A ILUSÃO DA NEUTRALIDADE ALGORÍTMICA: INTELIGÊNCIA ARTIFICIAL E VIESES OCULTOS NA GESTÃO DE PESSOAS

THE ILLUSION OF ALGORITHMIC NEUTRALITY: ARTIFICIAL INTELLIGENCE AND HIDDEN BIASES IN PEOPLE MANAGEMENT

TATIANE RODRIGUES RODA
UNINOVE – UNIVERSIDADE NOVE DE JULHO

Comunicação:
O XIV SINGEP foi realizado em conjunto com a 14th Conferência Internacional do CIK (CYRUS Institute of Knowledge) e com a SPARK (Society for Promoting Academic Research and Knowledge), em formato híbrido, com sede presencial na UNINOVE - Universidade Nove de Julho, no Brasil.

Agradecimento à orgão de fomento:
Agradecemos ao Prof. Leonardo Vils, tutor do grupo PET-ADI, pela orientação; ao Programa de Educação Tutorial (PET), pelo apoio institucional e financeiro; e à Universidade Nove de Julho (UNINOVE), pelo suporte à participação neste evento.

A ILUSÃO DA NEUTRALIDADE ALGORÍTMICA: INTELIGÊNCIA ARTIFICIAL E VIESES OCULTOS NA GESTÃO DE PESSOAS

Objetivo do estudo
Analisar de que maneira a aparência de neutralidade dos sistemas algorítmicos de recrutamento pode ocultar sua participação no exercício do poder diretivo do empregador, examinando as consequências dessa relação para a responsabilização organizacional e para a comprovação da discriminação algorítmica pelo candidato.

Relevância/originalidade
O estudo desloca o debate da correção técnica do viés para a responsabilização jurídico-organizacional, propondo a leitura do algoritmo de recrutamento como extensão do poder diretivo do empregador abordagem pouco explorada na literatura brasileira sobre inteligência artificial na gestão de pessoas.

Metodologia/abordagem
Pesquisa de abordagem qualitativa, desenvolvida por meio de procedimentos bibliográficos e documentais, articulando legislação brasileira, doutrina e literatura técnica sobre viés algorítmico e casos emblemáticos documentados, tratados como evidência qualitativa de mecanismos de produção e ocultação de viés em sistemas de recrutamento

Principais resultados
Constatou-se que vieses históricos entram no sistema por meio de variáveis aparentemente neutras (proxies), que a automação não retira a decisão da esfera organizacional, e que a opacidade algorítmica impõe ao candidato dificuldade estrutural de prova, parcialmente mitigável pela legislação vigente.

Contribuições teóricas/metodológicas
O artigo contribui ao articular o poder diretivo do empregador (art. 2º, CLT) com a responsabilidade objetiva por delegação de função (arts. 932-933, CC), e ao aplicar o conceito de interseccionalidade de Crenshaw à discriminação algorítmica no recrutamento.

Contribuições sociais/para a gestão
Para a prática de Gestão de Pessoas, o artigo propõe parâmetros de governança algorítmica, questionamento de fornecedores, documentação de critérios, auditoria periódica e supervisão humana efetiva, capazes de prevenir discriminação e mitigar risco de passivo trabalhista antes da ocorrência do dano.

Palavras-chave: Discriminação Algorítmica, Viés Algorítmico, Poder Diretivo do Empregador, Responsabilidade Civil, Recrutamento e Seleção

THE ILLUSION OF ALGORITHMIC NEUTRALITY: ARTIFICIAL INTELLIGENCE AND HIDDEN BIASES IN PEOPLE MANAGEMENT

Study purpose
To analyze how the appearance of neutrality in algorithmic recruitment systems may conceal their role in exercising the employer's directive power, examining the consequences of this relationship for organizational accountability and for proving algorithmic discrimination by the candidate.

Relevance / originality
This study shifts the debate from technical bias correction toward legal-organizational accountability, proposing that recruitment algorithms be read as an extension of the employer's directive power, an approach still underexplored in Brazilian literature on artificial intelligence in people management.

Methodology / approach
Qualitative research based on bibliographic and documentary procedures, articulating Brazilian legislation, doctrine and technical literature on algorithmic bias, and emblematic documented cases, treated as qualitative evidence of mechanisms of bias production and concealment in recruitment systems.

Main results
Findings show that historical biases enter systems through apparently neutral variables (proxies), that automation does not remove decisions from the organizational sphere, and that algorithmic opacity imposes structural evidentiary difficulty on candidates, partially mitigated by current legislation.

Theoretical / methodological contributions
The article contributes by articulating the employer's directive power (art. 2, CLT) with strict liability for delegated functions (arts. 932-933, Civil Code), and by applying Crenshaw's intersectionality concept to algorithmic discrimination in recruitment.

Social / management contributions
For Human Resources practice, the article proposes algorithmic governance parameters — questioning vendors, documenting criteria, periodic auditing and effective human oversight — capable of preventing discrimination and mitigating labor-law liability risk before harm occurs

Keywords: Algorithmic Discrimination, Algorithmic Bias, Employer's Directive Power, Civil Liability, Recruitment and Selection

A ILUSÃO DA NEUTRALIDADE ALGORÍTMICA
INTELIGÊNCIA ARTIFICIAL E VIESES OCULTOS NA GESTÃO DE PESSOAS

1 Introdução

E se a máquina que decide quem merece uma vaga de emprego já tiver aprendido, desde o início, que certos corpos valem menos?

Em 2018, a Amazon confirmou publicamente algo que muitas empresas hoje preferem não verificar, ou nem sabem como: um sistema interno de triagem de currículos, usado por quatro anos, penalizava candidatas do sexo feminino de forma sistemática, descartando currículos com a palavra "mulheres" e rebaixando formandas de faculdades exclusivamente femininas (Dastin, 2018). O sistema havia aprendido a partir de uma década de contratações anteriores da própria empresa, período em que os homens predominavam entre os profissionais contratados. Não foi necessário programar uma regra dizendo que mulheres deveriam receber pontuação inferior. O sistema aprendeu esse padrão a partir dos dados que recebeu.

O caso da Amazon tornou-se um dos exemplos mais conhecidos de um problema que acompanha o uso crescente da inteligência artificial na Gestão de Pessoas, a chamada neutralidade algorítmica. Ferramentas utilizadas em recrutamento e seleção são frequentemente apresentadas como capazes de tornar decisões mais objetivas e reduzir os vieses conscientes e inconscientes presentes na avaliação humana. Entretanto, transferir uma decisão para um sistema automatizado não significa, por si só, eliminar os preconceitos existentes no processo de seleção.

Essa questão se torna ainda mais relevante quando se observa como esses sistemas são construídos. Algoritmos são desenvolvidos por pessoas, alimentados por dados produzidos em determinados contextos sociais e ajustados de acordo com critérios definidos pelas organizações que os utilizam. Quando os dados de treinamento registram desigualdades construídas historicamente, essas desigualdades também podem ser incorporadas aos padrões identificados pelo sistema (O'Neil, 2016; Crawford, 2021). Nesse sentido, Silva, Luz e Rosa (2026) chamam atenção para o risco de atribuir à racionalidade das máquinas uma neutralidade que não necessariamente existe.

No Brasil, essa discussão encontra um mercado de trabalho historicamente marcado por desigualdades de gênero e raça. Mulheres negras, em especial, permanecem concentradas em posições de menor remuneração, prestígio e estabilidade no mercado formal (Viana, 2025). Isso significa que os dados utilizados para ensinar uma ferramenta a reconhecer o que seria um candidato “adequado”, “bem-sucedido” ou “compatível” não surgem em um espaço neutro: eles carregam consigo as características do mercado de trabalho que os produziu.

Os vieses, além disso, nem sempre aparecem de forma explícita. Um sistema de recrutamento não precisa perguntar a raça ou o gênero de uma pessoa para produzir resultados desiguais. Critérios aparentemente neutros podem funcionar como filtros indiretos. A penalização de longos períodos sem vínculo profissional, por exemplo, pode atingir com maior intensidade pessoas que interromperam a carreira para exercer atividades de cuidado. Da mesma forma, utilizar o CEP como critério de proximidade pode reproduzir desigualdades territoriais e socioeconômicas existentes nas cidades brasileiras.

Isoladamente, esses critérios parecem objetivos. Todavia, se observados dentro de uma estrutura social desigual, seus efeitos podem ser diferentes entre os grupos avaliados, nenhum dos dois critérios menciona gênero ou raça, mas produzem o mesmo efeito. É esse mecanismo que dá à decisão automatizada a aparência de resultado objetivo e, por isso, inquestionável.

É justamente nesse ponto que a neutralidade algorítmica precisa ser questionada. A decisão automatizada pode assumir aparência de precisão matemática ao mesmo tempo em que reproduz critérios, escolhas e desigualdades anteriores à própria tecnologia. O risco não está

apenas na existência do viés, mas também na dificuldade de percebê-lo quando ele deixa de parecer como escolha humana e passa a ser apresentado como resultado técnico.

O objetivo deste estudo é analisar de que maneira a aparência de neutralidade dos sistemas algorítmicos de recrutamento pode ocultar sua participação no exercício do poder diretivo do empregador. A partir daí, examinam-se as consequências dessa relação para a responsabilização das organizações e para a comprovação da discriminação algorítmica pelo candidato, à luz da Constituição Federal, da CLT, da Lei nº 9.029/1995 e da Lei Geral de Proteção de Dados.

De forma específica, busca-se: (a) identificar os mecanismos pelos quais vieses históricos e sociais são incorporados e ocultados em sistemas de IA usados em processos de recrutamento e seleção; e (b) analisar esses sistemas à luz do poder diretivo do empregador, discutindo em que medida a decisão algorítmica pode ser compreendida como manifestação da própria atuação organizacional. Complementarmente, pretende-se: (c) examinar os obstáculos que a opacidade algorítmica impõe à identificação e comprovação de práticas discriminatórias pelo candidato; e (d) discutir os parâmetros jurídicos existentes para a responsabilização das organizações e para a adoção de mecanismos de transparência, supervisão e prevenção da discriminação algorítmica.

2 Referencial Teórico

2.1 A neutralidade algorítmica como construção: dados, poder e desigualdade

Chamar um algoritmo de "neutro" pressupõe que ele exista fora de qualquer contexto, como se fosse possível separar o cálculo da decisão de quem o programou, de quem definiu suas variáveis e de quem escolheu o que contava como sucesso. O'Neil (2016) descreve esse tipo de sistema como uma arma de destruição matemática quando reúne três características: opacidade, escala e potencial de dano. Um algoritmo de recrutamento cumpre as três. Ele opera sem que o candidato saiba os critérios reais de avaliação, aplica a mesma lógica a milhares de currículos simultaneamente e, quando erra, o erro se multiplica em vez de se corrigir. Crawford (2021) vai num sentido parecido: para a autora, sistemas de inteligência artificial são estruturas materiais, construídas com trabalho humano, recursos concretos e escolhas políticas. A abstração técnica é a fachada; a produção é bem concreta.

A construção dessa neutralidade tem mecanismo identificável, não é só efeito de discurso. Fernandes e Graglia (2024) trazem o caso do sistema COMPAS, usado por tribunais norte-americanos para prever reincidência criminal e investigado pela ProPublica: taxa de acerto de apenas 20% em crimes violentos, com réus negros duas vezes mais propensos a ser classificados incorretamente como alto risco (Larson et al.,2016). O interesse do caso aqui não está no tema penal. Está no mecanismo: a ausência de uma variável sensível no código não impede que o resultado a reproduza, porque essa variável já está embutida em outras, aparentemente neutras, que funcionam como seu substituto estatístico. Esse mecanismo, não a intenção de quem programa, é o que sustenta a ilusão de neutralidade discutida neste artigo.

2.2 Dados históricos e a reprodução automatizada de desigualdades

Se a seção anterior explicou por que o algoritmo não é neutro, esta mostra como a desigualdade entra no sistema. O mecanismo central é a aprendizagem supervisionada: o algoritmo recebe exemplos do passado, currículos aprovados, perfis contratados e avaliações de desempenho e aprende a reproduzir os padrões que levaram a esses resultados. Quando o histórico de contratações de uma empresa é majoritariamente masculino, como ocorreu no caso da Amazon já mencionado, o sistema não apenas registra esse padrão. Ele o transforma em

critério para decisões futuras, tratando a baixa presença histórica de mulheres como sinal de menor adequação das candidatas.

Há um ponto que o caso Amazon sozinho não deixa tão claro: esse processo tende à amplificação, não só à repetição. Zhao et al. (2017) mostram isso com precisão: em seu estudo, a atividade "cozinhar" já aparecia associada a mulheres 33% mais do que a homens no conjunto de dados de treinamento, e, depois de treinado, o modelo ampliava essa disparidade para 68%. O algoritmo funciona, nesse sentido, menos como espelho do passado e mais como lente: aumenta a distorção que já estava lá. Para a gestão de pessoas isso pesa na prática. Um processo seletivo automatizado herda o viés histórico da organização e tende a agravá-lo a cada novo ciclo, porque os próprios resultados do sistema realimentam as bases de dados futuras.

2.3 Desigualdades estruturais de gênero e raça no mercado de trabalho brasileiro

No Brasil, a discussão sobre dados de treinamento ganha contornos concretos. A desigualdade que pode alimentar esses sistemas tem raízes históricas identificáveis e efeitos ainda perceptíveis no mercado de trabalho. Viana (2025) descreve como mulheres negras permanecem concentradas em posições de menor remuneração, menor prestígio e menor estabilidade. Trata-se de uma trajetória de exclusão construída ao longo do tempo, atravessada pelo período escravocrata, pela industrialização tardia do país e por condições historicamente desiguais de acesso à educação e ao emprego.

Esse contexto importa porque os dados utilizados por sistemas de recrutamento não surgem em um espaço neutro. Quando uma ferramenta é treinada a partir de históricos de contratação, perfis profissionais ou padrões de desempenho construídos nesse mercado, ela pode aprender também as desigualdades presentes nesses registros. O que antes aparecia como resultado de escolhas e estruturas sociais passa, então, a ser traduzido em correlações, pontuações e critérios de seleção. A desigualdade não precisa estar escrita no código para participar da decisão: muitas vezes, ela já está registrada nos dados que ensinam o sistema a reconhecer quem parece mais adequado para uma vaga.

2.4 Interseccionalidade e discriminação algorítmica

A pesquisa de Buolamwini e Gebru (2018), conhecida como *Gender Shades*, ajuda a compreender por que a interseccionalidade importa para a análise desenvolvida neste artigo. As autoras avaliaram três sistemas comerciais de classificação de gênero a partir de imagens faciais, utilizando a escala Fitzpatrick para classificar o tipo de pele, e não categorias raciais autodeclaradas. Os resultados mostraram taxas de erro de até 34,7% para mulheres de pele mais escura, enquanto, entre homens de pele mais clara, o erro máximo observado foi de 0,8%. A diferença não é pequena: no pior desempenho observado entre os grupos, a taxa de erro foi mais de quarenta vezes superior. Embora a classificação utilizada no estudo seja fenotípica, e não racial em sentido estrito, seus resultados oferecem uma evidência importante sobre como diferentes características podem se combinar e produzir desempenhos profundamente desiguais em sistemas automatizados.

É justamente esse tipo de sobreposição que a interseccionalidade permite enxergar. Crenshaw (1989, 1991) desenvolveu o conceito para questionar análises que tratavam raça e gênero como categorias isoladas e mutuamente excludentes. Em sua conhecida metáfora do cruzamento, diferentes formas de discriminação podem vir de direções distintas e se encontrar sobre a mesma pessoa, produzindo uma experiência que não pode ser compreendida pela análise de apenas um dos eixos. Uma mulher negra, portanto, não vivencia necessariamente uma simples soma entre discriminação racial e discriminação de gênero, mas uma forma específica de desigualdade produzida pela interação entre ambas.

Essa perspectiva também é retomada no contexto brasileiro por Stelzer e Kyrillos (2021), que destacam os limites das análises baseadas em um único eixo e a consequente invisibilização de experiências específicas de discriminação. A abordagem interseccional permite, nesse sentido, observar não apenas a presença de diferentes categorias sociais, mas a maneira como elas interagem e produzem condições distintas de vulnerabilidade.

Para os sistemas de inteligência artificial, essa diferença não é apenas teórica. Avaliações realizadas exclusivamente a partir de categorias amplas podem esconder justamente os grupos sobre os quais o sistema apresenta seu pior desempenho. Um modelo pode apresentar resultados considerados satisfatórios quando homens e mulheres são observados de maneira agregada e revelar uma distribuição muito diferente de erros quando gênero e tipo de pele são analisados conjuntamente. Foi esse ponto que *Gender Shades* tornou particularmente visível: as maiores taxas de erro estavam concentradas na combinação entre gênero feminino e pele mais escura.

Crenshaw (1989) já havia identificado um problema semelhante décadas antes da atual disseminação de sistemas algorítmicos de decisão. Em *DeGraffenreid v. General Motors* (1976), cinco mulheres negras questionaram práticas de contratação da empresa alegando discriminação. A análise separada das categorias dificultou o reconhecimento da experiência específica narrada pelas autoras: a existência de mulheres brancas entre os empregados enfraquecia a alegação de discriminação baseada apenas no gênero, enquanto a experiência dos homens negros não correspondia àquela vivenciada pelas mulheres negras. O problema estava justamente no espaço entre as categorias, onde a discriminação sofrida por aquelas trabalhadoras deixava de ser adequadamente enxergada.

Há uma continuidade importante entre esse caso e o problema hoje enfrentado pelos sistemas automatizados: aquilo que não é colocado como categoria de análise corre o risco de desaparecer na média. Quando uma auditoria observa apenas gênero ou apenas raça, pode deixar de perceber que determinados grupos enfrentam resultados distintos justamente na interseção desses marcadores.

Para este artigo, portanto, a interseccionalidade cumpre uma função precisa. Ela impede que a crítica à neutralidade algorítmica permaneça abstrata e permite investigar não apenas se determinado sistema produz resultados desiguais, mas sobre quem esses resultados recaem e de que maneira diferentes marcadores sociais interferem nessa distribuição. O ponto cego, nesse sentido, não nasceu com a tecnologia. Sistemas algorítmicos podem reproduzir uma dificuldade que o próprio Direito já demonstrava décadas antes: reconhecer danos que não se apresentam dentro de categorias isoladas.

3 Metodologia

Adota-se pesquisa de abordagem qualitativa, desenvolvida por meio de procedimentos bibliográficos e documentais. Trata-se de delineamento coerente com o problema de pesquisa: compreender como a aparência de neutralidade dos algoritmos de recrutamento oculta sua inserção no poder diretivo do empregador é uma questão teórico-normativa, que demanda articulação entre literatura técnica sobre inteligência artificial, doutrina jurídica e casos documentados.

O corpus reúne três tipos de fonte. Primeiro, legislação, cada qual cumprindo função distinta na análise: a Constituição Federal fornece o fundamento principiológico, igualdade e dignidade da pessoa humana; a CLT delimita o vínculo empregatício e o poder diretivo do empregador; a Lei nº 9.029/1995 proíbe expressamente práticas discriminatórias e limitativas para acesso à relação de trabalho; e a Lei Geral de Proteção de Dados rege o tratamento de dados pessoais e as decisões automatizadas, sendo por isso central à discussão sobre opacidade algorítmica e direito à revisão. Segundo, doutrina e literatura técnica sobre viés algorítmico,

neutralidade tecnológica e interseccionalidade, priorizando, sempre que possível, fontes primárias em vez de citação de segunda mão, optou-se por consultar diretamente o texto de Crenshaw (1989, 1991), publicação original em que a autora formula a crítica à abordagem antidiscriminatória de eixo único e desenvolve, na sequência, a perspectiva interseccional, bem como o relatório metodológico de Larson et al. (2016) sobre o sistema COMPAS. Terceiro, casos emblemáticos amplamente documentados e verificáveis, o sistema de triagem de currículos descontinuado pela Amazon (Dastin, 2018), o sistema COMPAS de previsão de reincidência criminal (Larson et al., 2016) e a auditoria *Gender Shades* de sistemas de reconhecimento facial (Buolamwini & Gebru, 2018), tratados não como amostra estatística, mas como evidência qualitativa de mecanismos de produção de viés já descritos na literatura.

A análise articula essas três fontes de forma crítico-interpretativa: os casos documentados evidenciam como o viés opera na prática; a literatura técnica explica os mecanismos que o produzem; a legislação e a doutrina fundamentam a leitura do algoritmo como extensão do poder diretivo do empregador e discutem os limites da responsabilização organizacional.

Por seu delineamento bibliográfico-documental, esta pesquisa não pretende produzir dados primários. A agenda de pesquisa futura, retomada nas considerações finais, aponta a investigação empírica com profissionais de Recursos Humanos, Direito e Psicologia Organizacional como etapa subsequente, voltada a testar e refinar, a partir da prática profissional, os argumentos aqui sustentados por via doutrinária e documental.

4 Análise e Discussão

4.1 Quando o passado se torna critério de seleção: como os vieses entram nos sistemas de recrutamento

O caso Amazon, já mencionado na introdução, merece ser retomado aqui com mais detalhe técnico, porque ele mostra exatamente o mecanismo que esta seção quer explicar. O sistema não recebia instrução para preferir homens. Recebia uma tarefa mais simples: aprender, a partir de dez anos de contratações da empresa, o que diferenciava um currículo "bom" de um currículo comum, e pontuar cada novo candidato de um a cinco, como se fossem produtos avaliados por estrelas. O problema é que, entre os contratados dessa década, homens eram amplamente maioria. O sistema aprendeu, então, que certas palavras associadas a candidatas mulheres, como "women's", em "women's chess club captain", indicavam menor qualidade. E aprendeu o oposto: verbos como "executed" e "captured", comuns em currículos de engenheiros homens, passaram a pesar a favor.

Nenhuma dessas palavras diz respeito a competência técnica. Nenhuma delas foi escolhida por um programador como critério de exclusão. Elas emergiram porque o sistema fazia exatamente o que foi treinado para fazer: encontrar o padrão estatístico que separava quem tinha sido contratado de quem não tinha. Quando esse padrão histórico reflete desigualdade, o sistema não identifica a desigualdade como problema, identifica-a como sinal.

Esse é o mecanismo central que atravessa qualquer sistema de recrutamento baseado em aprendizagem supervisionada: alguém precisa definir o que conta como "sucesso" para treinar o modelo, e essa definição quase sempre vem do próprio histórico de contratação, promoção ou avaliação de desempenho da organização. Se os contratados de sucesso do passado foram, em sua maioria, de um determinado perfil, o sistema aprende que esse perfil prediz sucesso futuro, não porque exista relação causal entre o perfil e a competência, mas porque essa foi a única relação que os dados continham. Um sistema de recrutamento não reproduz o mercado de trabalho como ele é. Reproduz o mercado de trabalho como a organização o construiu até ali,

com todos os filtros, formais e informais, intencionais e não, que moldaram quem chegou a ser contratado.

4.2 Proxies algorítmicos e a invisibilidade da discriminação

Nenhum sistema de recrutamento sério pergunta a raça ou o gênero do candidato, a maioria, hoje, nem coleta esse dado. Isso costuma ser apresentado como garantia de neutralidade: se a variável sensível não entra no cálculo, o resultado não pode discriminar por ela. O raciocínio tem um problema. Variáveis aparentemente neutras, como CEP, tempo de intervalo entre empregos, instituição de ensino, até o vocabulário usado no currículo, carregam, estatisticamente, boa parte da informação que a variável sensível carregaria. Chamam-se proxies, substitutos indiretos que permitem ao sistema reconstruir o que foi removido, sem nunca precisar nomeá-lo.

O sistema COMPAS, discutido na seção 2.1, ilustra isso com precisão. O algoritmo nunca recebe a raça do réu como dado de entrada. E, ainda assim, produz disparidade racial consistente em seus escores. Isso acontece porque outras variáveis do questionário, bairro de residência, histórico criminal de familiares, idade da primeira detenção, funcionam, na prática, como aproximações estatísticas da raça, dentro de um sistema de justiça criminal já marcado por desigualdade racial na aplicação da lei. Remover a variável explícita não removeu o padrão, apenas o deslocou para outro lugar.

No recrutamento, o mesmo mecanismo aparece sob outras formas. A universidade de origem funciona como proxy socioeconômico e, no Brasil, também racial, o acesso a instituições de elite segue distribuído de forma desigual entre grupos raciais, herança direta das desigualdades educacionais discutidas na seção 2.3. Ferramentas de triagem por vídeo, que avaliam padrão de fala, expressão facial ou tom de voz para inferir "adequação cultural", correm o risco de penalizar sotaques regionais, formas de comunicação associadas a determinados grupos e até características neurodivergentes, sem que a ferramenta em nenhum momento avalie raça, classe ou neurodivergência diretamente.

O efeito prático disso é que a discriminação por proxy passa despercebida exatamente onde alguém procuraria por ela. Uma auditoria que verifica se o sistema usa variáveis sensíveis como entrada vai concluir, corretamente, que não usa e vai errar ao concluir, a partir disso, que o sistema é neutro. A ausência formal de uma variável sensível, portanto, não basta para assegurar neutralidade. É preciso observar se a combinação de critérios aparentemente neutros permite inferir, ainda que indiretamente, características protegidas e reproduzir os mesmos efeitos discriminatórios.

4.3 O contexto brasileiro como amplificador do viés algorítmico

A seção 2.3 demonstrou que o mercado de trabalho brasileiro é atravessado por desigualdades estruturais de gênero e raça e que essas desigualdades podem alcançar os dados utilizados por sistemas de recrutamento. O contexto brasileiro, porém, acrescenta outros elementos ao problema. Não porque o viés algorítmico seja exclusivamente nacional, mas porque as condições para identificá-lo, questioná-lo e contê-lo ainda são limitadas.

Estudo anterior sobre o tema no contexto brasileiro (Cheong, 2025) já identificou, a partir da percepção de profissionais de RH, a tensão entre eficiência e viés no uso de sistemas de recrutamento automatizado, com enfoque predominantemente operacional. Este artigo desloca o eixo da discussão para a responsabilização jurídica organizacional, examinando especificamente as condições regulatórias e estruturais que amplificam esse risco no Brasil.

Uma primeira diferença aparece no campo regulatório. Algumas jurisdições já estabeleceram mecanismos específicos de controle para ferramentas automatizadas utilizadas

em decisões de emprego. Na cidade de Nova York, a Local Law 144 condiciona o uso de determinadas ferramentas automatizadas de decisão à realização periódica de auditoria de viés por auditor independente, além de exigir a divulgação de seus resultados e a comunicação aos candidatos ou empregados afetados. No Brasil, embora já existam normas de proteção contra discriminação e regras aplicáveis ao tratamento automatizado de dados, ainda não há mecanismo federal equivalente de auditoria prévia e independente voltado especificamente aos sistemas utilizados em processos seletivos. O PL nº 2.338/2023, que pretende estabelecer um marco regulatório para a inteligência artificial, permanece em tramitação na Câmara dos Deputados.

Essa diferença não significa que as decisões automatizadas estejam fora do alcance do Direito brasileiro. A Constituição Federal, a legislação trabalhista e a Lei nº 9.029/1995 oferecem proteção contra práticas discriminatórias no acesso ao trabalho, enquanto a LGPD estabelece direitos relacionados ao tratamento de dados e às decisões automatizadas. A dificuldade está em outro ponto: entre reconhecer juridicamente que a discriminação é proibida e conseguir verificar como ela foi produzida por um sistema opaco existe uma distância considerável.

Essa distância também aparece dentro das organizações. Sistemas de recrutamento podem ser contratados como soluções prontas, desenvolvidas por fornecedores externos, sem que a equipe responsável pela seleção tenha acesso ao funcionamento interno do modelo ou conhecimento técnico suficiente para compreender como cada variável interfere no resultado. Nessas situações, o profissional de Gestão de Pessoas recebe uma classificação, uma pontuação ou uma recomendação e precisa incorporá-la ao processo seletivo sem necessariamente conhecer todo o caminho percorrido pelo sistema até chegar àquele resultado.

O problema deixa, então, de ser exclusivamente tecnológico. Não é razoável esperar que cada profissional de Recursos Humanos seja capaz de auditar um modelo de inteligência artificial, assim como também não parece suficiente aceitar uma recomendação automatizada apenas porque ela foi produzida por uma ferramenta especializada. Entre esses dois extremos surge uma questão de governança: quem deve garantir que o sistema utilizado pela organização foi efetivamente testado quanto aos riscos de discriminação?

É nesse ponto que o contexto brasileiro pode ampliar os efeitos da opacidade algorítmica. As desigualdades que alimentam determinados dados não são produzidas pela tecnologia, e a ausência de uma regra específica de auditoria também não cria, por si só, o viés. O que essa combinação pode produzir é um ambiente em que distorções já existentes encontram menos barreiras para serem identificadas antes de alcançarem uma decisão de contratação. O viés nasce antes do algoritmo; a falta de mecanismos de verificação pode permitir que ele atravesse o processo seletivo com aparência de decisão técnica.

4.4 O algoritmo como extensão do poder diretivo e da decisão organizacional

Quando uma empresa abre uma vaga, várias escolhas já foram feitas antes mesmo de o primeiro currículo chegar: qual perfil se procura, quais experiências serão valorizadas, o que será considerado compatível com a vaga e quais características podem eliminar um candidato. Essas escolhas integram o poder diretivo do empregador, fundado no art. 2º da CLT, que atribui a quem admite, assalaria e dirige a prestação de serviços a organização da atividade econômica, inclusive a definição de quem terá acesso a ela. A inteligência artificial não surge fora desse processo. Ela entra justamente para organizar, acelerar ou automatizar parte dessas escolhas.

Por isso, talvez o ponto mais importante não seja perguntar se foi uma pessoa ou um algoritmo que tomou determinada decisão, mas entender como aquela decisão passou a fazer parte do processo de seleção da organização. Um sistema pode classificar currículos, atribuir pontuações, criar rankings ou indicar quais candidatos devem seguir para a próxima etapa.

Ainda assim, é a empresa que escolhe utilizar a ferramenta e que decide quanto peso dará ao resultado produzido por ela.

Essa diferença é importante porque a automação pode criar uma espécie de distanciamento. Quando um recrutador elimina diretamente um candidato, a decisão é facilmente percebida como parte da atuação da empresa. Quando a exclusão aparece como uma pontuação baixa ou como recomendação de um sistema, existe a tendência de enxergá-la como resultado técnico, quase independente de quem conduz o processo. É justamente aí que a aparência de neutralidade, discutida na seção 2.1, volta a aparecer, agora não mais como conceito teórico, mas como mecanismo concreto de diluição da responsabilidade.

Os arts. 932, III, e 933 do Código Civil oferecem uma referência útil para pensar esse deslocamento, ainda que não se pretenda equiparar juridicamente o algoritmo a um preposto, a ferramenta não é sujeito de direito e não pratica conduta própria. O que interessa é a lógica de responsabilização que esses dispositivos revelam que o ordenamento já admite que delegar a execução de uma função não é suficiente para transferir, para fora da organização, a responsabilidade pelos efeitos que essa função produz. Mesmo quando o sistema foi desenvolvido por um fornecedor externo, é a organização empregadora que o escolhe, o incorpora ao processo seletivo e decide que peso dar ao resultado. A LGPD reforça essa leitura ao reconhecer, no art. 20, a possibilidade de que decisões automatizadas definam perfis profissionais — e ao assegurar ao titular instrumentos para questioná-las, pressupondo que exista, do outro lado, alguém responsável a quem essa pergunta possa ser dirigida.

O problema se torna ainda mais delicado quando nem mesmo os profissionais responsáveis pelo recrutamento conhecem com clareza os critérios utilizados pelo sistema. Uma ferramenta pode entregar uma lista de candidatos classificados como mais aderentes à vaga sem explicar, de maneira compreensível, quais informações tiveram maior peso naquele resultado. Nesse cenário, o profissional de Gestão de Pessoas corre o risco de deixar de analisar criticamente a recomendação e passar apenas a operacionalizá-la.

Não se trata de exigir que profissionais de RH compreendam a programação interna de cada sistema. Trata-se de reconhecer que utilizar uma ferramenta automatizada não elimina a necessidade de questionar o que ela produz. Se determinados grupos são constantemente eliminados, se certos critérios geram resultados desproporcionais ou se ninguém consegue explicar por que um candidato recebeu determinada pontuação, a resposta não pode ser apenas que "foi o algoritmo".

É nesse sentido que este artigo compreende o algoritmo como extensão do poder diretivo do empregador e, por consequência, da própria decisão organizacional: a tecnologia modifica a forma como a escolha é realizada, mas não a torna neutra nem independente de quem a utiliza.

E essa constatação conduz a uma questão ainda mais difícil: se o candidato não conhece os critérios utilizados pelo sistema e, muitas vezes, nem sabe que foi eliminado por uma decisão automatizada, como poderá identificar que sofreu discriminação? É essa relação entre opacidade e dificuldade de comprovação que a seção seguinte discute.

4.5 Opacidade algorítmica e a dificuldade de prova da discriminação

Reconhecer que a decisão automatizada continua ligada à organização que utiliza o sistema resolve apenas uma parte do problema. Resta uma questão talvez ainda mais difícil: como o candidato demonstra que aquela decisão foi discriminatória se não conhece os critérios que levaram à sua exclusão?

A discriminação em processos seletivos sempre apresentou dificuldades de prova. Comentários, mensagens, testemunhas, comparação entre candidatos ou a repetição de determinado comportamento podem, em algumas situações, ajudar a reconstruir o que aconteceu. No recrutamento automatizado, porém, surge uma dificuldade adicional: parte do

caminho que levou à decisão pode estar registrada apenas dentro do próprio sistema. O candidato recebe uma resposta simples, "não classificado", "perfil incompatível" ou apenas o encerramento de sua participação, sem necessariamente saber quais informações foram consideradas, que peso receberam ou por que seu perfil foi colocado abaixo de outro.

É nessa diferença que a opacidade deixa de ser apenas uma característica técnica e passa a produzir consequência concreta. Para questionar uma possível discriminação, o candidato precisa primeiro perceber que ela existiu. Depois, precisa compreender quais critérios foram utilizados. E, por fim, precisa ter acesso a elementos suficientes para demonstrar que esses critérios produziram tratamento desigual. Viana (2025), ao discutir as dificuldades probatórias da discriminação algorítmica, chama atenção justamente para essa assimetria: quem sofre os efeitos da decisão nem sempre consegue enxergar a lógica que a produziu.

A situação pode se tornar ainda mais complexa quando o sistema é fornecido por uma empresa externa. Nesse caso, nem sempre todas as informações sobre o funcionamento da ferramenta estão disponíveis para quem conduz diretamente o recrutamento. Podem existir limites técnicos, contratuais e comerciais para o acesso ao modelo. O problema, portanto, não está apenas na distância entre candidato e algoritmo, mas também na quantidade de agentes que podem existir entre quem sofreu a decisão e quem conhece efetivamente como ela foi construída.

A LGPD oferece instrumentos importantes para enfrentar parte dessa opacidade. O art. 20 assegura ao titular o direito de solicitar revisão de decisões tomadas unicamente com base em tratamento automatizado que afetem seus interesses, inclusive aquelas destinadas à definição de perfil profissional. O controlador também deve fornecer, quando solicitado, informações claras e adequadas sobre os critérios e procedimentos utilizados na decisão, observados os segredos comercial e industrial. Caso essas informações não sejam fornecidas com fundamento nesse sigilo, a própria lei prevê a possibilidade de auditoria pela Autoridade Nacional de Proteção de Dados para verificar aspectos discriminatórios do tratamento automatizado.

Além da via regulatória aberta pela LGPD, o processo do trabalho oferece um instrumento próprio para lidar com essa assimetria: o art. 818, §1º, da CLT permite ao juiz atribuir o ônus da prova de modo diverso da regra geral quando há impossibilidade ou excessiva dificuldade de uma das partes cumprir seu encargo probatório, ou maior facilidade da parte contrária em produzir a prova do fato oposto. O caso da discriminação algorítmica preenche esse critério com precisão: o candidato enfrenta dificuldade estrutural para demonstrar como o sistema chegou à decisão que o prejudicou, enquanto o empregador, por ter escolhido e contratado a ferramenta, está em posição mais favorável para produzir essa prova, ainda que precise requisitá-la do fornecedor. Combinada à responsabilidade objetiva discutida na seção 4.4, essa possibilidade desloca o peso da demonstração de quem menos tem acesso à informação para quem mais tem controle sobre ela.

4.6 Responsabilização organizacional e governança algorítmica na Gestão de Pessoas

As duas seções anteriores olharam principalmente para o problema depois que a decisão discriminatória já aconteceu: de que forma essa decisão permanece vinculada à organização e quais obstáculos o candidato enfrenta para compreendê-la e questioná-la. Para a Gestão de Pessoas, porém, existe uma pergunta anterior e talvez ainda mais importante: o que pode ser feito antes que o dano aconteça? Se sistemas automatizados passam a participar das decisões de recrutamento, acompanhar e questionar seu funcionamento não deveria ser uma tarefa periférica da organização, mas parte do modo responsável de utilizá-los.

O primeiro momento de prevenção começa antes mesmo de o sistema analisar um currículo: na escolha da ferramenta. Quando uma organização contrata uma solução

desenvolvida por fornecedor externo, não precisa conhecer cada linha de programação para fazer perguntas importantes. Com quais tipos de dados o sistema foi desenvolvido ou treinado? Já foi submetido a alguma avaliação de viés? Os critérios utilizados para classificar candidatos podem ser explicados de maneira compreensível? Há documentação sobre limitações conhecidas do modelo? Existe possibilidade de revisão das decisões produzidas? Essas perguntas não transformam o profissional de Recursos Humanos em especialista em inteligência artificial; apenas reconhecem que contratar uma tecnologia que participa da seleção de pessoas exige critérios diferentes daqueles utilizados na aquisição de uma ferramenta meramente operacional.

O segundo ponto está dentro da própria organização. A ausência de uma exigência regulatória específica de auditoria, discutida na seção 4.3, não impede que empresas estabeleçam seus próprios mecanismos de acompanhamento. Documentar os critérios utilizados no processo seletivo, registrar quando sistemas automatizados participam da decisão e observar periodicamente os resultados produzidos pode ajudar a identificar padrões que passariam despercebidos em análises individuais. Se determinado grupo aparece repetidamente entre os candidatos eliminados ou se uma ferramenta produz diferenças que a equipe não consegue explicar, isso deveria ser motivo para investigação, e não apenas um dado aceito porque foi produzido por um sistema.

Esse acompanhamento não significa que profissionais de Gestão de Pessoas devam realizar sozinhos auditorias técnicas complexas. Dependendo da ferramenta, essa análise pode exigir profissionais especializados ou mesmo auditoria externa. O papel do RH está, antes, em não tratar o resultado automatizado como resposta definitiva e em exigir que a organização consiga compreender, questionar e justificar a tecnologia que decidiu utilizar.

O terceiro ponto envolve justamente a participação humana. Inserir uma pessoa ao final do processo não garante, por si só, que exista verdadeira supervisão. Se o profissional recebe uma classificação pronta e apenas confirma aquilo que o sistema recomendou, a revisão humana torna-se formal. Para que funcione como mecanismo de controle, é preciso que exista possibilidade real de discordância, acesso suficiente às informações e condições para que a recomendação seja reavaliada quando produzir um resultado estranho ou potencialmente discriminatório.

Nesse cenário, a capacitação dos profissionais de Gestão de Pessoas assume outra dimensão. Não se espera que dominem programação ou saibam reconstruir tecnicamente um modelo de inteligência artificial. Torna-se mais importante compreender as limitações dessas ferramentas, reconhecer situações que merecem questionamento e saber quando uma decisão automatizada precisa ser revista.

Governança algorítmica, nesse sentido, não se resume a impedir que a empresa seja responsabilizada depois. Significa criar condições para que a própria organização saiba qual tecnologia está utilizando, porque confia nela, quais são seus limites e o que fará quando seus resultados indicarem possíveis distorções. Isso envolve fornecedores, profissionais de Gestão de Pessoas, áreas técnicas, jurídicas e de gestão, porque nenhuma dessas áreas, isoladamente, consegue responder a todas as questões produzidas pela automação.

Nenhuma dessas medidas elimina as desigualdades presentes nos dados históricos discutidas ao longo deste artigo. Governança não apaga o passado utilizado para ensinar os sistemas nem garante que toda decisão automatizada será imparcial. Ela pode, contudo, criar pontos de controle entre o dado, o algoritmo e a decisão final, permitindo que resultados problemáticos sejam percebidos antes de se tornarem exclusões naturalizadas pelo processo seletivo.

É justamente nesse ponto que a ilusão da neutralidade algorítmica encontra seu maior risco para a Gestão de Pessoas: quando uma decisão deixa de ser questionada não porque se demonstrou que ela é justa, mas simplesmente porque foi produzida por uma tecnologia.

Romper essa lógica exige menos confiança automática na ferramenta e mais responsabilidade sobre a forma como ela é escolhida, utilizada e supervisionada.

5 Considerações finais

Este artigo partiu de uma pergunta simples de formular, mas difícil de responder: em que medida a aparência de neutralidade dos algoritmos utilizados no recrutamento pode esconder sua participação em decisões que continuam pertencendo à organização? Ao longo da análise, sustentou-se que automatizar uma etapa da seleção não torna a decisão independente de quem escolheu utilizar a ferramenta. Ao contrário, a aparência de objetividade técnica pode criar um distanciamento entre a organização e o resultado produzido pelo sistema, tornando menos visíveis tanto os critérios utilizados quanto a responsabilidade por seus efeitos.

O caminho percorrido permitiu responder às quatro frentes propostas nos objetivos específicos. Primeiro, demonstrou-se como vieses históricos e sociais podem alcançar sistemas de recrutamento por meio dos dados utilizados em seu desenvolvimento e funcionamento. Informações aparentemente neutras, como localização, trajetória profissional, períodos de afastamento ou determinados padrões presentes no currículo, podem adquirir peso diferente quando combinadas e reproduzir desigualdades que não aparecem de maneira explícita no código. Nesse contexto, a ausência de uma variável como gênero ou raça não é suficiente, por si só, para assegurar que o resultado produzido seja neutro.

A análise também sustentou que a utilização de um sistema automatizado não retira a decisão do espaço organizacional. A empresa continua definindo a vaga, escolhendo a ferramenta, estabelecendo como ela será incorporada ao processo seletivo e decidindo quanto peso será atribuído às recomendações produzidas. A legislação brasileira oferece elementos importantes para essa leitura, especialmente a CLT, a LGPD e as normas de proteção contra discriminação, ainda que não exista um regime jurídico desenvolvido especificamente para todas as particularidades do recrutamento algorítmico.

Ao mesmo tempo, identificou-se uma dificuldade que talvez seja uma das faces mais relevantes desse problema: como questionar uma decisão quando não se consegue enxergar claramente como ela foi construída? A opacidade dos sistemas pode acentuar a desigualdade de acesso à informação entre o candidato e a organização. Quem recebe a decisão conhece, muitas vezes, apenas o resultado; quem utiliza ou fornece a tecnologia encontra-se em posição mais próxima dos critérios, registros e informações necessários para explicar como esse resultado foi produzido. Nesse cenário, instrumentos como o art. 20 da LGPD e a distribuição dinâmica do ônus da prova prevista na CLT oferecem caminhos importantes, embora não eliminem completamente essa assimetria.

A contribuição deste estudo, portanto, não está apenas em reafirmar que sistemas algorítmicos podem reproduzir desigualdades, fenômeno já identificado em diferentes pesquisas e casos documentados. O que se buscou foi deslocar a discussão para uma pergunta anterior à própria correção técnica do viés: o que acontece com a responsabilidade organizacional quando uma decisão sobre pessoas passa a ser mediada por uma tecnologia que se apresenta como neutra? Esse deslocamento aproxima o debate da realidade da Gestão de Pessoas, porque deixa de tratar o viés algorítmico apenas como falha de programação e passa a observá-lo também como problema de escolha, supervisão e governança organizacional.

Essa perspectiva também modifica o papel atribuído aos profissionais de Gestão de Pessoas. Não se espera que conheçam a programação interna de cada ferramenta, mas que sejam capazes de questionar aquilo que utilizam para tomar decisões sobre pessoas. Saber se o sistema foi avaliado quanto a possíveis vieses, compreender quais informações influenciam seus resultados, identificar padrões incomuns de exclusão e garantir espaço real para revisão humana

passam a integrar uma atuação mais responsável diante da automatização do recrutamento. A tecnologia pode apoiar a decisão, mas não deveria substituir a capacidade de questioná-la.

O estudo possui limitações. Por sua natureza bibliográfica e documental, não foram produzidos dados empíricos primários sobre a utilização desses sistemas por profissionais e organizações brasileiras. A dimensão jurídica da análise também se concentrou nas relações trabalhistas, na proteção contra discriminação e no tratamento automatizado de dados, sem pretensão de esgotar outras possíveis repercussões regulatórias ou jurídicas. Além disso, o ambiente normativo relacionado à inteligência artificial permanece em transformação, o que exige que as conclusões apresentadas sejam compreendidas dentro do contexto regulatório existente no período em que a pesquisa foi realizada.

Como continuidade, propõe-se a realização de investigação empírica com profissionais de Recursos Humanos, Direito e Psicologia Organizacional, buscando compreender como esses diferentes grupos percebem, na prática, os riscos, limites e possibilidades do recrutamento mediado por inteligência artificial. Essa etapa poderá confrontar os argumentos desenvolvidos a partir da literatura e dos documentos analisados com situações concretamente vivenciadas dentro das organizações, ampliando a compreensão sobre como decisões automatizadas são incorporadas à rotina de Gestão de Pessoas.

Por fim, discutir neutralidade algorítmica significa discutir também que tipo de mercado de trabalho se pretende construir. Sistemas capazes de reproduzir desigualdades de gênero e raça dialogam diretamente com desafios relacionados à igualdade, ao trabalho decente e à redução das desigualdades. A tecnologia não cria sozinha as estruturas históricas que alimentam seus dados, mas pode ampliar sua escala e tornar seus efeitos menos perceptíveis quando seus resultados deixam de ser questionados.

Questionar a neutralidade de um algoritmo de recrutamento, portanto, não significa rejeitar a tecnologia. Significa recusar a ideia de que uma decisão se torna justa apenas porque foi automatizada.

6 Referências

BRASIL. Decreto-Lei nº 5.452, de 1º de maio de 1943. Aprova a Consolidação das Leis do Trabalho. Brasília, DF: Presidência da República, 1943. Disponível em: https://www.planalto.gov.br. Acesso em: 9 ago. 2026.

BRASIL. Constituição da República Federativa do Brasil de 1988. Brasília, DF: Presidência da República, 1988. Disponível em: https://www.planalto.gov.br. Acesso em: 9 jul. 2026.

BRASIL. Lei nº 9.029, de 13 de abril de 1995. Proíbe a adoção de qualquer prática discriminatória e limitativa para efeito de acesso à relação de trabalho. Brasília, DF: Presidência da República, 1995. Disponível em: https://www.planalto.gov.br. Acesso em: 9 jul. 2026.

BRASIL. Lei nº 10.406, de 10 de janeiro de 2002. Institui o Código Civil. Brasília, DF: Presidência da República, 2002. Disponível em: https://www.planalto.gov.br. Acesso em: 9 jul. 2026.

BRASIL. Lei nº 13.709, de 14 de agosto de 2018. Lei Geral de Proteção de Dados Pessoais (LGPD). Brasília, DF: Presidência da República, 2018. Disponível em: https://www.planalto.gov.br. Acesso em: 9 ago. 2026.

BRASIL. Tribunal Superior do Trabalho. Recurso de Revista nº 0000444-14.2021.5.09.0651. Relatora: Min. Kátia Magalhães Arruda. 6ª Turma. Brasília, DF, 25 out. 2023. Publicação: 27 out. 2023. Acesso em: 30 de jun. 2026.

BUOLAMWINI, Joy; GEBRU, Timnit. Gender shades: intersectional accuracy disparities in commercial gender classification. Proceedings of Machine Learning Research, v. 81, p. 77-91 2018. Acesso em: 15 jul. 2026.

CHEONG, Lucas. O uso da inteligência artificial no recrutamento e seleção de pessoas: eficiência ou viés? 2025. Trabalho de Conclusão de Curso (Bacharelado em Administração) – Pontifícia Universidade Católica de São Paulo, São Paulo, 2025. Acesso em: 12 jul. 2026.

CRAWFORD, Kate. Atlas of AI: power, politics, and the planetary costs of artificial intelligence. New Haven: Yale University Press, 2021. Acesso em: 20 jul. 2026.

CRENSHAW, Kimberlé. Demarginalizing the intersection of race and sex: a black feminist critique of antidiscrimination doctrine, feminist theory and antiracist politics. University of Chicago Legal Forum, v. 1989, artigo 8, p. 139-167, 1989.

CRENSHAW, Kimberlé. Mapping the margins: intersectionality, identity politics, and violence against women of color. Stanford Law Review, v. 43, n. 6, p. 1241-1299, 1991.

DASTIN, Jeffrey. Amazon scraps secret AI recruiting tool that showed bias Against women. Reuters, 10 out. 2018. Disponível em: https://www.reuters.com. Acesso em: 9 jul. 2026.

FERNANDES, Erika Ribeiro; GRAGLIA, Marcelo Augusto Vieira. Inteligência humana e inteligência artificial e os desafios dos vieses nos algoritmos de IA. RISUS – Journal on Innovation and Sustainability, São Paulo, v. 15, n. 1, p. 133-142, fev./mar. 2024. DOI: 10.23925/2179-3565.2023v15i1p133-142. Acesso em: 30 jun. 2026.

LARSON, Jeff; MATTU, Surya; KIRCHNER, Lauren; ANGWIN, Julia. How we analyzed the COMPAS recidivism algorithm. ProPublica, 23 maio 2016.

O'NEIL, Cathy. Weapons of math destruction: how big data increases inequality and threatens democracy. New York: Crown, 2016. Acesso em: 20 jul. 2026.

ORGANIZAÇÃO INTERNACIONAL DO TRABALHO. Convenção nº 111: discriminação em matéria de emprego e profissão. Genebra: OIT, 1958. 30 jun. 2026.

SILVA, Juliana Pires da; LUZ, Priscila Flores da; ROSA, Rafael Arlindo. Vieses, ilusões e decisões: até que ponto podemos confiar na inteligência artificial? Revista Devir Educação, Lavras, v. 10, n. 1, e-1108, 2026.

SILVA, Tarcízio. Visão computacional e racismo algorítmico: branquitude e opacidade no aprendizado de máquina. Revista da ABPN, v. 12, p. 428-448, 2020.

VIANA, Nicole Ferreira. Discriminação algorítmica nas relações de trabalho: desigualdade de gênero e os caminhos do acesso à justiça para a efetivação da justiça social na era da inteligência artificial. 2025. 115 f. Dissertação (Mestrado em Direito) – Centro Universitário Christus, Fortaleza, 2025.