade, já descrito, é bem alinhado ao conceito de veracidade pela necessidade constante de análise em tempo real, isso significa, de dados que condizem com a realidade daquele momento, pois dados passados não podem ser considerados dados verídicos para o momento em que é analisado. A relevância dos dados coletados é tão importante quanto o primeiro conceito. A verificação dos dados coletados para adequação e relevância ao propósito da análise é um ponto chave para se obter dados que agreguem valor ao processo (HURWITZ, 2013).

Valor: é muito bom ter acesso a *big data*, mas, a menos que possamos transformá-lo em valor, ele se tornará inútil. A potencialidade oferecida pela *big data*, de variedade, volume e velocidade, aliados ao propósito de tomar uma decisão, fez com que os dados pessoais fossem valorizados. A própria capacidade de a *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 imediata (ROSS, 2016).

A partir das características mencionadas, é possível perceber que a *big data* deu ao mercado novas possibilidades de atuação, ao 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 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 (LINDOSO, 2021).

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 partir da criação de um perfil do usuário, através dos dados que ele próprio forneceu – às vezes de forma inconsciente ou desautorizada - é possível criar quaisquer tipos de previsões que impactam diretamente a vida desses usuários. 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. (ROSS, 2016).

Destaca-se que esse potencial da *big data* não beneficiou apenas as empresas, mas também o consumidor, já que o desenvolvimento de um comércio especializado, focado nos interesses pessoais de cada um, possibilita

direcionar a ele somente produtos que poderiam ter a chance de adquirir (OECD, 2013).

A grande discussão a esse respeito, segundo Lindoso, 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?

É difícil determinar se o cálculo probabilístico feito pela *big data* diz respeito ao que o usuário quer, ou ao que ele tem mais chances de consumir (TURROW, 2006).

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 usuários (ZUBOFF, 2019).

Os próprios impactos sociais que a *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 utilizados como instrumentos de manipulação. (SCHROEDER, 2018). A discriminação de gênero é apenas uma dentre várias outras preocupações vindas desta realidade.

2.3. Mineração de dados

Mineração de Dados é a análise de grandes conjuntos de dados (*big data*) a fim de encontrar relacionamentos inesperados e de resumir os dados de uma

forma que eles sejam tão úteis quanto compreensíveis ao dono dos dados (HAND et al, 2001).

Analisando-se seu funcionamento, é possível perceber que, em sua essência, essa tecnologia pressupõe um tipo de discriminação estatística: são matematicamente selecionados os padrões mais semelhantes e esses são agrupados em perfis que conseguem prever seus interesses comuns. Com isso, é possível retratar, para dentro de uma base de dados, um cenário similar ao da realidade (BAROCAS, 2016).

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 mineração de dados. E 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 estudo. Já na mineração de dados, a coleta de dados é feita de forma indiscriminada, sem critérios em relação à fonte da coleta ou à forma de armazenamento do conteúdo (CALDERS, 2013)

Ainda em relação à mineração de dados, percebe-se que ele, juntamente com a *big data*, e através dos algoritmos que possibilitam as predições, 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 humana (CHRISTIN, 2015). 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 (LINDOSO, 2021).

Além disso, o uso desse tipo de tecnologia assegurou diversos avanços na desburocratização de tomada de decisões. Com o uso de algoritmos e da *big*

data, a mineração de dados permitiu que fossem construídos padrões preditivos aptos a decidirem questões relevantes, diminuindo custos para fazê-lo, possibilitando a sistematização da orientação 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 (LINDOSO, 2021).

De fato, a tomada de decisão humana possui diversos elementos incontroláveis de natureza subconsciente, muitas vezes dotados de vieses e subjetividades. 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 decisão. Por isso, os programas que se utilizam de mineração de dados se tornaram saídas que afastam a subjetividade e tentam trazer racionalidade ao processo decisório (KAHNEMAN, 2011).

Ocorre que, nessa análise estatística, há certa falta de transparência, 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. Percebe-se, ao fim, que todas as definições também estão interligadas. As tecnologias preditivas são apenas um fruto de intenso aprimoramento da análise massiva de dados e de construção de perfis dos usuários através de máquinas (LINDOSO, 2021).

2.4. 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 específica (MENDES, 2014).

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 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 traduzir 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 exemplos (AFFELT, 2013). 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 (LINDOSO, 2021).

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 que sua natureza é a de bem jurídico, uma vez que são objetos de transações e de negócios jurídicos firmados na rede (LESSIG, 1998). 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 indivíduo (TEPEDIO, 2014). 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 restrita 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 (LINDOSO, 2021).

Essa segunda perspectiva também culminou em discussões que criaram um novo direito fundamental, qual seja o direito à proteção de dados pessoais (FUSTER, 2014). 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, 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” (ALMEIDA, 2012), motivo pelo qual a própria definição de privacidade vem se renovando dentro do ordenamento jurídico. Antes compreendida como o direito de ser deixado sozinho (WARREN, 1890), a privacidade se torna um direito de controle, de autodeterminação informativa (KONDER, 2018), 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 dados pessoais 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.” (MENDES, 2014).

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 da dignidade da pessoa humana (MULHOLLAND, 2018), e para que eles não sejam interpretados exclusivamente dentro da ótica de mercado (MENDES, 2014).

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 (LGPD) 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 terceiros (RODOTÀ, 2008).

Em relação aos dados pessoais, a LGPD também trouxe outra perspectiva, que diz respeito à vedação do uso de dados como forma de discriminação. Contudo, é relevante considerar que 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” (MULHOLLAND, 2018). Dessa forma, não é vedado utilizar dados pessoais para fins mercadológicos, tampouco tratar de forma diferente os vários usuários na rede.

Os dados pessoais sensíveis foram definidos na LGPD nos seguintes termos o 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 mencionado (MULHOLLAND, 2018). 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 usuário (MULHOLLAND, 2018).

A esse respeito, deve-se destacar que a categorização feita pelo diploma brasileiro não se limita a 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. É importante 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 os 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 taxativo (KONDER, 2019). 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 discriminatório (DONEDA, 2016), 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 legislativa (LINDOSO, 2018).

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. 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 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 equidade 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 gênero (AVILA, 2018).

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 (LINDOSO, 2021).

3. DESIGUALDADE DE GÊNERO

Segundo Laqueur (2001), a ideia/teoria de uma diferença sexual substantiva e binária-oposta (homem/mulher) nem sempre existiu. Desde Aristóteles até o século XVIII houve a predominância da teoria do sexo único. Segundo essa teoria, entre homens e mulheres haveria apenas uma diferença de grau, sendo as mulheres consideradas como homens menores. (ZANELLO, 2018)

Dimen (1997) afirma, nessa direção, que há uma divisão de trabalho nas sociedades patriarcais que “denota uma estrutura de poder político disfarçado em sistema de diferença natural” (Dimen, 1997, p. 46). Segundo a autora, a divisão de trabalho emocional sugere que aos homens é interpelada a individualização e a autonomia, ou a independência; já às mulheres, a ligação e o cuidado, ou seja, a interdependência (ZANELLO, 2018).

Em uma cultura sexista, o tornar-se pessoa é sempre estruturado pelo binarismo do tornar-se homem ou mulher. Como afirmam Kitayama e Park (2007), as tendências pessoais motivacionais são adquiridas mediante anos de socialização, as quais começam muito cedo, desde os primeiros anos de vida, e são, em consequência, automatizadas, performadas e incorporadas. (ZANELLO, 2018)

3.1. Gênero

Foi a psicologia, em sua vertente médica (por intermédio dos trabalhos de Robert Stoller) quem cunhou a palavra “gênero” (Lamas, 1986): tratava-se da construção social do “feminino” e do “masculino”. Desde uma perspectiva psicológica, “gênero” articula três instâncias básicas (ZANELLO, 2018):

- a assinalação (rotulação, atribuição) de gênero;
- a identidade de gênero;
- o papel de gênero.

Nesse sentido, o gênero seria uma divisão sexual imposta aos sexos, a qual transformaria a fêmea em mulher e o macho em homem. Em nossa cultura, essa organização se caracterizaria pela heterossexualidade obrigatória, pelo binarismo e pelas restrições da sexualidade feminina. A autora aponta assim que, longe de ser a expressão de diferenças naturais, a identidade de gênero exclusiva é a supressão de similaridades naturais (ZANELLO, 2018).

Como vimos com Laqueur (2001), não se trata de negar que existam diferenças (pois elas existem aos montes, mesmo entre duas mulheres ou dois homens), mas antes, de apontar como e porque exatamente essas diferenças foram tomadas de uma determinada forma, para justificar espaços sociais de maior ou menor empoderamento. Ou seja, a diferença foi traduzida em oposição e desigualdade. “Gênero” é, portanto, um conceito relacional e implica, sempre, relações de poder, de privilégios, de maior ou menor prestígio. (ZANELLO, 2018)

3.2. Tecnologia e 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. 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 (LINDOSO, 2021).

Percebeu-se que inexistiam estímulos à participação feminina nas áreas das ciências exatas, o que acabava decorrendo de toda uma educação

sexualmente dividida, que deixava de estimular meninas e meninos a 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, deficitária (BRAY, 2007).

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 submissão (KASI, 2000). Também se difundiu que o campo da tecnologia prescindia de instinto, o que não era algo inerente às mulheres, mas sim aos homens (KIRK 2009).

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 feminina nesses espaços não aumentou de forma a impedir que o tratamento desigual continuasse existindo (LINDOSO, 2021).

O descuido em relação ao gênero é tamanho que hoje existe uma falta de dados de gênero, de modo que nem mesmo a produção científica se preocupa em buscar informações relacionadas exclusivamente às mulheres. 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 um total desconhecimento das realidades e especificidades das mulheres. 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 homens (PEREZ, 2019).

Se as mulheres não vivem uma realidade de equidade, a ciência e a tecnologia também não poderiam viver. O espaço científico não se modificou até hoje, as mulheres ainda não conseguiram ocupar efetivamente esse campo, e não conseguiram desfazer construções estereotipadas, então as decisões tomadas como fruto da ciência também irão continuar a reproduzir o padrão antigo e discriminatório (LINDOSO, 2021).

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 possibilitou a solução de problemas de forma simples, através da diferença de perspectiva e de pensamento. A inclusão, contudo, não ocorre em razão da falta de políticas efetivas para que a equidade seja promovida. Falta da atuação positiva dos governos para que possa ocorrer equiparação de oportunidades (LINDOSO, 2021).

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 como 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 discriminatório, 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, também sancionado por um homem. Não é difícil perceber, nesse contexto, porque inexistente preocupação com o gênero feminino (LINDOSO, 2021).

Assim, não é difícil pensar que a tecnologia pode operar em detrimento dos interesses de equidade de mulheres, até porque essa pretensão, muitas vezes, pode nem existir nos espaços essencialmente masculinos onde é

produzido o conhecimento. A discussão sobre democratização da economia digital, nesse sentido, precisa voltar à tona, principalmente sob uma perspectiva de gênero. E isso não só porque as empresas se valem dos seus monopólios no campo tecnológico para manipular comportamentos humanos (ZUBOFF, 2019), mas principalmente porque a equidade está em risco, e as mulheres – além de outros grupos minoritários – estão sendo prejudicadas (MAZZUCATO, 2019).

4. VIESES DE GÊNERO NO TRATAMENTO DE DADOS

O uso dos algoritmos para a tomada de decisões automáticas vem ganhando cada vez mais espaço em diversas esferas do cotidiano e conquistaram grande adesão, principalmente, em decorrência (LINDOSO, 2021):

- da promessa de desburocratização e celeridade com uma redução de custos;
- da possibilidade de sistematização de processos decisórios similares; e
- 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.

A possibilidade de eliminar custos e de padronizar abordagens e resoluções de conflitos representa um ganho inegável das tecnologias preditivas.

Contudo, essa ausência de vieses não corresponde à realidade, existem sólidos estudos e consensos internacionais de que os processos automatizados podem causar a discriminação de minorias. É importante mapear essa possibilidade ao longo de todo processo automatizado, a fim de compreender de que forma a discriminação pode se perpetuar e como seria possível solucionar essa questão.

Em princípio, a discriminação pode ocorrer em duas etapas:

- discriminação de gênero pelos dados e pelas bases de dados (pela falta de representatividade e pela supressão de dados pessoais sensíveis);
- discriminação de gênero por algoritmos (pela estruturação do algoritmo e pelas correlações e inferências estatísticas da mineração de dados).

4.1. Dados e base de dados

A realidade para mulheres ainda não é a mesma realidade dos homens. Levando em conta o campo da tecnologia e das decisões automatizadas, percebe-se que a base de dados utilizada pelos algoritmos reflete realidades sociais atuais ou contextos passados e não necessariamente o que seria justo. O uso dessas informações, ou até a ausência delas, poderia impactar no resultado de tomada de decisão pelo algoritmo. Verifica-se que a discriminação decorre de vieses preexistentes, decorrentes das construções sociais anteriores à criação de desses algoritmos. Assim, os dados carregam informações sociais anteriores que contaminam o processo automatizado com perspectivas potencialmente discriminatórias.

Em seu livro "*Invisible Women*", Caroline Criado Perez aborda a questão de falta de representatividade de dados femininos em diversos aspectos:

- Existe falta de dados sobre mulheres nos mais variados campos de produção de conhecimento, e;
- Há um desconhecimento geral em relação às perspectivas e às realidades exclusivas ao gênero feminino.

Fundamentada por vasto cruzamento de dados científicos divulgados, a adoção de um padrão de gênero universal (o padrão masculino) acabou invisibilizando a realidade das mulheres, causando-lhes prejuízos enormes (PEREZ, 2021):

- 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 postos de liderança são idealizados para características tipicamente masculinas;
- As tecnologias foram desenvolvidas com base no sexo masculino, como tamanho de mão para segurar um celular, ou de olhos, para reconhecimento facial.
- Aparelhos de ar-condicionado das empresas são programados com base na temperatura corpórea média de um homem, que é mais alta que a temperatura feminina, motivo pelo qual, inclusive, a maior parte das mulheres costuma passar frio em seus locais de trabalho.

Com base em todos esses aspectos, podemos perceber a falta de dados e preocupação em relação às mulheres, que também pode ser identificado nos algoritmos que geralmente tomam como entrada esses mesmos dados causando uma enorme falta de representatividade.

Como escreveram Solon Barocas e Andrew Selbst: “o algoritmo é tão bom quanto a base de dados com que ele trabalha”, porque, de fato, os algoritmos estão diretamente relacionados com a qualidade dos dados que foram coletados. Portanto, se não existem dados suficientes sobre as mulheres, dificilmente os algoritmos conseguirão compreender a realidade feminina de forma inclusiva e não discriminatória.

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. Como no caso citado pela MIT Technology Review, em que o LinkedIn encaminharia mais homens do que mulheres para os cargos disponíveis simplesmente porque os homens costumam ser mais agressivos na busca de novas oportunidades.

O impacto negativo da falta de representatividade dos dados é evidente, e gera um distanciamento, por parte do processo automatizado, da equidade de gênero que deve ser perseguida.

Existe uma grande diferença em relação a mineração de dados e os estudos estatísticos. Enquanto um possui preocupações específicas da coleta de dados, onde são produzidos estudos específicos acerca da metodologia de coleta dos dados, porque isso pode impactar o resultado do estudo, o outro se utiliza de todo e qualquer conteúdo armazenado em uma base. Não há, contudo, critério metodológico claro e transparente acerca de como funciona a coleta de dados que serão analisados, até porque, as empresas vêm transformando todo tipo de informação e conteúdo em dado passível de ser analisado por mineração de dados.

Nesse ponto, é importante ressaltar que 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.

Também relacionada à qualidade dos dados utilizados, o processo decisório pode ter potencial discriminatório quando dados descontextualizados para aquela análise específica são utilizados como entradas, permitindo associações que não são necessariamente verdadeiras e transferindo vieses de dados que não guardam relação com o contexto. Essas associações são reproduções de estereótipos, e são especialmente prejudiciais para mulheres.

A discriminação de gênero em processos automatizados, causada pelos dados, também pode ocorrer com a supressão de dados pessoais sensíveis. Conforme a LGPD, os dados pessoais sensíveis são os que têm 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.

A supressão espontânea pode culminar na discriminação de gênero em razão do potencial risco da falta de representatividade: 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. A simples exclusão de suas realidades do processo decisório poderá culminar na perpetuação, e até no reforço da discriminação.

O funcionamento dos algoritmos pressupõe uma certa autonomia própria, 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 será reinserido na análise preditiva sem ter existido a autorização.

Essas inferências e correlações são corriqueiras dentro dos algoritmos, e decorrem do cruzamento de informações e da criação da relação estatística entre um dado e outro. Com a supressão deliberada de apenas alguns tipos de dados, como é o caso dos dados sensíveis, o algoritmo poderá fazer a inferência estatística com o cruzamento de informações para tentar suprir a lacuna de conteúdo que não consta na base.

Essa prática conhecida também como “cegar o algoritmo”, pode ocorrer em boa-fé, com a pretensão de retirar vieses potencialmente discriminatórios do resultado final da predição automatizada, tentando promover decisões mais justas e equivalentes que não estariam associadas às características sensíveis dos usuários, porém prejudica a representatividade de dados e, ainda, permite a realização de correlações e inferências. Percebe-se então, que a supressão dos dados sensíveis não é o melhor caminho para evitar o tratamento diferenciado de mulheres.

4.2. Estruturação dos algoritmos e mineração de dados

A estrutura matemática e a manipulação da tecnologia preditiva podem interferir diretamente no potencial discriminatório das decisões automatizadas. As empresas se eximem de responder 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 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 não podem ser mais aplicados. Existe um grau de perícia que ainda pode ser desenvolvido em relação aos processos automatizados, e que está associado à maior capacidade de controle dos usuários em relação às etapas de tratamento de dados. Assim, é preciso controlar as ferramentas que desenvolve, atentando-se 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 (LINDOSO, 2021).

Construiu-se o ideal de que o algoritmo é algo excessivamente complexo e intangível para a maioria das pessoas, motivo pelo qual são consideradas fórmulas idôneas, criadas com exclusivo propósito de operacionalizar uma determinada função.

Contudo, essas fórmulas não são necessariamente neutras. Os algoritmos são 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 não (O'NEIL, 2021).

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 treinado. Por esse motivo que, antes de qualquer discussão acerca do potencial discriminatório em decorrência da mineração de dados, 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 (SILVA, 2018).

Ao utilizar determinados *proxies* - critérios inseridos diretamente na fórmula matemática e que deverão identificar o padrão pretendido, 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 e outros grupos. Esse tipo de interferência, na verdade, é difícil de ser verificada pois são protegidas como segredos de indústria e não costumam ser divulgadas (BAROCAS, 2016).

No mundo da tecnologia, existem também as correlações e inferências estatísticas, que são definidas pela capacidade do algoritmo de presumir a existência de informações e o conteúdo que, não necessariamente, existem nas bases de dados. A partir disso realiza-se uma associação de padrões e informações não necessariamente verdadeira, mas estatisticamente viável. Porém, se essas inferências forem falsas, elas podem estar associadas à reprodução de estereótipos discriminatórios, que prejudicarão mulheres e outras minorias.

Um exemplo disso é 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 prejuízos. 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, 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 vítimas, e não o contrário (LINDOSO, 2021).

5. POSSÍVEIS SOLUÇÕES PARA A DIMINUIÇÃO DE VIESES NOS ALGORITMOS

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 humano. E isso não se modifica pelo simples fato de ser feito por fórmulas matemáticas humanas de estrutura mais complexa.

Trata-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.

Algumas medidas podem ser tomadas para mitigar a discriminação algorítmica:

- a transparência da tecnologia, para viabilizar mecanismo de controle das estruturas automatizadas; e
- o compromisso com a informação, para que a população compreenda o funcionamento dos processos automatizados e a importância dos dados pessoais nas decisões automatizadas.

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

- um fluxo de dados seguro e confiável;

- o desenvolvimento de uma inteligência artificial centrada no ser humano e nos seus interesses;
- um compromisso dos Estados com o desenvolvimento tecnológico, com definição e políticas públicas flexíveis, mas robustas, em relação à temática;
- um pacto de aprimorar a segurança dos dados e dos usuários na economia digital; e
- 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 acesso, permitindo a participação de diferentes grupos nas variadas etapas dessa economia.

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 equidade de mulheres a partir do uso dos mecanismos automatizados. Criou-se um compromisso dos Estados-membros de

- estabelecerem regulações objetivando a primazia da transparência no processamento de dados pessoais;
- incentivarem a criação de bancos de dados abertos e neutros em relação ao gênero; e
- 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 gênero.

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 equidade 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.

5.1. Dados e base de dados

Uma forma de aumentar a representatividade de dados seria a adoção de base com dados qualitativamente relevantes onde todas as populações minoritárias sejam devidamente representadas de forma proporcional e justa.

Controlar as fontes de coleta de dados, fazer uma seleção cuidadosa de conteúdo relacionado ao processo, mapear a realidade da situação que será analisada, dentre outros cuidados podem ser fundamentais para evitar prejuízos às mulheres.

É extremamente importante também a participação de mulheres na manipulação e no desenvolvimento dessas tecnologias para ajudar a produzir dados sobre elas mesmas e diminuir a falta de representatividade de gênero existente nas produções científicas e na seleção e organização das informações para análise preditiva.

Em relação aos dados históricos, deve-se verificar a necessidade do seu uso em determinados contextos, com objetivo de evitar que uma determinada realidade seja perpetuada.

A supressão deliberada de dados pessoais sensíveis, ainda quando feita de boa-fé, para “cegar o algoritmo”, pode culminar em alguns problemas (LINDOSO, 2021):

- a falta de representatividade de dados; e

- 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.

Todas as diferentes características são importantes para que se assegure a representatividade dentro de uma análise por mineração de dados, 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 nos processos, inclusive, com direito de oposição ao resultado produzido.

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. Por outro lado, quando foram reinseridas as características de gênero com o objetivo de ajustar as distorções, percebeu-se a diminuição de vieses, reforçando a importância dos dados pessoais sensíveis para a análise específica. (ŽLIOBAITE, 2016).

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 na mineração de dados, ou que não serão objeto de correlações estatísticas ou inferências.

Portanto, é importante compreender, segundo Lindoso, de pronto, que os dados utilizados no processo automatizado podem causar impactos no resultado. Primeiro, porque existe pouca produção de dados acerca da realidade das mulheres, e 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 mineração de dados 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.

5.2. Estruturação dos algoritmos e mineração de dados

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 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. E isso ocorreria porque o desenho do algoritmo seria mais bem pensado, levando-se em consideração que:

- a estrutura precisa respeitar as diferentes circunstâncias vividas pelas mulheres—motivo pelo qual não poderia apenas reproduzir resultados que traduzem a média para todos os casos, e que
- 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 características discriminatórias nas estruturas algorítmicas, viabilizando melhores resultados em busca da equidade.

Outro ponto seria a falta de transparência em relação aos códigos que não é consequência apenas da opacidade dos algoritmos, mas dos interesses das empresas tendo em vista seus interesses individuais. Mesmo que essa proteção dos segredos de negócios seja legítima, o compromisso de transparência também deve ser valorizado.

Uma das premissas da LGPD é “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.

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.

A necessidade de transparência também assegura ao usuário determinadas obrigações por parte do provedor, como a própria explicação da lógica do tratamento de dados.

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 controlam.

Porém a divulgação de códigos, os quais são objeto de grande desconhecimento por parte da população em geral, e até por parte dos agentes regulatórios, 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 entender.

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.

Uma outra alternativa seria inserir comandos específicos na estrutura do algoritmo para que ele atuasse beneficiando positivamente os grupos minoritários, a fim de lhes assegurar a equidade, que seriam aqueles vieses não negativos, que se mostram como formas de alterar comportamentos sociais relevantes em razão dos resultados que podem produzir.

Divulgação dos critérios utilizados pelos programadores para treinarem o algoritmo, ou quais foram as características constantes no modelo e da metodologia segundo o qual aquela decisão será tomada, isso não viola segredos industriais, tampouco prejudica, sob a perspectiva da concorrência, o

modelo de negócios das empresas. Isso teria a finalidade de garantir que as mulheres não estão sendo prejudicadas, mas sendo tratadas de forma justa e comprometida com a equidade.

A própria tecnologia de mineração de dados pode permitir a realização de correlações e inferências estatísticas que não são necessariamente verdadeiras. Para resolução desse problema, retomamos a representatividade de dados, participação de mulheres na tecnologia, transparência, auditoria, educação algorítmica, treinamento com proxies positivos para neutralização de discriminações

6. CONCLUSÃO

Frequentemente pensamos nos termos como "algoritmo" e "*big data*" como sendo neutros ou objetivos, mas eles são tudo menos isso. Longe de serem estruturas neutras, são proposições carregadas de valores dignos de questionamentos, e repletos de poder. Parte do desafio de compreender os vieses algorítmicos é perceber que as formulações matemáticas que guiam as decisões automatizadas são feitas por seres humanos. As pessoas que desenham e usam esses dados para tomada de decisões automatizadas detêm todos os tipos de valores, muitos dos quais promovendo abertamente o racismo, misoginia, e noções falsas de meritocracia.

Nos Capítulos 1 e 2, vimos que a tomada de decisões automáticas viabilizada pelos algoritmos e pela inteligência artificial tem influenciado o cotidiano de toda a população em razão da velocidade que permitiu que as predições estatísticas ganhassem mais relevância. A *big data* permitiu criar um perfil do indivíduo de tamanha profundidade, que nem o próprio indivíduo pode controlar. Através desse perfil é possível criar quaisquer tipos de predições que impactam diretamente a vida desses usuários. 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, sobre quanto receberá de crédito no mercado.

Ocorre que, 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.

Em relação aos dados pessoais, a LGPD trouxe a perspectiva, que diz respeito à vedação do uso de dados como forma de discriminação. Perceber o gênero como dado pessoal sensível, 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.

No capítulo 3 é possível perceber que, em relação ao gênero, não se trata de negar que existam diferenças (pois elas existem aos montes, mesmo entre duas mulheres ou dois homens), mas antes, de apontar como e porque exatamente essas diferenças foram tomadas de uma determinada forma, para justificar espaços sociais de maior ou menor empoderamento. Ou seja, a diferença foi traduzida em oposição e desigualdade. “Gênero” é, portanto, um conceito relacional e implica, sempre, relações de poder, de privilégios. Assim, a tecnologia pode operar em detrimento dos interesses das mulheres, até porque essa pretensão, muitas vezes, pode nem existir nos espaços essencialmente masculinos onde é produzido o conhecimento.

Primeiro, porque existe pouca produção de dados acerca da realidade das mulheres, e 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 mineração de dados 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.

No Capítulo 4, foram apresentados conceitos sobre como a qualidade da base de dados influencia diretamente o resultado dos algoritmos. Portanto, se não existem dados suficientes sobre as mulheres, dificilmente os algoritmos conseguirão compreender a realidade feminina de forma inclusiva e não discriminatória. Contudo, a estrutura matemática em si e a manipulação da tecnologia preditiva podem interferir diretamente no potencial discriminatório das decisões automatizadas e não apenas a base de dados.

No Capítulo 5, foram apresentadas algumas medidas para mitigar a discriminação algorítmica em relação às mulheres como:

- adoção de base com dados qualitativamente relevantes, controle das fontes de coleta de dados;
- seleção cuidadosa de conteúdo relacionado ao processo e mapeamento da realidade da situação que será analisada;
- verificação da necessidade do uso de dados históricos em determinados contextos, com objetivo de evitar que uma determinada realidade discriminatória seja perpetuada;
- evitar a supressão deliberada de dados pessoais sensíveis, ainda quando feita de boa-fé, para “cegar o algoritmo”, a análise de dados sensíveis deve ser feita de forma consciente, cuidadosa e não discriminatória, garantindo ao usuário o controle e a participação ativa nos processos, inclusive, com direito de oposição ao resultado produzido;
- inserção de *proxies* positivos na estrutura do algoritmo para atuar beneficiando positivamente os grupos minoritários;
- aumento do compromisso das empresas em relação a da transparência no processamento de dados pessoais;
- maior presença e participação de mulheres enquanto programadoras e no campo da ciência poderia ajudar a diminuir a capacidade de inserção de características discriminatórias nas estruturas algorítmicas, viabilizando melhores resultados em busca da equidade;
- educação algorítmica para grupos minoritários possam cada vez mais participar da produção da tecnologia.

Com essas medidas podemos perceber que as empresas efetivamente possuem o controle sobre os algoritmos e que eles operam a seu favor e em seu benefício, portanto a diminuição da discriminação às mulheres e outras minorias dependem do compromisso ético dessas empresas, da legislação, do poder público, e principalmente do engajamento da população, principalmente das mulheres, para que essas medidas sejam efetivamente tomadas e implementadas corretamente.

7. REFERÊNCIAS

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

ALMEIDA, Virgilio A.F.. **Privacy Problems in the Online World**. IEEE Internet Computing, v. 16, 2012.

ANURADHA, J. et al. **A brief introduction on Big Data 5Vs characteristics and Hadoop technology**. Procedia computer science, v. 48, 2015.

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

BAER, Tobias. **Understand, manage, and prevent algorithmic bias: A guide for business users and data scientists**. Apress, 2019.

BANAJI, Mahzarin R.; GREENWALD, Anthony G. **Blindspot: Hidden biases of good people**. Bantam, 2016.

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

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.

CHODOSH, Sara. **Courts use algorithms to help determine sentencing, but random people get the same results**. Popular Science, 2018.

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%20Christina.pdf. Acesso em 7 de maio de 2022.

CORMEN, Thomas H. et al. **Algoritmos: teoria e prática**. Editora GEN LTC, 3ª Edição, 2021.

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

D'IGNAZIO, Catherine; KLEIN, Lauren F. **Data feminism**. MIT press, 2020.

DASTIN, Jeffrey. **Amazon scraps secret AI recruiting tool that showed bias against women**. 2018. Disponível em: <https://www.reuters.com/article/us-amazon-com-jobs-automation-insight-idUSKCN1MK08G>. Acesso em 7 de maio de 2022.

DONEDA, Danilo; Almeida, Virgilio A.F. **What Is Algorithm Governance?** IEEE Internet Computing, 2016.

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, 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 7 de maio de 2022.

EBERHARDT, Jennifer L. **Biased: Uncovering the hidden prejudice that shapes what we see, think, and do**. Penguin Books, 2020.

ELSEVIER. Gender in the Global Research Landscape. **Analysis of research performance through a gender lens across 20 years, 12 geographies and 27 subject areas**. Disponível em: https://www.elsevier.com/__data/assets/pdf_file/0008/265661/ElsevierGenderReport_final_for-web.pdf. Acesso em 7 de maio de 2022.

FRY, Hannah. **Hello World: How to be Human in the Age of the Machine.** Random House, 2018.

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.

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.

HAND, D; MANNILA, H; SMYTH, P. **Principles of Data Mining.** MIT Press, 2001.

HOOKER, Sara. **Moving beyond “algorithmic bias is a data problem”.** Patterns, v. 2, n. 4, p. 100241, 2021.

HORA, Nina da. **Ética em IA: a pergunta que não estamos fazendo.** MIT TECHNOLOGY REVIEW. Disponível em: <https://mittechreview.com.br/etica-em-ia-a-pergunta-que-nao-estamos-fazendo/>. Acesso em 5 de junho de 2022.

HURWITZ, J. et al. **Big Data.** New York, 2013.

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.

KEARNS, Michael. **Data Intimacy, Machine Learning and Consumer Privacy.** University of Pennsylvania Law School, May 2018. Disponível em: <https://www.law.upenn.edu/live/files/7952-kearns-finalpdf>. Acesso em 7 de maio de 2022.

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

KLEINBERG, Jon. **Discrimination in the Age of Algorithms,** Journal of Legal Analysis, Volume 10, 2019, Pages 113–174.

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.

LAQUEUR, Thomas Walter. **Inventando o sexo: corpo e gênero dos gregos a Freud.** Trad. Vera Whately. Rio de Janeiro: Relume Dumará, 2001.

LEE, Nicol Turner. Resnick, Paul. Barton, Genie. **Algorithmic bias detection and mitigation: Best practices and policies to reduce consumer harms.** Brookings: 2019. Disponível em <https://www.brookings.edu/research/algorithmic-bias-detection-and-mitigation-best-practices-and-policies-to-reduce-consumer-harms/>. Acesso em 7 de maio de 2022.

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

LINDOSO, Maria Cristine Branco. **Discriminação de Gênero no Tratamento Automatizado de Dados Pessoais.** Editora Processo; 1ª edição. 2021.

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.

MADGAVKAR, Anu. **A conversation on artificial intelligence and gender bias.** 2021. Disponível em: <https://www.mckinsey.com/featured->

insights/asia-pacific/a-conversation-on-artificial-intelligence-and-gender-bias.

Acesso em 7 de maio de 2022.

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.

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.

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://jornalgggn.com.br/tecnologia/internet/como-democratizar-a-economia-digital-e-evitar-ofeudalismo-digital-por-mariana-mazzucato/>. Acesso em 7 de maio de 2022.

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

MIKAELA Pisani. **How Women Need To Be Involved In Data Science To Prevent Bias In Algorithms.** Disponível em: <https://www.rootstrap.com/blog/how-women-need-to-be-involved-in-data-science-to-prevent-bias-in-algorithms/>. Acesso em 7 de maio de 2022.

MIKKELSON, Stephanie. **Gender Bias in Data and Tech.** Disponível em: <https://www.engineeringforchange.org/news/gender-bias-data-tech/>. Acesso em 7 de maio de 2022.

MIT TECHNOLOGY REVIEW. **A IA para busca de candidatos a vagas do LinkedIn era tendenciosa. A solução da empresa? Mais IA.** 2021. Disponível em: <https://mittechreview.com.br/a-ia-para-busca-de-candidatos-a-vagas-do-linkedin-era-tendenciosa-a-solucao-da-empresa-mais-ia/>. Acesso em 7 de maio de 2022.

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, 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.

NIETHAMMER, Carmen. **AI Bias Could Put Women's Lives At Risk - A Challenge For Regulators**. 2020. Disponível em: <https://www.forbes.com/sites/carmenniethammer/2020/03/02/ai-bias-could-put-womens-lives-at-risk-a-challenge-for-regulators/?sh=6f12efe6534f>. Acesso em 7 de maio de 2022.

NOBLE, Safiya Umoja. **Algorithms of oppression**. New York University Press, 2018.

O'NEIL, Cathy. **Algoritmos de Destruição em Massa**. Editora Rua do Sabão, 2021.

OECD **Exploring the Economics of Personal Data**. Paris: OECD Publishing, 2013, p. 12. Disponível em: <<https://doi.org/10.1787/5k486qtxldmq-en>>. Acesso em 7 de maio de 2022.

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

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

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

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

SAGIROGLU, Seref; SINANC, Duygu. **Big data: A review**, 2013 International Conference on Collaboration Technologies and Systems (CTS), 2013, pp. 42-47, doi: 10.1109/CTS.2013.6567202.

SANTOS-D'AMORIM, Karen; CRUZ, Rúbia Wanessa; SILVA, Marcela; CORREIA, Anna. (2020). **Dos dados ao conhecimento: tendências da produção científica sobre Big Data na Ciência da Informação no Brasil**. Encontros Bibli: revista eletrônica de biblioteconomia e ciência da informação, 2020.

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

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

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

SMITH, Genevieve, and Ishita Rustagi. **When Good Algorithms Go Sexist: Why and How to Advance AI Gender Equity**. Stanford Social Innovation Review, 2021.

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

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

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

WARREN, Samuel D.; BRANDEIS, Louis D. **The right to privacy**. Harvard Law Review, 1890.

ZANELLO, Valeska. **Saúde mental, gênero e dispositivos: cultura e processos de subjetivação**. Editora Appris, 1ª edição. 2018.

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 7 de maio de 2022.

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.

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