



# A mitigação de riscos à privacidade e vieses no pré-processamento de dados num processo de triagem de currículos baseado em modelos de I.A. generativa

## *Mitigating privacy risks and algorithmic biases in data pre-processing within generative AI-based curriculum screening processes*

[10.29073/j2.v8i1.1107](https://doi.org/10.29073/j2.v8i1.1107)


**Recebido:** 20 de fevereiro de 2026.

**Aprovado:** 21 de março de 2026.

**Publicado:** 04 de abril de 2026.

**Autor/a 1:** Ana Dara Fernandes, ESTG-IPP, Portugal, [8240099@estg.ipp.pt](mailto:8240099@estg.ipp.pt).

**Autor/a 2:** Marco Filipe Gomes, ESTG-IPP, Portugal, [mfg@estg.ipp.pt](mailto:mfg@estg.ipp.pt).

**Autor/a 3 (Correspondente):** Sérgio Miguel Tomás , ESTG-IPP, Portugal, [smt@estg.ipp.pt](mailto:smt@estg.ipp.pt).

### Resumo

Este artigo analisa o uso de I.A. generativa em sistemas de triagem automatizada de currículos, articulando perspetivas jurídicas e computacionais, ao estudar um conjunto de 758 currículos associados a um processo de recrutamento na Federação Polaca de Futsal.

O objetivo centrou-se em criar uma cadeia de pré-processamento de dados que mitigasse os riscos associados à privacidade e vieses (bias) dos dados de entrada a modelos de I.A. A experiência realizada permitiu desenvolver procedimentos de extração automática, anonimização manual e de normalização dos dados em bruto que mitigassem vieses inerentes. Os programas desenvolvidos foram executados localmente, alinhando-se com os princípios do RGPD e com as obrigações do regulamento AI Act para sistemas de alto risco.

Os resultados indicam uma redução do risco associado aos vieses e reforça a importância de uma abordagem de mitigação de riscos no pré-processamento dos dados antes de os submeter a modelos de I.A. generativa.

**Palavras-Chave:** Inteligência Artificial Generativa; Recrutamento; Recursos Humanos; RGDP; Triagem de Currículo.

### Abstract

This article examines the use of generative AI in automated résumé-screening systems, combining legal and computational perspectives through the analysis of a dataset of 758 résumés associated with a recruitment process conducted by the Polish Futsal Federation. The objective was to design a data pre-processing pipeline capable of mitigating privacy risks and biases present in the input data used by AI models.

The experiment enabled the development of procedures for automatic data extraction, manual anonymization, and normalization of raw data in order to reduce inherent biases. All programs were executed locally, ensuring alignment with GDPR principles and with the obligations established by the AI Act for high-risk systems.

The results indicate a reduction in bias-related risks and reinforce the importance of adopting a risk-mitigation approach during data pre-processing before submitting information to generative AI models.

**Keywords:** GDPR; Generative Artificial Intelligence; Human Resources; Recruitment; Résumé Screening.

## 1. Introdução

A Inteligência Artificial (I.A.) tornou-se um elemento central na transformação da área de recursos humanos (RH), permitindo automatizar e otimizar funções como o recrutamento, a integração, a formação e a avaliação



de desempenho (Dasaklis et al., 2025). Entre estas funções, o recrutamento e a seleção assumem um papel particularmente relevante, uma vez que influenciam diretamente o desempenho global das organizações.

A triagem de currículos constitui a primeira fase eliminatória do processo de recrutamento, na qual os profissionais de RH analisam e filtram candidaturas para identificar perfis alinhados com os requisitos da função e com a cultura organizacional (Costa, 2024; Barreto et al., 2023).

O facto de o recrutamento e a triagem de currículos serem funções transversais a organizações de diferentes setores, geografias e dimensões reforça a relevância científica e social deste domínio. Pequenas alterações nos critérios de seleção ou nos dados utilizados podem afetar grandes volumes de candidatos, reproduzindo práticas discriminatórias em larga escala (Rana, 2021).

Apesar dos avanços tecnológicos da I.A., a automatização da triagem de currículos apresenta riscos significativos para reproduzir e amplificar padrões de discriminação. Apesar dos avanços tecnológicos da I.A., a automatização da triagem de currículos apresenta riscos significativos de reprodução e amplificação de enviesamentos.

Estudos demonstram que sistemas treinados com dados históricos podem reproduzir padrões de discriminação de género, idade e outras características demográficas, dado que estes sistemas são “alimentados” por conjunto de dados contendo vieses inerentes (e.g., um conjunto de dados que não representa a realidade de forma equilibrada ou neutra, fazendo com que certas características, grupos ou padrões apareçam mais ou menos importantes do que realmente são). Por exemplo, mulheres mais velhas ou com filhos apresentam menor probabilidade de avançar para etapas subsequentes, mesmo quando possuem qualificações equivalentes (Derous & Decoster, 2017; González et al., 2019). Similarmente, currículos de candidatos mais velhos recebem menos respostas positivas do que os de candidatos mais jovens, evidenciando discriminação etária (Derous & Decoster, 2017).

No ordenamento jurídico português, o artigo 24.º do Código do Trabalho, reforçado pela Lei n.º 13/2023 (Agenda do Trabalho Digno), consagra o princípio da igualdade e da não discriminação no acesso ao emprego e nas condições de trabalho. Este regime articula-se com o RGPD, em particular com o artigo 22.º relativo a decisões automatizadas, e com o Regulamento Europeu de Inteligência Artificial (AI Act), que classifica os sistemas de I.A. utilizados em contexto laboral como sistemas de alto risco, impondo obrigações reforçadas de transparência, segurança, supervisão humana e mitigação de riscos de discriminação.

Este trabalho destaca, assim, a mitigação do risco de enviesamento das decisões promovidas por modelos de I.A. como um campo de investigação importante e considera a fase de pré processamento de currículos em sistemas de triagem automatizada com I.A. generativa como uma fase importante para a mitigação dos riscos associados à reprodução da discriminação e à privacidade dos dados.

Este enquadramento jurídico-normativo condiciona o desenho da solução técnica adotada, nomeadamente as opções de execução local, anonimização e normalização dos dados, em conformidade com o RGPD e o AI Act. Importa distinguir decisões automatizadas, nos termos do artigo 22.º do RGPD, de sistemas de apoio à decisão. No presente estudo, a triagem configura uma decisão automatizada, por resultar do processamento autónomo do sistema, convocando as garantias aplicáveis a decisões exclusivamente automatizadas com impacto significativo.

Alinhadas com o objetivo do artigo, duas perguntas de investigação foram formuladas: a primeira, é possível, no contexto de um processo de triagem de currículos, desenvolver procedimentos que possam mitigar os riscos associados ao processamento de conjuntos de dados contendo vieses? e a segunda, até que ponto a eliminação de vieses e a mitigação de riscos à privacidade podem reduzir indicadores diretos e indiretos a atributos sensíveis nos currículos num conjunto de dados desbalanceado (em que certas categorias, grupos ou valores estão representados de forma muito desigual)?



Embora um conjunto de estudos recentes, destacados na revisão da literatura deste artigo, explore as potencialidades e oportunidades da utilização de sistemas de inteligência artificial nos processos de recrutamento, em particular na fase de triagem, a maioria dessas abordagens não se centra nos riscos associados à submissão de conjuntos de dados desbalanceados e estruturalmente enviesados a modelos de inteligência artificial generativa (por exemplo, ChatGPT).

É neste contexto que o presente trabalho enfatiza uma experiência conduzida com 758 currículos reais, submetidos no âmbito de um processo de candidatura a um cargo na administração da Federação Polaca de Futsal. Todos os programas desenvolvidos foram executados localmente, num ambiente controlado, sem recurso a infraestruturas externas, com o objetivo de responder às questões de investigação que orientaram este estudo. A experiência permitiu analisar, de forma controlada, como os procedimentos adotados influenciam a mitigação de riscos num processo de triagem automatizada. A execução local garantiu a confidencialidade, integridade e auditabilidade dos dados, reforçando a segurança e a conformidade com os princípios do RGPD e do AI Act.

## 2. Revisão da Literatura

O recrutamento e seleção envolve ações estruturadas para atrair candidatos qualificados (Loureiro, 2023), sendo a triagem de currículos crucial para determinar quem avança, influenciando a equidade e eficácia da seleção (Costa, 2024). Tradicionalmente realizada manualmente ou com regras fixas, o aumento do número de candidaturas gerou gargalos operacionais (Barreto et al., 2023), tornando a automação e a I.A. ferramentas estratégicas para gerir grandes volumes de dados, triagem de currículos, avaliação de competências e entrevistas (Lo et al., 2025; Blumen & Cepellos, 2023; Dargnies et al., 2022; Moreira, 2022).

A I.A. generativa destaca-se por compreender linguagem natural, sintetizar informações e extrair conhecimento de grandes volumes de dados, permitindo decisões mais eficientes (Dasaklis et al., 2025) e triagem automatizada flexível capaz de identificar competências implícitas (Lo et al., 2025). Apesar de ganhos em eficiência e redução de custos (Chen, 2023; Marcelino, 2023), estes sistemas reproduzem vieses que podem comprometer princípios de equidade e não discriminação (Chen, 2023; Moreira, 2022; Anzenberg et al., 2025). Estudos mostram que mulheres mais velhas e candidatos com nomes estrangeiros têm menor probabilidade de avançar, e que a idade funciona como proxy de outros atributos (González et al., 2019; Wen et al., 2025). Sivakaminathan & Musi (2025) evidenciam que o ChatGPT reforça enviesamentos de género presentes em anúncios de emprego, privilegiando traços associados a linguagem masculina, enquanto a falta de transparência gera frustração entre candidatos (Armstrong et al., 2024).

Dada a influência direta das decisões automatizadas, a utilização de I.A. no recrutamento exige enquadramento jurídico e ético rigoroso, com mecanismos de segurança, transparência e responsabilização. Em Portugal, o Código do Trabalho garante não discriminação e igualdade, aplicáveis a decisões algorítmicas, prevendo inversão do ónus da prova (Falcão & Tomás, 2025, pp. 102-109; Machado & Magalhães, s.d.), enquanto o artigo 22.º do RGPD limita decisões exclusivamente automatizadas, exigindo salvaguardas como supervisão humana (Peixe, 2025).

O AI Act regula sistemas de alto risco, reforçando gestão de risco, qualidade de dados, transparência e supervisão, articulando-se com RGPD nos princípios de minimização de dados, proteção desde a conceção e segurança do tratamento (artigos 5.º, 25.º e 32.º).

A anonimização assume papel central na mitigação de riscos de privacidade, e o artigo 10.º permite tratamento de dados sensíveis para mitigar enviesamentos, condicionado a pré-processamento rigoroso e auditoria (Awadet al., 2023; van Bekkum, 2025). O caso da Amazon (2018) ilustra estes riscos, com enviesamento de género que levou à suspensão do sistema (Rodriguez, 2023; Viana & Macedo, 2024; Ataíde, 2025).

A literatura evidencia limitações na aplicação da I.A. generativa na triagem de currículos, nomeadamente no que concerne à reprodução de enviesamentos e a falta de transparência e privacidade. Em resposta, o capítulo seguinte apresenta a metodologia utilizada neste estudo, baseada num pré-processamento estruturado e



sequencial, inspirado em equidade composicional (Biswas&Rajan, 2021), permitindo analisar sistematicamente o impacto de cada intervenção na mitigação dos riscos mencionados anteriormente na fase de pré-processamento dos dados de um sistema de triagem automatizada.

### **3. Redução de Vieses e Proteção de Privacidade no Pré-Processamento de Currículos para Sistemas de I.A. de Alto Risco**

A presente experiência parte do pressuposto de que, em sistemas de triagem automatizada baseados em modelos de linguagem de grande dimensão, a gestão dos dados e o pré-processamento são determinantes centrais do comportamento algorítmico, frequentemente mais relevantes do que a própria arquitetura do modelo. A literatura indica que estes modelos tendem a reproduzir enviesamentos linguísticos e estruturais existentes, sobretudo em domínios marcados por desigualdades de género e idade.

A experiência baseou-se num conjunto de 758 currículos reais relativos a um processo de candidatura à administração da Federação Polaca de Futsal, disponibilizados no âmbito de uma colaboração científica com a Universidade de Bielsko-Biala.

Os dados apresentavam elevada heterogeneidade estrutural e linguística (currículos no formato digital em diferentes formatos (e.g., PDF, DOCX) e em diferentes línguas (Polaco e Inglês) e existindo uma distribuição demográfica e profissional desigual (83% dos candidatos eram do género masculino e 72% tinham sido jogadores ou treinadores) configurando um risco algorítmico relevante.

Neste contexto, adotou-se uma abordagem de Ação-Investigação, integrando a neutralização de enviesamentos e a proteção da privacidade desde a fase de pré-processamento, concebida como um instrumento de governação de dados em sistemas de I.A. de alto risco.

As seções seguintes descrevem detalhadamente a cadeia de pré-processamento desenvolvida, as etapas envolvidas, os riscos mitigados e a sua articulação com os requisitos legais aplicáveis, incluindo o RGPD e o AI Act.

#### **3.1. Metodologia Aplicada e Etapas do Pré-Processamento**

A investigação adotou uma abordagem de Ação-Investigação, na qual cada intervenção técnica no pré-processamento foi acompanhada por observação sistemática e reflexão crítica sobre os seus efeitos no comportamento do modelo de linguagem. Esta metodologia permitiu iterar e ajustar a cadeia de pré-processamento com base em evidência empírica, integrando simultaneamente requisitos técnicos, éticos e jurídicos.

O objetivo central foi mitigar a reprodução de enviesamentos presentes nos dados, assegurando, em paralelo, a integridade, utilidade e confidencialidade da informação no sistema automatizado de triagem.

O pré-processamento foi estruturado em cinco etapas principais. A primeira consistiu na extração automática do conteúdo textual dos currículos com scripts em Python capazes de lidar com múltiplos formatos e línguas, garantindo uniformidade, rastreabilidade e mitigação de vieses estruturais.

A segunda etapa envolveu a anonimização manual, justificada pela elevada densidade contextual dos documentos. A título ilustrativo, antes do pré-processamento, cerca de 82% dos currículos continham identificadores diretos (nomes completos, endereços de email ou contactos telefónicos), percentagem que foi reduzida para 0% após a anonimização.

Foram igualmente removidos identificadores indiretos, como referências a instituições, cargos específicos e eventos profissionais, com a eliminação fictícia de aproximadamente 1950 entidades nomeadas, distribuídas por categorias como instituições de ensino (41%), clubes ou organizações desportivas (33%) e cargos ou funções específicas (26%).



Estas intervenções protegeram a privacidade e neutralizaram fontes explícitas de enviesamento associadas à identificação individual, em conformidade com o RGPD. Seguiu-se a terceira etapa em que consistiu na normalização estrutural, segmentando os currículos em secções homogéneas (formação académica, experiência profissional, competências e certificações).

Após esta etapa, 100% dos currículos passaram a obedecer a uma estrutura comum, eliminando variações narrativas que, em cenários não controlados, podem favorecer estilos discursivos associados a determinados grupos sociais.

Esta normalização permitiu ainda identificar, de forma controlada, indicadores indiretos de atributos sensíveis, como referências temporais suscetíveis de inferir idade, sem os expor diretamente ao modelo. A quarta etapa centrou-se na mitigação de enviesamentos linguísticos. De forma ilustrativa, referências explícitas a atributos sensíveis (e.g., género, estado civil) foram reduzidas de cerca de 18% dos currículos para 0%, enquanto variáveis substitutas com potencial discriminatório foram neutralizadas e padronizadas em aproximadamente 64% dos casos identificados.

A quinta etapa consistiu na execução local de toda a cadeia de pré-processamento, sem recurso a infraestruturas externas em linha com boas práticas de engenharia de software. O resultado foi um conjunto de currículos anonimizados, normalizados e com parcialidade mitigada, adequado à avaliação por modelos de I.A. generativa e à comparação com decisões humanas. Isto permitiu separar claramente enviesamento nos dados (desigualdade demográfica e profissional) do enviesamento no output do modelo, preparando os dados para avaliação ética de sistemas de I.A. generativa.

Todas as intervenções foram alinhadas com os princípios do RGPD e do AI Act, incluindo minimização de dados, proteção desde a conceção, segurança do tratamento, qualidade dos dados, gestão de riscos, supervisão humana e transparência. Assim, o pré-processamento assumiu-se como instrumento de governação de dados, assegurando uma triagem automatizada ética, transparente e juridicamente compatível.

### **3.2. Resultados Obtidos**

O conjunto de currículos foi submetido à cadeia de pré-processamento (feito através de uma sequência de execução de programas em Python desenvolvidos para o efeito) e resultou num conjunto de dados anonimizados, normalizados e com parcialidade mitigada. Importa notar que, apesar destas medidas, a anonimização não é absoluta, aproximando-se conceptualmente de pseudonimização, subsistindo um risco residual de reidentificação em cenários de cruzamento com fontes externas, o qual foi considerado aceitável no contexto controlado do estudo. A análise das etapas de pré-processamento ajudou a compreender os passos para a mitigação de riscos e enviesamentos (ver a Tabela 1).

Em particular, para salientar o que foi realizado na experiência, destacam-se alguns dos procedimentos concretizados: a extração automática assegurou integridade e uniformidade dos dados, mitigando o viés estrutural associado a diferentes formatos e extensões de documentos.

Por outro lado, a anonimização manual reduziu o risco de re-identificação e viés de prestígio; a normalização garantiu que a informação relevante fosse avaliada de forma consistente; e a execução local garantiu confidencialidade e integridade dos dados sensíveis, em conformidade com o RGPD e o AI Act. Os resultados indicaram uma redução da influência de fatores irrelevantes ou potencialmente discriminatórios, aumentando a equidade e a auditabilidade das decisões automatizadas.

De forma sintetizada, a relação entre decisões de pré-processamento, enviesamentos mitigados e enquadramento regulatório encontra-se apresentada na Tabela 1.

**Tabela 1:** Decisões de pré-processamento, enviesamentos e regulamentação

Decisão técnica	Enviesamento ou risco mitigado	Fundamentação regulatória
-----------------	--------------------------------	---------------------------



Extração automática padronizada	Viés estrutural	Art. 25.º RGPD; Art. 10.º AI Act
Anonimização manual	Risco de re-identificação e viés de prestígio	Art. 5.º, 25.º, 32.º RGPD; Art. 10.º, 14.º AI Act
Normalização estrutural	Viés narrativo	Art. 10.º, 13.º AI Act
Mitigação de enviesamentos linguísticos	Viés de género, etário e geracional	Art. 9.º AI Act
Execução local da cadeia de pré-processamento	Risco de confidencialidade	Art. 32.º RGPD; Art. 9.º AI Act

Esta abordagem permitiu estabelecer um enquadramento para a governação de dados, integrando mitigação de parcialidade, proteção da privacidade e conformidade regulatória, assegurando uma triagem automatizada ética, transparente e auditável.

### 3.3. Discussão e Limitações Técnicas

A experiência desenvolvida demonstra que uma cadeia de pré-processamento contendo procedimentos de mitigação de riscos, como a anonimização manual, a normalização estrutural e a mitigação de enviesamentos linguísticos, contribui de forma para a redução dos vieses de dados e dos riscos à privacidade, permitindo que modelos de linguagem de grande dimensão (I.A. generativa) operem de forma mais equitativa e auditável.

À luz dos indicadores quantitativos apresentados, é possível afirmar que o pré-processamento contribuiu de forma significativa para a redução de vieses nos dados, em particular no que respeita a viés de identificação pessoal, viés estrutural e viés linguístico, com reduções observáveis entre 75% e 100%, consoante a categoria analisada. Em contrapartida, o viés de representatividade demográfica e profissional manteve-se, refletindo a composição original da amostra e sendo tratado como um risco conhecido e controlado, e não como um artefacto introduzido pelo sistema.

Esta separação permitiu distinguir claramente enviesamento nos dados de enviesamento no output do modelo, reforçando a validade metodológica e a interpretabilidade dos resultados. Estes resultados alinham-se com a necessidade de mitigar os riscos estudos dado que os modelos generativos como o ChatGPT podem amplificar enviesamentos de género na triagem de currículos quando expostos a descrições de funções com linguagem “orientada ao género” (Sivakaminathan & Musi, 2025).

Apesar destes resultados, a investigação apresenta limitações metodológicas. A distribuição demográfica desigual do conjunto de dados limitou a avaliação do impacto das intervenções em grupos minoritários. Adicionalmente, a anonimização manual e a neutralização de variáveis substitutas exigem elevado esforço humano e conhecimento contextual, dificultando a sua replicação em conjuntos de dados de grande escala.

Por fim, a execução local da cadeia de pré-processamento, embora assegure elevados níveis de confidencialidade e segurança, restringe a escalabilidade e a integração em arquiteturas distribuídas.

### 3.4. Resposta às Perguntas de Investigação

Em resposta à primeira pergunta de investigação, que questiona se é possível desenvolver procedimentos que mitiguem os riscos associados ao processamento de conjuntos de dados contendo vieses, a experiência demonstrou que procedimentos sistemáticos de pré-processamento são eficazes nesse sentido.

A combinação de extração automática do conteúdo textual (utilizando bibliotecas Python como PyPDF2, python-docx e Textract), anonimização manual e automatizada (com técnicas de Reconhecimento de Entidades Nomeadas, via spaCy), normalização estrutural (segmentação semântica em secções de formação, experiência e competências, apoiada em regras heurísticas e classificadores simples) e neutralização de enviesamentos



linguísticos e estruturais (com a remoção de referências a gênero, idade e proxies implícitos) mostrou-se capaz de reduzir a influência de atributos sensíveis e padrões discriminatórios.

A execução local em ambiente controlado garantiu rastreabilidade, integridade e conformidade com o RGPD e o AI Act, evidenciando que tais procedimentos constituem instrumentos relevantes de governação de dados em sistemas de triagem automatizada de alto risco.

Relativamente à segunda pergunta de investigação, que incide sobre até que ponto a eliminação de vieses e a mitigação de riscos à privacidade reduzem indicadores diretos e indiretos de atributos sensíveis em conjuntos de dados desbalanceados, a análise revelou que o pré-processamento diminuiu significativamente a presença de identificadores diretos (nomes, contactos, referências institucionais) e de representantes de atributos sensíveis (como extensões de carreira ou expressões linguísticas codificadas por gênero ou idade).

Apesar do desbalanceamento acentuado por gênero e faixa etária, estas intervenções tornaram os dados mais neutros e consistentes, reduzindo a probabilidade de reprodução de discriminação implícita. Embora não elimine totalmente os efeitos do desbalanceamento, o pré-processamento forneceu uma base mais segura para a aplicação de modelos de I.A. generativa e para comparações com avaliações humanas, demonstrando que a mitigação de enviesamentos e a proteção de privacidade a montante são cruciais para reduzir riscos éticos, legais e técnicos em sistemas de triagem automatizada.

#### **4. Conclusão**

A investigação realizada centrou-se no estudo da fase inicial de tratamento dos dados para sistemas de triagem automatizada, em que a ausência de pré-processamento rigoroso pode perpetuar desigualdades históricas de gênero, idade e origem, produzindo decisões enviesadas e, por conseguinte, juridicamente inválidas. Por isso, este estudo integrou uma cadeia de pré-processamento de dados contendo procedimentos de mitigação de riscos, constituindo uma resposta técnico-jurídica concreta à necessidade de integrar os requisitos do RGPD e do AI Act.

Este trabalho representa, assim, o primeiro passo de um estudo mais amplo, que visa não apenas fundamentar técnica e juridicamente a fase de preparação dos dados, mas também avaliar empiricamente os efeitos dessa preparação sobre o desempenho e a equidade dos modelos de I.A. generativa aplicados à triagem de currículos. A continuidade do estudo incidirá sobre a avaliação empírica do impacto do pré-processamento, através de uma comparação sistemática entre os conjuntos de dados brutos e tratados.

Como perspetiva de trabalho futuro, pretende-se ampliar a generalização desta metodologia a conjuntos de dados mais vastos e diversificados, incorporando currículos de diferentes contextos geográficos, setores profissionais e níveis de qualificação, de forma a testar a robustez da abordagem em condições variadas e analisar o desempenho de modelos de I.A. generativa considerando conjunto de dados pré-processados e não pré-processados no contexto de processos de triagem automatizada.

#### **Referências**

Anzenberg, E., Samajpati, A., Chandrasekar, S., & Kacholia, V. (2025). Evaluating the promise and pitfalls of LLMs in hiring decisions [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.2507.02087>

Armstrong, L., Liu, A., MacNeil, S., & Metaxa, D. (2024). The silicon ceiling: Auditing GPT's race and gender biases in hiring [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.2405.04412>

Ataíde, M. C. (2025). A discriminação algorítmica na seleção de trabalhadores: O caso Amazon. *Cadernos Jurídicos da Faculdade de Direito de Sorocaba*, 5(1), 33–58. <https://cadernosjuridicos.fadi.br/cadernosjuridicos/article/view/125>

Awad, E., Balafoutas, L., Chen, L., Ip, E., & Vecchi, J. (2023). Artificial intelligence and debiasing in hiring: Impact on applicant quality and gender diversity [Preprint]. *SSRN*. <https://doi.org/10.2139/ssrn.4626059>



- Barreto, J. C., Stefano, E., Freitag, A. E. B., Santana, W. A., & Picoli, M. A. (2023). Currículo inclusivo: Uma proposta para a equidade e efetividade nos processos de recrutamento. *Revista de Gestão e Secretariado*, 14(5), 7586–7607. <https://doi.org/10.7769/gesec.v14i5.2139>
- Biswas, S., & Rajan, H. (2021). Fair preprocessing: Towards understanding compositional fairness of data transformers in machine learning pipeline [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.2106.06054>
- Blumen, D., & Cepellos, V. M. (2023). Dimensões do uso de tecnologia e inteligência artificial (IA) em recrutamento e seleção (R&S): Benefícios, tendências e resistências. *Cadernos EBAPE*, 21(2), 1–16. <https://doi.org/10.1590/1679-395120220080>
- Chen, Z. (2023). Ethics and discrimination in artificial intelligence-enabled recruitment practices. *Humanities & Social Sciences Communications*, 10, Article 567. <https://doi.org/10.1057/s41599-023-02079-x>
- Costa, V. S. A. (2024). *A utilização de inteligência artificial na triagem de currículos e tomada de decisão em processos seletivos* [Trabalho de conclusão de curso, Universidade Estadual de Goiás]. Repositório Institucional. <https://repositorio.ueg.br/jspui/handle/riueg/6213>
- Coutinho, C. P., Sousa, A., Dias, A., Bessa, F., Ferreira, M. J., & Vieira, S. (2009). Investigação-ação: Metodologia preferencial nas práticas educativas. *Psicologia, Educação e Cultura*, 12(2), 455–479. <https://hdl.handle.net/1822/10148>
- Dargnies, M. P., Hakimov, R., & Kübler, D. (2022). Aversion to hiring algorithms: Transparency, gender profiling, and self-confidence [Preprint]. *SSRN*. <https://doi.org/10.2139/ssrn.4238275>
- Dasaklis, T. K., Giannopoulos, P. G., Koutras, D., Malamas, V., & Chountalas, P. T. (2025). Large language models in human resource management: A systematic literature review of applications, open issues, and future research directions. *Decision Support Systems*. Advance online publication. <https://doi.org/10.2139/ssrn.5314976>
- Derous, E., & Decoster, J. (2017). Implicit age cues in résumés: Subtle effects on hiring discrimination. *Frontiers in Psychology*, 8, Article 1321. <https://doi.org/10.3389/fpsyg.2017.01321>
- Falcão, D., & Tomás, S. T. (2025). *Lições de direito do trabalho: Relação individual de trabalho* (15.ª ed.). Almedina.
- González, J., Cortina, C., & Rodríguez, J. (2019). The role of gender stereotypes in hiring: A field experiment. *European Sociological Review*, 35(2), 187–204. <https://doi.org/10.1093/esr/jcy055>
- Lei n.º 13/2023, de 3 de abril. Altera o Código do Trabalho e legislação conexa no âmbito da agenda do trabalho digno. *Diário da República*, 1.ª série, n.º 66. <https://diariodarepublica.pt/dr/detalhe/lei/13-2023-211340863>
- Lei n.º 58/2019, de 8 de agosto. Assegura a execução, na ordem jurídica nacional, do Regulamento (UE) 2016/679 do Parlamento Europeu e do Conselho, de 27 de abril de 2016 (Regulamento Geral sobre a Proteção de Dados). *Diário da República*, 1.ª série, n.º 151. <https://diariodarepublica.pt/dr/detalhe/lei/58-2019-123815982>
- Lei n.º 7/2009, de 12 de fevereiro. Aprova a revisão do Código do Trabalho. *Diário da República*, 1.ª série, n.º 30. [https://www.unl.pt/sites/default/files/codigo\\_do\\_trabalho.pdf](https://www.unl.pt/sites/default/files/codigo_do_trabalho.pdf)
- Lo, F. P.-W., Qiu, J., Wang, Z., Yu, H., Chen, Y., Zhang, G., & Lo, B. (2025). AI hiring with LLMs: A context-aware and explainable multi-agent framework for resume screening [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.2504.02870>
- Lukács, B. (2023). GDPR-compliant AI-based automated decision-making in the world of work. *Computer Law & Security Review*, 49, Article 105789. <https://doi.org/10.1016/j.clsr.2023.105789>



- Machado, S. S., & Magalhães, M. M. (n.d.). O uso responsável dos algoritmos no mundo do trabalho em Portugal. In *Direitos sociais: Diálogos transdisciplinares* (Vol. II, pp. 385–391). IberoJurSciencePress. <https://doi.org/10.62140/SMMM3852024>
- Marcelino, N. R. (2023). *Inteligência artificial aplicada aos processos de recrutamento e seleção em Portugal* [Dissertação de mestrado, Instituto Politécnico de Setúbal]. Repositório Comum. <http://hdl.handle.net/10400.26/58467>
- Moreira, T. C. (2022). *Direito no trabalho na era digital*. Almedina.
- Page, M. J., Moher, D., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... McKenzie, J. E. (2021). PRISMA 2020 explanation and elaboration: Updated guidance and exemplars for reporting systematic reviews. *BMJ*, 372, Article n160. <https://doi.org/10.1136/bmj.n160>
- Peixe, J. (2025). Decisões automatizadas, inteligência artificial e proteção de dados: Riscos e desafios no contexto português e europeu. *Vida Judiciária*. <https://www.vidajudiciaria.com>
- Rana, C. I. P. (2021). *Gestão de talentos e processos de recrutamento: Vantagens e desafios* [Dissertação de mestrado, ISCTE – Instituto Universitário de Lisboa]. Repositório ISCTE-IUL. [https://repositorio.iscte-iul.pt/bitstream/10071/24227/1/master\\_catarina\\_pereira\\_rana.pdf](https://repositorio.iscte-iul.pt/bitstream/10071/24227/1/master_catarina_pereira_rana.pdf)
- Regulamento (UE) 2016/679 do Parlamento Europeu e do Conselho, de 27 de abril de 2016 (Regulamento Geral sobre a Proteção de Dados). *Jornal Oficial da União Europeia*, L 119, 1–88. <https://eur-lex.europa.eu/eli/reg/2016/679/oj>
- Regulamento (UE) 2024/1689 do Parlamento Europeu e do Conselho, de 13 de junho de 2024 (Regulamento sobre Inteligência Artificial). *Jornal Oficial da União Europeia*, L. <https://eur-lex.europa.eu/eli/reg/2024/1689/oj>
- Rodriguez, V. (2023). Ethical implications of AI-based algorithms in recruiting processes: A study of civil rights violations under Title VII and the Americans with Disabilities Act [Graduate project, Boise State University]. *ScholarWorks @ Boise State University*. [https://scholarworks.boisestate.edu/cgi/viewcontent.cgi?article=1006&context=cyber\\_gradpro](https://scholarworks.boisestate.edu/cgi/viewcontent.cgi?article=1006&context=cyber_gradpro)
- Sequeira, F. V. (2022). O algoritmo no tecido empresarial: Das vicissitudes de contratação ao despedimento de trabalhadores – uma arma nociva que necessita de ser desarmada? In *Anuário da Proteção de Dados 2022* (pp. 70–126). Faculdade de Direito da Universidade Nova de Lisboa. <https://protecaodedadosue.cedis.fd.unl.pt/wp-content/uploads/2022/12/3.-Frederico-Sequeira.pdf>
- Sivakaminathan, S. S., & Musi, E. (2025). ChatGPT is a gender bias echo-chamber in HR recruitment: An NLP analysis and framework to uncover the language roots of bias. *AI & Society*. Advance online publication. <https://doi.org/10.1007/s00146-025-02564-8>
- van Bekkum, M. de M. (2025). Using sensitive data to de-bias AI systems: Article 10(5) of the AI Act. *Computer Law & Security Review*, 56, Article 106115. <https://doi.org/10.1016/j.clsr.2025.106115>
- Wen, A., Patil, T., Saxena, A., Fu, Y., O'Brien, S., & Zhu, K. (2025). FAIRE: Assessing racial and gender bias in AI-driven resume evaluations [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.2504.01420>
- Xavier, J. P., & Ferreira, D. O. (2025). Inteligência artificial e direitos fundamentais da seleção em Portugal. In *Livro de atas* (pp. 371–395). <https://doi.org/10.62140/JXDF3712025>



### Declaração Ética

**Conflito de Interesse:** Nada a declarar. **Financiamento:** Nada a declarar. **Revisão por Pares:** Dupla-cega.



Todo o conteúdo do *J<sup>2</sup> — Jornal Jurídico* é licenciado sob [Creative Commons](#), a menos que especificado de outra forma e em conteúdo recuperado de outras fontes bibliográficas.