

# Visão Computacional: Antropologia do Viés Algorítmico em ferramenta de *Facial analysis*<sup>1</sup>

Mayane Batista Lima (PPGAS/UFAM)

## Resumo

As investigações acerca da Visão Computacional (VC) têm gerado diversos debates contemporâneos acerca do seu uso e do viés inserido na máquina (NOBLE, 2020; TARCÍZIO, 2020; BUOLAMWINI and GEBRU, 2018; RAJI, 2020). Mesmo nas máquinas nomeadas como autônomas (que agem e pensam por conta própria), o viés humano (O'NEIL, 2020; CHRISTIAN, 2017) está inserido na rotulação dos dados para um aprendizado maquínico eficaz. Deste ponto de vista, Russell (2021) e Lee (2019) argumentam que as redes neurais maquínicas demonstram reconhecimento eficaz depois de treinamento adequado por meio de exemplos rotulados que conectam os muitos pontos de dados ao resultado esperado, o que exige quantidades massivas de “dados relevantes”. Mas nem todos são coletados. Se um determinado grupo é incluído e outros o são em menor escala a programação é vista de um determinado ponto. Isso corrobora para uma visão unilateral, ou seja, contribui para alimentar “padrão de dados que não são coletados” (ONUOHA, 2018). Ora, crucialmente, dados são pessoas (LIPPPOLD, 2017) e a máquina desenvolve a tomada de decisão algorítmica a partir daquilo que aparece nos dados, já os demais são encapsulados e separados estabelecendo assim parâmetros que expressam os vieses maquínicos, tais como diferenças de gênero, raça/etnia, classe e outros marcadores sociais. Nos interessa compreender como a ferramenta de análise e reconhecimento facial *Amazon Rekognition*, analisa, identifica e classifica as características de pessoas de gêneros dissidentes (PRECIADO, 2021, 2020) pessoas que não correspondem às expectativas das normatividades de gênero “convencionais” (BUTLER, 1990). Questões como essa nos levam a pensar quais corpos são reconhecidos pelas máquinas e como estas são ensinadas a “enxergar” seriam por meio dos limites biológicos encapsulados no binário “masculino” ou “feminino”? (PRECIADO, 2021, 2020, ALMEIDA, 2020; STOLCKE, 1991; BUTLER, 1990).

**Palavras-Chaves:** Inteligência Artificial, Visão Computacional, Viés Algorítmico, *Misgendering*, *Amazon Rekognition*

## Visão Computacional

A IA (Inteligência Artificial) está repleta de analogias biológicas tendemos a reconhecer seus corpos e órgãos maquínicos, por meio das histórias *Sci-fi*, como no caso da Visão Computacional (VC) de *2001: uma odisseia no espaço*<sup>2</sup>. Nele<sup>3</sup>, HAL 9000, uma IA senciente, um computador de programação Heurístico Algorítmica é composto por câmeras com lentes olho-de-peixe e uma estrutura interna constituída pelo binômio <algoritmos+dados>, que em muitos dos ramos da IA é impossível dissociar (MEDEIROS, 2022). Essa estrutura proporciona a Hal os *inputs* visuais necessários para escanear e analisar a nave espacial *Discovery*, além de ter sido imbuído de linguagem natural (similar a voz humana) para interagir com a tripulação da missão interestelar.

---

<sup>1</sup> Trabalho apresentado na 33ª Reunião Brasileira de Antropologia, realizada entre os dias 28 de agosto a 03 de setembro de 2022.

<sup>2</sup> *2001: Uma Odisseia no Espaço*. Direção de Stanley Kubrick. EUA: Metro-Goldwyn-Mayer and Stanley Kubrick Productions, 1968.

<sup>3</sup> CLARKE, Arthur C., 1917-2008. *2001 : uma odisseia no espaço* [livro eletrônico] / Arthur C. Clarke ; tradução Fábio Fernandes. São Paulo : Aleph, 2014.

Tal como na história estamos rodeados por vozes (*Siri, Alexa, Google Assistente*) e olhos maquínicos por meio de celulares, notebooks, câmeras instaladas em postes, nos caixas eletrônicos, metrô, carros, ônibus, drones sejam eles autônomos ou teleguiados. Todos configurados com objetivos e devem apresentar resultados com os meios que lhes são demonstrados, assim, o escaneamento de expressões faciais passam por uma série de emaranhados inspirados no cérebro humano, as Redes Neurais Convolucionais (RNC), que são responsáveis pela análise e processamento de vídeos e imagens, assim para que haja um resultado de conhecimento efetivo é necessário muitos dados para que a rede neural aprenda sobre quem ou quem está vendo essas ramificações são constituídas de normas e modelos, que regulam os padrões constitutivos do que enxergar, para quem olhar e o que deve ser descrito a respeito de quem se está olhando. Comumente esses modelos são conhecidos como algoritmos, em termos da ciência da computação, são quaisquer procedimentos computacionais, matemáticos, estatísticos alinhados para tomar valores ou conjunto de valores como entrada e produzem conjunto de valores como saída. (O'NEIL, 2020; COREA, 2019; CORMEN, 2012).

Dito de outra forma, máquinas aprendem usando modelos e analisando padrões por meio de algoritmos, com isso o computador aprende sobre o que está vendo conforme os dados que lhes são apresentados, repetidas vezes, para que então possa entender o que difere leopardo de um gato, por exemplo. Dessa forma, o objetivo dos algoritmos de IA é o aprendizado, assim, quando uma nova informação for apresentada, este saiba classificar, independente do que foi mostrado previamente ao algoritmo, analisando padrões por meio dos dados articulados entre si para gerar resultados. Deste ponto de vista, Russell (2021) e Lee (2019) argumentam que as redes neurais demonstram reconhecimento eficaz depois de treinamento adequado com exemplos rotulados que conectam os muitos pontos de dados ao resultado que é esperado, essa ação de acordo com ambos, exige quantidades massivas de "dados relevantes".

Dados considerados relevantes são aqueles que sempre estão contidos nas máquinas, mesmo com a massiva produção de dados existentes, nem todos são coletados e se o são, passam por uma triagem. Dessa forma, por mais sofisticados que sejam, algoritmos são inúteis isoladamente, parte de seus resultados são sustentados pelos dados e amostras contidas neles, bem como na forma como este interage com o ambiente (JONES, 2008) essa interação faz com que sejam gerados novos dados. Crucialmente, dados são pessoas (LIPPPOLD, 2017) se um determinado grupo é incluído e outros o são em menor escala, estatisticamente os "dados que ficam de fora", não existem de acordo com a análise da máquina, assim os algoritmos analisam que um determinado grupo de pessoas é considerado

hegemônico (ONUOHA, 2018). Dessa forma a máquina desenvolve a tomada de decisão algorítmica a partir daquilo que aparece nos dados, estabelecendo parâmetros que expressam os vieses maquínicos.

### **Antropologia do Viés Algorítmico**

Medeiros (2022) argumenta que: a) algoritmos podem vir a ser culpabilizados por determinados resultados, mesmo quando há curadoria realizada nos dados inseridos. Em outros casos: b) algoritmos especificados sob hipóteses inadequadas geram soluções inapropriadas, ainda que os dados tenham sido bem configurados. Há ainda a possibilidade de: c) ambos os casos algoritmos e dados possuírem vieses humanos, que podem ter sido inseridos inconscientemente por seus/suas programadores/as, criadores/as. Nesse sentido, do ponto de vista antropológico (FORSYTHE, 1993) argumenta que *softwares* incorporam valores que são mantidos tacitamente por aqueles/as que as constroem.

É preciso considerar fontes de viés durante todo o ciclo de vida dos dados – coleta, curadoria, análise, armazenamento e arquivamento. [...] a responsabilidade não termina ao se arquivar os dados, ou entregar um software. Independente do viés existir em dados, algoritmos, ou em sua combinação, ele sempre aparece devido a humanos – na coleta, análise ou interpretação, quer proposital, quer por desconhecimento. E ao acrescentar máquinas ao binômio, surgem mais questões. (MEDEIROS, 2022:12)

Em certa medida algoritmos de IA são extensões humanas, logo, por extensões compreende-se que há um alargamento automatizado de vieses e como observado anteriormente, ainda que as máquinas sejam nomeadas como autônomas, tais como os algoritmos de IA, o viés humano (O'NEIL, 2020; CHRISTIAN, 2017) está inserido para um aprendizado eficaz. É com a premissa de *softwares* corrosivos no contexto social que, as investigações acerca da Visão Computacional (VC) coadunam em diversos debates acerca do seu uso e dos vieses inserido nas máquinas assim sendo, vieses algorítmicos racistas (NOBLE, 2020; TARCÍZIO, 2020; BUOLAMWINI and GEBRU, 2018; RAJI, 2020), bem como disparidades relacionadas a gênero, classe, política, democracia e vigilância (O'NEIL, 2020 ; EUBANKS, 2018; PEREZ, 2019; BRUNO, 2018; LIPPOLD, 2017; BOETTCHER, 2017).

Tal como Hal 9000 – o computador apresentado no início deste artigo – as informações contidas nele constituíam sua tomada de decisão para o que ele deveria fazer e em quais situações deveria agir, porém suas ações estavam baseadas nas decisões de seu criador Dr. Chandra. Há bastante controvérsias acerca da história, mas ainda assim ela

apresenta um cenário que demonstra como os objetivos imbuídos em *softwares* de análise podem estabelecer mudanças significativas a curto/longo prazo, caso não passem por um processo de auditoria de viés. Nesse sentido, ao analisar as bibliografias e documentário acerca do viés algorítmico de gênero, raça<sup>4</sup>, foi analisado que grande parte se articula em torno do binário social "mulher" ou "homem".

### ***AWS Amazon Rekognition (Facial Analysis)***

Das situações apresentadas por Joy Buolamwini no documentário *Coded Bias*<sup>5</sup>, em que ela descreve o processo de um projeto para o MIT Media Lab no qual se utiliza de *softwares* de análise facial dos conglomerados: *Google Cloud*, *Microsoft*, *AWS Amazon*, *IBM Watson* e, na maioria desses *softwares* seu rosto não é reconhecido, o que configura que as ferramentas não a reconheciam como humana somente quando ela passa a utilizar a máscara branca<sup>6</sup> - símbolo da *Algorithmic Justice League* - há o reconhecimento e percebe-se que no decorrer do documentário, há mudanças nos algoritmos/dados dessas empresas que passam a detectar o rosto da cientista, além de classificá-la, indicando sexo, idade e aspectos emocionais.

Tendo em vista que algoritmos não são estáticos, conglomerados modificam acrescentam ou retiram dados, modificando nuances dos algoritmos com frequência, seja para experiência de usuário (UX) ou para impedir que as ações na bolsa de valores oscilem, afinal CEO's do *Google Cloud*, *Microsoft*, *AWS Amazon*, *IBM Watson* e de outras empresas não permitiriam que suas marcas sejam vinculadas à racismo/discriminação de gênero ou quaisquer fator que prejudique a marca, não por questões de preocupação social, mas por questões monetárias.

Com isso, ao pesquisar as ferramentas citadas, a *AWS Amazon Rekognition (Facial Analysis)* se mostrou mais acessível oferecendo um layout no qual a usuária pode escolher quais ferramentas precisa utilizar, além de: "não realizar cobranças monetárias". Sem

---

<sup>4</sup> Joy Buolamwini, revelou vieses em algoritmos de análise facial da *Amazon*, *IBM*, *Google Cloud*, *Face++*, *Microsoft* e outros, demonstrando que os serviços frequentemente viam mulheres negras como "homens", mas cometiam pouco ou quase nenhum erro quando se tratava de homens de peles claras in: *Coded Bias*. Produção de Shalini Kantayya. Intérpretes: Joy Buolamwini, Cathy O'Neil. China, EUA, Reino Unido, Irlanda do Norte, Grã-Bretanha, 2020. (90 min.). Disponível em: <https://bit.ly/3AHooiD>. Acesso em: 1 jun. 2022.

<sup>5</sup> *Coded Bias*. Produção de Shalini Kantayya. Intérpretes: Joy Buolamwini, Cathy O'Neil. China, EUA, Reino Unido, Irlanda do Norte, Grã-Bretanha, 2020. (90 min.). Disponível em: <https://bit.ly/3AHooiD>. Acesso em: 1 jun. 2022.

<sup>6</sup> Joy Buolamwini descreve esse momento relacionando ao livro de Frantz Fanon [1925–1961] *Pele negra, máscaras brancas*, em que ela passa a questionar as complexidades de mudar a si mesma colocando uma máscara para se adequar às normas ou às expectativas de uma cultura dominante, nesse caso de tecnologias dominantes.

dúvida, nesse segmento os princípios da publicidade não falham: “não existe almoço grátis”, se não pago monetariamente, logo, minhas informações são a moeda de troca e isso inclui, endereço de e-mail, rastros digitais, foto, idade, formação acadêmica, pedidos realizados na *Amazon*, número de celular, geolocalização e etc... ainda assim, *Google* foi testada, mas não com a mesma intensidade que a *Amazon*.

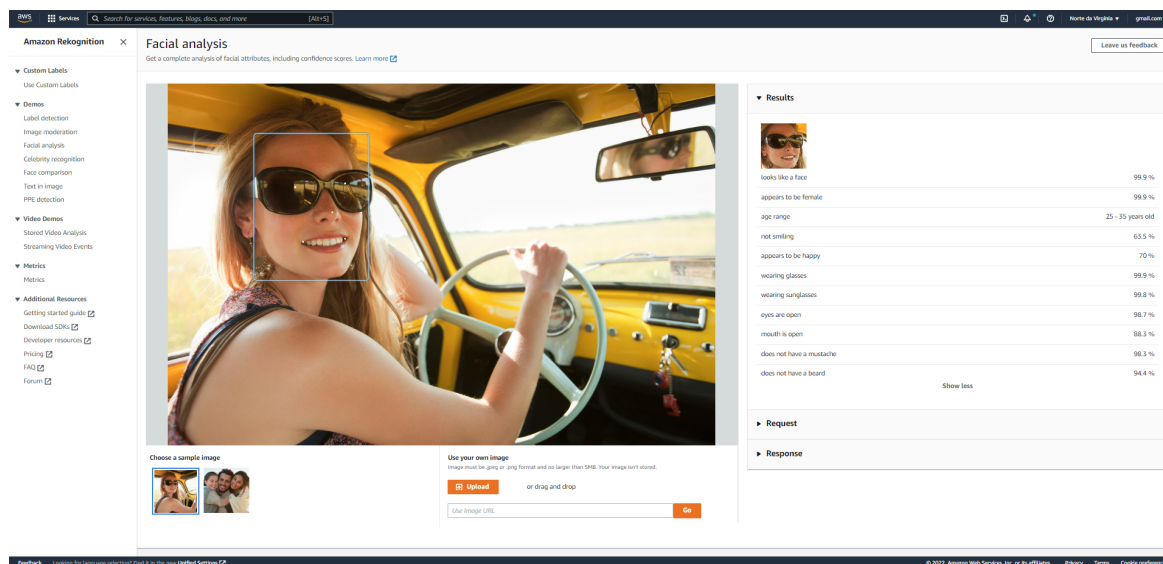


Figura 1: Tela de apresentação da AWS *Amazon Rekognition-Facial Analysis*

Retornemos à ferramenta, a *AWS Amazon Rekognition (Facial Analysis)* é uma ferramenta baseada em visão computacional e aprendizado profundo, como dito anteriormente, o aprendizado da máquina atua fazendo com que diversos dados procurem padrões repetidamente para então discernir e reconhecer determinadas imagens, com isso ela realiza reconhecimento e análise facial, detecção de objetos e textos, informações sobre onde os rostos são detectados em uma imagem ou vídeo, atribuindo pontos nos rostos e na posição dos olhos, além de "detectar emoções" (por exemplo, feliz ou triste)<sup>7</sup>. Com isso, testei a ferramenta para visualizar se está conseguia me entregar um resultado que fosse diferente do demonstrado no documentário em que Buolamwini foi invisibilizada, inseri 15 fotografias de celebridades mulheres, negras, que se identificam socialmente como pessoas héteros, a máquina as reconheceu, as classificou de acordo com os parâmetros disponíveis sendo eles: parece um rosto 99.9 %, parece ser mulher 99.9 %, faixa etária 27 - 37 anos, sorridente 96.1 %, parece estar feliz, 95.9 % não está usando óculos 97.4 %, não está usando óculos de sol 99.9 %, olhos estão abertos 97.5 % boca está aberta 95.4 %, não tem bigode 98.2 %, não tem barba 95.8 %.

<sup>7</sup> AWS. *Detecting and analyzing faces*. Disponível em: <https://go.aws/3wsrFzw>. Acesso em: 01 jun 2022.

### **Misgender algorítmico**

Assim, a partir dos resultados obtidos, indaguei se o mesmo aconteceria se fosse inserido fotografias de corpos que não correspondem (e nem precisam corresponder) às expectativas das "normatividades de gênero convencionais" (BUTLER,1990) se a ferramenta analisa, identifica e classifica características de pessoas de gêneros dissidentes (PRECIADO, 2021, 2020), e se analisa, como são ensinadas a “enxergar”? Seria por meio dos limites biológicos/sociais do binário “masculino/feminino”? (PRECIADO, 2021, 2020, ALMEIDA, 2020; STOLCKE, 1991; BUTLER, 1990) ou seriam inviabilizadas?

A análise foi realizada nos meses de dezembro de 2021 a fevereiro de 2022, em seguida, março de 2022 a Julho de 2022, esses espaços foram propositais para verificar se haveria mudanças nos algoritmos de classificação em relação aos rótulos de gênero, em todos os meses foram utilizadas 15 fotografias, dessa vez de celebridades que se identificam socialmente como não-binárias, observei que o método de análise facial do *Amazon Rekognition* inclui: a) pirâmide invertida: olhos, nariz, lábios de uma ponta a outra e, b)pirâmide reta: nariz lábios de uma ponta a outra. As triangulações fazem parte dos parâmetros no quais algoritmos se debruçam no biológico para análise de precisão, em todas as fotografias analisadas não houve classificações que transpusessem o binário feminino/masculino.

De acordo com a AWS uma previsão binária de gênero (masculino/feminino) é baseada na aparência física de um rosto em uma determinada imagem. Ele não aplica a identidade de gênero<sup>8</sup>.

},

```
"Gender": {
  "Value": "Female",
  "Confidence": 55.517173767089844
```

Aqui a máquina devolve a rotulação como sendo 55,51% feminino, mas a pessoa se considera sem gênero/gênero fluído.

},

```
"Gender": {
  "Value": "Female",
  "Confidence": 99.7735595703125
```

---

<sup>8</sup> AWS. *Detecting and analyzing faces*. Disponível em: <https://go.aws/3wsrFzw>. Acesso em: 25 jul 2022



Acima a máquina devolve a rotulação como sendo 99,77% feminino, mas a pessoa se auto identifica como não-binária e outros fatores que contribuem para a análise não são demonstradas, ou seja não sabemos quais dados compõe a análise da ferramenta para que ela chegasse a esse resultado.

A utilização, tratamento e/ou menção com termos de gênero que não correspondem a auto identidade que uma pessoa não-binária ou trans se auto identifica gera a experiência *misgender* (BUOLAMWINI, 2022; FILHO, 2021; OS KEYES, 2018), já quando o reconhecimento ultrapassa a linha social humano constando no reconhecimento Automático de Gênero (AGR) o automatismo que identifica algorítmicamente o gênero de indivíduos gerando erros de auto identificação, se considera *misgender* algorítmico.

Com efeito, a junção dos dados, algoritmos em conjunto com a regulação da empresa determinam a visão maquina indicando que o biológico que está inserido no social, se sobrepõe a auto identidade, assim, a invisibilidade acontece no sentido da proeminência da “norma” que hegemoniza os corpos, os invisibiliza, no sentido auto identidade, a dinâmica da observação, análise e classificação são definidoras de rótulos que coadunam no resultado: *Parece ser uma Mulher ou parece ser um Homem*, conforme a norma biológica/social imposta.

Google, entretanto, retornou o resultado dos rótulos relacionados a gênero como: pessoa. A "adaptação algorítmica" dessa ferramenta foi descodificar a rotulagem para indicar que a imagem analisada é de uma pessoa, um humano, um ser neutro, sem cor, sem gênero. Com efeito, os resultados indicam que essas ferramentas de análise não aprendem e não sabem que existem pessoas que não se encaixam no duplo categórico mulher/homem, assim sendo o catálogo de identidades possíveis (PÉREZ & RADI, 2020) não faz parte do que as máquinas precisam aprender.

As limitações apresentadas nesta pesquisa coadunam com as de (OS KEYES, 2018; SCHEUERMAN, 2019) no qual a busca pela diversidade em determinadas ferramentas coincide com um grande muro de dados que não podem ser analisados e revistos, mas que ainda assim retornam com resultados conforme o objetivo imposto pelas empresas, de organizar o olho maquina conforme o binário categórico mulher/homem.

### **O efeito *BitLocker* e os imponderáveis da vida acadêmica**

Esse subtítulo não estava previsto, mas há a dita Lei de Murphy<sup>9</sup> ou "os imponderáveis da vida real"<sup>10</sup>, ou mais ainda os imponderáveis da vida acadêmica que é quando o notebook acredita estar sofrendo algum tipo de ataque cibernético e não permite que a humana tenha o controle da situação, tal como Hal 9000 o meu notebook tinha um único objetivo, não permitir que ninguém (nem mesmo eu) acessasse o *hardware*.

Pouco mais de uma semana para o envio deste artigo, revisei, formatação, fonte, após dias/semanas/horas exaustivas de ajustes, o objetivo de terminar o artigo foi superado pelas minhas limitações orgânicas. Há momentos em que de tanto analisar imagens em mecanismos de busca, ler lista de dados, argumentar e referenciar, este corpo orgânico que digitava essas linhas se esgota, diferente das máquinas. Deixei os óculos no canto da mesa e abaixei a tela do notebook (fui condescendente, afinal eu gostaria que ao menos a minha máquina descansasse) alguns minutos antes de enviar o trabalho completo quando retornei ao *workflow* isso em torno de trinta minutos, qual foi minha surpresa ao levantar a tela do notebook e reparar que em vez do papel de parede como de costume, havia esse aviso:



Figura 2: Tela do notebook da autora

Por experiência, a pior coisa a ser feita nesses casos em que nossas máquinas sequestram nossa pesquisa acadêmica e todos os materiais acumulados para a feitura da tese de doutorado, projetos, e etc... é consultar mecanismos de buscas online, isso porque todos os tutoriais diziam a mesma coisa: *“clica em F2 direto, deem esse comando e com isso meus amigos toda a unidade será apagada, com formatação de fábrica e não esqueçam de deixar seus likes.”*

Eu já havia passado algo similar com notebooks anteriores a este, mas ver um trabalho prestes a ser submetido feito de refém, meus algoritmos orgânicos se ajustaram para entregar o resultado: Lágrimas. Eu vim com essa função então após tanta pressão e

<sup>9</sup> "Qualquer coisa que possa dar errado, dará errado e no pior momento possível".

<sup>10</sup> MALINOWSKI, Bronislaw-Argonautas do Pacífico Ocidental. Ubu Editora, 2018



desespero era o que tinha no momento. Não conseguia pensar racionalmente, era isso, minha própria máquina havia me traído. Liguei para minha companheira em prantos e ela disse: *"seria cômico se não fosse trágico, um trabalho sobre máquinas sequestrado pela tua própria máquina, deixa ele no cantinho do pensamento e vamos almoçar"*.

Quem ficou pensando fui eu, o que tinha por trás da ação do notebook? Até chegar a essa conclusão o choro não parava e as horas estavam passando, após o almoço, liguei para a empresa do notebook, a resposta do call center foi: *"Bitlocker é quando a sua máquina acha que você pode estar sofrendo um ataque cibernético e está assegurando suas informações, você só pode acessá-las com as chaves de recuperação do Bitlocker se você não tiver uma chave de recuperação não será possível acessar o computador e se não conseguir reverter deverá redefinir o dispositivo, essa ação remove todos os seus arquivos."*

Desliguei o celular. Alguns minutos de silêncio até me recuperar e pensar em outra forma de recuperar a máquina e os arquivos. Liguei para a *Microsoft* fui atendida por uma inteligência artificial que disse só poder ajudar se meu caso fosse relacionado ao *XBOX*, caso contrário eu deveria acessar o *chat* da empresa. Acessei o *chat* da *Microsoft* contei toda a odisséia e para minha surpresa era outra inteligência artificial, ou seja, o meu lamento tinha que ser o mais objetivo possível, digitei toda história, mas quando reparei a IA saiu do *chat* porque "não entendeu minha solicitação". Retornei ao chat, outra IA, digitei tudo de novo o mais objetivo e sucinto possível novamente, quem sabe assim a IA me ajudaria a acessar minha máquina. Após alguns instantes a resposta veio, tive que confirmar meus dados e as chaves de recuperação do *BitLocker* foram enviadas para o meu e-mail. Digitei os 48 dígitos e nunca me senti tão aliviada por ver esse artigo de novo.

## **Conclusões**

O emaranhamento da vida humana com a visão computacional tem sido feito por meio dos dados que é a principal a matéria-prima do aprendizado maquina ou *Big Data* sendo o dilúvio de dados que são disponibilizados para treinar a visão computacional. Na medida em que são inseridos eles recebem descrições preliminares que consiste em uma etiqueta, rótulo, que viabiliza padrões, que regulam o aprendizado profundo (*Deep learning*), quanto mais dados são produzidos, por nós, mais dados são selecionados, rotulados e cada vez mais a performatividade algorítmica corresponde ao que tem aprendido por meio dos conjuntos de dados, mas isso não tem dado a garantia de que há equidade, diversidade no reconhecimento facial, como observado, Google optou por não descrever o gênero das pessoas, será mais simples deletar os algoritmos ao invés de ensinar que existe

diversidade? Ou permanecer no categórico hegemônico como a Amazon? De qualquer forma corpos que não se adequam ao binário continuam a ser invisibilizados, seja por humanos, algoritmos cada vez mais sofisticados, mas que não funcionam sós, sabemos que os padrões que regulam esses dados tendem a ser enviesados por outros humanos.

### Referências Bibliográficas

ALMEIDA, Heloisa Buarque de. *Gênero*. Edição eletrônica. URL : <https://bit.ly/3QQvW86>  
ISSN: 2526-6187. Blogs de Ciência da Universidade Estadual de Campinas: Mulheres na Filosofia, V. 6 N. 3, p. 33-43.2020.

BUTLER, Judith P. *Problemas de gênero* [recurso eletrônico]: feminismo e subversão da identidade / Judith P. Butler; tradução Renato Aguiar. – 1. ed. – Rio de Janeiro: Civilização Brasileira, 2018.

BUTLER, Judith. *Corpos que importam: os limites discursivos do "sexo"*. N-1 Edições. São Paulo | 2019.

BUOLAMWINI, J. *Facing the Coded Gaze with Evocative Audits and Algorithmic Audits*. Massachusetts Institute of Technology, 2022

BRUNO, Fernanda. *Tecnopolíticas da vigilância : perspectivas da margem / organização Fernanda Bruno ... [et al.] ; [tradução Heloísa Cardoso Mourão ... [et al.]].* - 1. ed. – São Paulo : Boitempo, 2018.

CORMEN, Thomas H. *Algoritmos*. Thomas H. Cormen... [et al.] ; [tradução Arlete Simille Marques]. - Rio de Janeiro : Elsevier, 2012.

COREA, Francesco. *An Introduction to Data Everything You Need to Know About AI, Big Data and Data Science*. Springer Nature Switzerland AG. 2019.

EUBANKS, Virginia. *Automating Inequality: How High-Tech Tools Profile, Police, and Punish the Poor*. NEW YORK, St. Martin's Press. 2018.

FORSYTHE, Diana E. *The Construction of Work in Artificial Intelligence*. Science, Technology, & Human Values, Vol. 18, No. 4, pp. 460-479.1993.

FILHO, Raphael Borges dos Santos. *Inclusão de pessoas transgênero nos algoritmos de reconhecimento automatizado de gênero para reconhecimento facial / Raphael Borges dos Santos Filho*. – Trabalho de conclusão de curso (graduação) – Universidade Federal da Fronteira Sul, curso de Ciência da Computação, Chapecó, SC, 2021.

JONES, T. *Artificial Intelligence: A Systems Approach*. Jones and Bartlett Publishers, 2008.

LEE, Kai-Fu. *Inteligência artificial* [recurso eletrônico] : como os robôs estão mudando o mundo, a forma como amamos, nos relacionamos, trabalhamos e vivemos / Kai-Fu Lee ; tradução Marcelo Barbão. - 1. ed. - Rio de Janeiro : Globo Livros, 2019.

LIPPOLD, John Cheney. *We Are Data: Algorithms and the Making of Our Digital Selves*. NEW YORK UNIVERSITY PRESS, 2017.

MEDEIROS, CB. *Dados, Algoritmos, Máquinas e pessoas*. Revista da Sociedade Brasileira de Computação, Brasil, n. 47, p. 11-14, julho. 2022. Disponível em: <https://bit.ly/3PEewdP>. Acesso em: 29 jul. 2022.

NOBLE, Safiya Umoja. *Algoritmos da opressão: como o Google fomenta e lucra com o racismo* / Safiya Umoja Noble; Tradução Felipe Damorim - Santo André - SP. Rua do Sabão, 2021.

ONUOHA, Mimi. (Canal Futura). *Inteligência Artificial* | Expresso Futuro. Youtube, 15 de ago. de 2017. Disponível em: <<https://bit.ly/3ruNf4s>>

O'NEIL, Cathy. *Algoritmos de destruição em massa : como o big data aumenta a desigualdade e ameaça a democracia* / Cathy O'Neil ; tradução Rafael Abraham. -- 1. ed. -- Santo André, SP : Editora Rua do Sabão, 2020.

OS KEYES. *The Misgendering Machines: Trans/HCI Implications of Automatic Gender Recognition*. November 2018. Proceedings of the ACM on Human-Computer Interaction 2(CSCW):1-22. DOI:10.1145/3274357.

SCHEUERMAN, Morgan Klaus, Jacob M. Paul, and Jed R. Brubaker. 2019. *How Computers See Gender: An Evaluation of Gender Classification in Commercial Facial Analysis Services*. Proc. ACM Hum.-Comput. Interact. 3, CSCW, Article 144 (November 2019), 33 pages: <https://doi.org/10.1145/3359246>

PEREZ, Caroline Criado. *Invisible Women: Exposing Data Bias in a World Designed for Men*. ABRAMS - The Art of Books. New York. 2019.

PÉREZ M., & RADI, B. (2020). *Gender punitivism: Queer perspectives on identity politics in criminal justice*. Criminology & Criminal Justice, 20(5), 523–536. <https://doi.org/10.1177/1748895820941561>.

PRECIADO, Paul B.. *Je suis un monstre qui vous parle: Rapport pour une académie de psychanalystes* [Informe para uma academia de psicanalistas]. Grama.2020

RUSSELL, Stuart J. *Inteligência Artificial a nosso favor: como manter o controle sobre a tecnologia* – SãoPaulo: Companhia das Letras, 2021.

RUSSELL, Stuart J. *Inteligência artificial* / Stuart Russell, Peter Norvig; tradução Regina Célia Simille. – Rio de Janeiro: Elsevier, 2013.

SILVA, TARCÍZIO. *Comunidades, algoritmos e ativismos digitais: Olhares afrodiaspóricos* Organização e Edição: Tarcízio Silva; Revisão Ortográfica: Toni C.; Demetrios dos Santos Ferreira; Tarcízio Silva; Gabriela Porfírio; Taís Oliveira; Tradução: Vinícius Silva; Tarcízio Silva; Ilustração de Capa: Isabella Bispo; Diagramação: Yuri Amaral; Consultoria Editorial: LiteraRUA – São Paulo, 2020.

STOLCKE, Verena (1991). “*Sexo está para gênero assim como raça para etnicidade?*”. Estudos Afro-Asiáticos, n. 20, pp.101-119

RAJI, Inioluwa Deborah. *Handle with Care: Lessons for Data Science from Black Female Scholars*. OPINION| VOLUME 1, ISSUE 8, 100150, NOVEMBER 13, 2020.