

MEC-AI: Modelo de Enriquecimento de Explicação com Engenharia de Contexto para Inteligência Artificial

Gabriel Bicharra Santini Pinto¹, Ana Cristina Bicharra Garcia¹

¹Programa de Pós-Graduação em Informática (PPGI)
Universidade Federal do Estado do Rio de Janeiro (UNIRIO)
Av. Pasteur, 458, Urca, RJ, Brazil

gabrielbspinto@edu.unirio.br, cristina.bicharra@uniriotec.br

Abstract. *Explainability models in artificial intelligence, such as SHAP and LIME, present limitations in user understanding and trust due to the lack of contextual information required for interpreting results. This paper introduces the Model for Explanation Enrichment with Context Engineering for Artificial Intelligence (MEC-AI), which proposes a conceptual approach to incorporate domain knowledge in a context-sensitive manner. Grounded in [Bicharra 1992], the model extends traditional XAI by enabling contextualized explanations. The application in the labor market domain is based on knowledge acquisition with Human Resources specialists and comparison with the RAIS dataset, distinguishing structured variables from those requiring contextual complement.*

Resumo. *Modelos de explicabilidade em inteligência artificial, como SHAP e LIME, apresentam limitações na compreensão do usuário por não incorporarem o contexto de uso. Este artigo apresenta o Modelo de Enriquecimento de Explicação com Engenharia de Contexto (MEC-AI), que estrutura conhecimento de domínio de forma sensível ao contexto. Fundamentado em [Bicharra 1992], o modelo amplia a XAI tradicional ao permitir explicações contextualizadas. A aplicação no mercado de trabalho baseia-se na aquisição de conhecimento com especialistas de RH e na comparação com a base da RAIS, distinguindo variáveis estruturadas daquelas que requerem complementação contextual.*

1. Introdução

Sistemas de inteligência artificial têm alcançado elevada precisão por meio de algoritmos avançados de *machine learning* e *deep learning*, porém esse ganho preditivo tem sido acompanhado pela opacidade interpretativa dos modelos *black-box*. Embora produzam estimativas estatisticamente robustas, tais modelos dificultam a compreensão do processo inferencial pelo usuário [Ali et al. 2023]. A Inteligência Artificial Explicável (XAI) surge como resposta a essa tensão entre desempenho e transparência [Bertrand et al. 2022], sendo fundamental para identificar vieses, prevenir decisões injustas e fortalecer a confiança [Mohammed et al. 2025, Fidel et al. 2020], além de atender a demandas regulatórias por *accountability* [Ali et al. 2023].

Contudo, métodos como SHAP [Lundberg 2017] e LIME [Ribeiro et al. 2016], frequentemente utilizados na explicabilidade no domínio de Recursos Humanos (RH), concentram-se na contribuição das variáveis, sem reconstruir o contexto no qual o usuário

avalia a estimativa [Hooshyar and Yang 2024]. No domínio de RH, isso se apresenta como uma lacuna crítica, por se tratar de um mercado marcado pela informação desigual entre as partes - assimetria informacional. No entanto, tais explicações tendem a refletir apenas a contribuição das variáveis do modelo [Pinto et al. 2025], sem contemplar elementos contextuais fundamentais para a compreensão humana da decisão, como as condições do mercado de trabalho, as características da empresa, a composição do pacote de benefícios, a posição do empregado no mercado e os fatores de ancoragem pessoal. A explicabilidade deve ser orientada ao usuário para superar essa lacuna [Fabeyo 2025], que não é apenas de interpretabilidade algorítmica, mas também de adequação sociotécnica da explicação ao contexto de uso.

Diante desse cenário, este artigo propõe o Modelo de Enriquecimento de Explicação com Engenharia de Contexto para Inteligência Artificial (MEC-AI), fundamentado na abordagem de [Bicharra 1992], especialmente no princípio de consistência entre explicação e estrutura. O modelo é concebido como uma estrutura geral e aplicável a mercados com informação assimétrica, sendo instanciado no domínio de RH por meio de aquisição de conhecimento com especialistas de RH. Seu objetivo é enriquecer explicações derivadas de métodos como SHAP e LIME com conhecimento contextual integrado via engenharia de contexto [Mei et al. 2025], ampliando a confiança do usuário na estimativa.

2. Fundamentação Teórica

2.1. Explicabilidade em Inteligência Artificial e Contexto de Uso

A literatura sobre XAI destaca a necessidade de tornar sistemas preditivos transparentes, compreensíveis e auditáveis [Bertrand et al. 2022, Fidel et al. 2020, Ali et al. 2023]. Métodos baseados em atribuição de importância de variáveis, como SHAP e LIME, representam avanços na explicação local de modelos complexos, mas permanecem centrados na dimensão estatística, sem incorporar adequadamente o contexto interpretativo do usuário.

A pesquisa em XAI aplicada a RH evidencia uma transição de métodos tradicionais para abordagens orientadas à decisão. Modelos intrinsecamente interpretáveis, como redes bayesianas para recrutamento [Pessach et al. 2020], e técnicas contrafactuais [Tran et al. 2021] buscam transparência direta sobre fatores determinantes. Métodos de importância de atributos são amplamente utilizados para identificar variáveis críticas e detectar vieses [Naudé et al. 2023, Marra and Kubiak 2024], enquanto técnicas pós-hoc como SHAP e LIME são aplicadas em avaliação de candidatos e previsão de rotatividade [Das et al. 2022]. Observa-se também o avanço para sistemas mais complexos, como frameworks autoexplicáveis [Sun et al. 2024] e modelos neurais com mecanismos de atenção [Zhang et al. 2021]. Em conjunto, essas abordagens indicam um campo em evolução, focado em explicações acionáveis, mitigação de vieses e suporte à decisão mais justa em RH.

No domínio de RH, sistemas de XAI podem ser aprimorados pela integração de três requisitos centrais: negociação (*bargaining*), que permite a expressão de perspectivas e reduz assimetrias informacionais; mitigação de vieses, essencial para corrigir distorções históricas; e justiça (*fairness*), que exige abordagens sensíveis ao contexto

[Pinto et al. 2025]. Esses elementos sustentam sistemas mais transparentes e confiáveis, capazes de fortalecer relações de trabalho mais equilibradas.

Em ambientes com assimetria informacional, a explicabilidade assume papel estratégico, especialmente em domínios como crédito e RH, nos quais decisões sensíveis exigem não apenas precisão, mas alinhamento com referências cognitivas e condições situacionais do usuário [Černevičienė and Kabašinskas 2024, Bujold et al. 2024, Rigotti and Fosch-Villaronga 2024]. Nesse cenário, a engenharia de contexto surge como complemento à XAI, estruturando conhecimento de domínio por meio de classes e relações que permitem a geração de explicações dinâmicas. Ao articular conhecimento estatístico, conhecimento de domínio e referências cognitivas do usuário, essa abordagem reduz lacunas interpretativas e fortalece a confiança na interação humano-máquina.

À luz dessa evolução, tais sistemas podem ser compreendidos como mecanismos de mediação sociotécnica em dois níveis: entre IA e humanos, ao traduzir decisões algorítmicas em explicações compreensíveis; e entre atores humanos, ao articular diferentes perspectivas — de candidatos, especialistas de RH e gestores — em torno dessas explicações. Assim, as explicações deixam de ser apenas artefatos informacionais e passam a atuar como elementos mediadores que reduzem assimetrias informacionais, viabilizam negociação e apoiam o entendimento compartilhado. Essa perspectiva aproxima a explicabilidade do conceito de *boundary objects*, conforme [Star and Griesemer 1989, Caccamo et al. 2023, Werth et al. 2024], nos quais artefatos mantêm coerência estrutural ao mesmo tempo em que permitem interpretações flexíveis por diferentes comunidades. Desse modo, as explicações em XAI podem ser entendidas como objetos que conectam atores e domínios de conhecimento, posicionando a explicabilidade como componente central de sistemas colaborativos mediados por IA.

2.2. Modelo de Enriquecimento de Explicação com Engenharia de Contexto para Inteligência Artificial

O MEC-AI parte da premissa de que a estimação de valor em diferentes mercados ocorre sob condições de assimetria informacional. Conforme a teoria econômica clássica [Akerlof 1978, Spence 1978, Stiglitz 1975], agentes operam com níveis distintos de informação, influenciando tanto a formação de preços quanto sua interpretação. Por isso, no domínio de RH, explicar uma estimativa salarial exige mais do que revelar quais variáveis influenciaram a predição; exige integrar fatores contextuais que permitam ao usuário compreender por que aquela resposta faz sentido naquela situação.

Extende-se a teoria dos documentos ativos de [Bicharra 1992] à pesquisa em XAI, propondo que explicações sejam estruturas dinâmicas e sensíveis ao contexto, capazes de se expandir ou contrair conforme as necessidades do usuário. O grafo apresentado na Figura 1 apresenta o modelo conceitual do MEC-AI para estimação do valor do salário mensal. As variáveis em rosa correspondem a fatores estruturados presentes em base de dados de RH [Vemulapati et al. 2023, Eichinger and Mayer 2022, Özer et al. 2022, Siswanto et al. 2023]. A *Trajatória de Carreira* representa o histórico profissional do indivíduo, incluindo experiência, progressão e mobilidade, que influenciam diretamente sua valorização no mercado. As *Características da Empresa* referem-se a atributos organizacionais, como porte, setor e posicionamento competitivo, que impactam os níveis

de remuneração. Já as *Características Pessoais* incluem atributos individuais, como formação, habilidades e perfil profissional, que afetam a estimativa salarial.

Os elementos em roxo representam fatores contextuais não estruturados em base de dados de RH, mas relevantes para a interpretação da estimativa. As *Atribuições do Cargo* dizem respeito às responsabilidades e escopo da função, influenciando a percepção de valor associada à posição. A *Ancoragem de Expectativas* refere-se às referências cognitivas utilizadas pelo usuário, como salário atual ou ofertas comparáveis, que orientam sua avaliação da estimativa. Por fim, os *Fatores Econômicos* abrangem condições externas, como dinâmica de mercado, oferta e demanda por talentos e contexto macroeconômico, que afetam os níveis salariais.

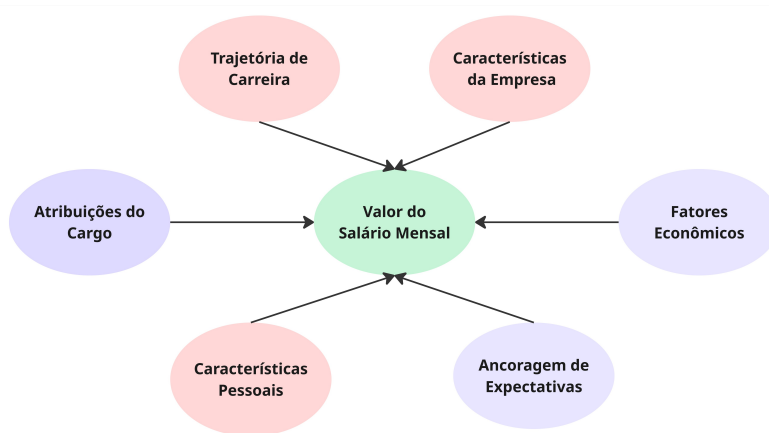


Figura 1. Diagrama Conceitual do MEC-AI

3. Metodologia

3.1. Método de Pesquisa

Este estudo adotou uma abordagem qualitativa fundamentada no paradigma interpretativista em Sistemas de Informação [Wainer et al. 2007, Klein and Myers 1999], adequada à investigação da construção do Modelo de Enriquecimento de Explicação com Engenharia de Contexto (MEC-AI). A estratégia metodológica baseou-se em análise interpretativa, com foco na compreensão dos significados, critérios e racionalidades mobilizadas por especialistas de RH nos fatores que compõe e diferenciam a remuneração profissional, priorizando profundidade analítica em vez de mensuração estatística.

A seleção dos participantes seguiu amostragem intencional (*purposive sampling*) [Akbari and Hauswirth 2024, Smith et al. 2013, Sibona et al. 2020], considerando experiência estratégica em remuneração e dinâmica salarial. Foram entrevistados cinco especialistas com perspectivas complementares — gestão corporativa, recrutamento executivo, pesquisa setorial e consultoria — buscando ampliar o espectro interpretativo e possibilitar triangulação analítica conforme [Sarker et al. 2013, Lee and Liebenau 1997]. O número de participantes mostrou-se suficiente para assegurar densidade temática e coerência interpretativa alinhadas aos objetivos do estudo. Como limitação, o número reduzido de participantes e o recorte empírico específico limitam a generalização dos achados, sendo, contudo, coerentes com a natureza exploratória e interpretativa da pesquisa.

A amostra foi composta por cinco especialistas com posições complementares no ecossistema de RH: um Diretor de RH em empresa de grande porte, responsável por estratégia e políticas salariais; um Diretor de empresa de *headhunting*, com atuação em recrutamento executivo e negociação de remuneração; um Diretor de Pesquisa de associação de RH, focado em estudos salariais e tendências de mercado; uma Consultora de RH voltada a pequenas e médias empresas, com experiência em estruturação de cargos e planos de remuneração; e um Consultor independente especializado em remuneração estratégica e *benchmarking salarial*.

3.2. Coleta e Análise dos Dados

As entrevistas foram realizadas entre agosto e outubro de 2025, de forma remota, por meio da plataforma *Microsoft Teams*, com duração média de aproximadamente 50 minutos e conduzidas a partir de roteiro semiestruturado. O questionário foi desenvolvido com base na literatura sobre compensação e estrutura salarial [Cullen et al. 2025, Berger et al. 2008], buscando captar a experiência dos entrevistados [Schultze and Avital 2011], e posteriormente refinado pela equipe de pesquisa. A organização do roteiro seguiu progressão temática de questões amplas para tópicos específicos, equilibrando direcionamento analítico e abertura à emergência de dados contextualizados. Todas as entrevistas foram gravadas mediante consentimento e transcritas integralmente com o auxílio do software *Transkriptor*, sendo as transcrições revisadas para assegurar fidelidade às falas.

A análise e codificação das entrevistas utilizou o software *Atlas.TI* e adotou abordagem interpretativa baseada em leitura iterativa das transcrições [Braun and Clarke 2006], envolvendo identificação de padrões de significado, construção de categorias e articulação entre evidências empíricas e referencial teórico por meio de 111 códigos produzidos. As interpretações foram discutidas entre os pesquisadores para ampliar a pluralidade analítica e mitigar vieses individuais. As categorias emergentes fundamentaram a estruturação dos elementos de engenharia de contexto do modelo MEC-AI, alinhando conhecimento especializado de domínio à arquitetura explicativa proposta.

4. Resultados e Discussão

Os 111 códigos identificados nas entrevistas possibilitaram a granularização da instanciação do modelo MEC-AI no domínio de RH. Esses códigos foram agrupados com base em conceitos do domínio e nas seis variáveis do modelo, com foco não apenas na associação entre variáveis e a estimativa salarial, mas também na estruturação de conhecimento de domínio por meio de agrupamentos conceituais derivados da análise qualitativa. Esses agrupamentos representam abstrações analíticas construídas a partir dos relatos dos especialistas e organizadas de forma a apoiar a geração de explicações contextualizadas. Os trechos a seguir ilustram o processo de análise e codificação:

Especialista 1 [Código: Situação de Busca]: “Mas tem um aspecto importante: quando o candidato está empregado e em boa situação profissional, o grau de seletividade é maior. Ele aplica apenas para vagas que realmente fazem sentido. Já quando está desempregado, tende a aplicar para diversas vagas, independentemente do setor ou da real adequação, quase como atirar para todos os lados.”

O trecho evidencia que a interpretação do usuário varia conforme sua situação de busca de emprego. Mesmo quando a estimativa apresenta alta precisão, sua compreensão depende do contexto em que o indivíduo está inserido no mercado de trabalho. A variável *Situação de Busca* representa esse estado no momento da consulta — por exemplo, empregado, desempregado, satisfeito, insatisfeito ou em transição estratégica. As entrevistas indicam que profissionais empregados e satisfeitos tendem a exigir um prêmio salarial — frequentemente entre 10% e 30% — para considerar uma mudança. Assim, uma estimativa alinhada à média de mercado pode ser percebida como insuficiente. Em contraste, um profissional desempregado, geralmente menos seletivo, tende a interpretar a mesma estimativa de forma distinta. Portanto, a avaliação da estimativa salarial é diretamente influenciada pela situação do candidato, que orienta suas expectativas e critérios de decisão.

Especialista 2 [Código: Benefícios]: “Mas não só o valor. Para mim, o ‘quanto’ também diz respeito ao modelo. Acho que há uma evolução: antes, a conversa era só sobre salário, bônus e benefícios. Agora está ficando mais sofisticada. Por exemplo: ‘O salário é X, o bônus é de três salários por ano, mas foi pago nos últimos anos? Quais os critérios?’ Ou: ‘Existe remuneração de longo prazo?’”

De forma semelhante, a decisão do candidato sobre a adequação de um valor salarial não depende apenas do montante estimado, mas também de outros elementos, como benefícios — representados pela variável *Benefícios*, como plano de saúde e alimentação — e aspectos intangíveis, como ambiente organizacional e flexibilidade para trabalho remoto, representados pela variável *Pacote Intangível*. Esses fatores atuam como referências que orientam a avaliação do salário, ancorando as expectativas do usuário em relação à estimativa. Nesse sentido, *Situação de Busca*, *Benefícios* e *Pacote Intangível*, instanciados no domínio de RH, podem ser compreendidos como desdobramentos da variável *Ancoragem de Expectativas* no modelo MEC-AI.

Além da variável *Ancoragem de Expectativas*, a análise qualitativa também evidenciou a relevância da variável *Atribuições do Cargo* e suas ramificações no domínio de RH. Entre essas, destaca-se o *Nível de Impacto da Posição*, que se refere ao grau de responsabilidade e influência organizacional associado ao cargo. Cargos com maior impacto, como posições de diretoria, tendem a apresentar maior flexibilidade na negociação salarial, o que influencia a forma como a estimativa é interpretada. Adicionalmente, as atribuições do cargo variam significativamente conforme o contexto organizacional, como porte e setor da empresa. Por exemplo, funções gerenciais em grandes organizações podem envolver maior complexidade e responsabilidade do que cargos equivalentes em empresas menores, o que afeta diretamente a percepção de adequação da estimativa salarial. Dessa forma, as *Atribuições do Cargo* constituem um conjunto de fatores contextuais que influenciam tanto a formação quanto a interpretação do valor estimado.

De maneira complementar, a variável *Fatores Econômicos* também se destacou na análise como elemento relevante para contextualizar a estimativa salarial. Suas ramificações incluem aspectos como orçamento organizacional e contexto socioeconômico, que condicionam a capacidade da empresa de oferecer determinados níveis de remuneração. Em cenários econômicos favoráveis, políticas salariais tendem a ser mais competitivas, enquanto contextos de restrição orçamentária podem resultar em ofertas mais conservadoras. Esses fatores, embora não estejam explicitamente representados

específica. Observou-se que explicações baseadas apenas em variáveis estruturadas, embora tecnicamente informativas, não são suficientes para sustentar uma comunicação inteligível no contexto organizacional, pois desconsideram aspectos pessoais, organizacionais e situacionais relevantes à interpretação do salário.

Para enfrentar essa lacuna, foram conduzidas entrevistas com cinco especialistas de RH com o objetivo de elicitare os elementos contextuais necessários para enriquecer a explicação. A partir dessa análise, foi definido um modelo conceitual baseado na integração de fatores contextuais como ancoragem de expectativas, atribuições do cargo e fatores econômicos, permitindo estruturar o conhecimento de domínio de forma a apoiar a interpretação da estimativa.

Assim, esta pesquisa apresenta o modelo MEC-AI como uma contribuição conceitual para a explicabilidade em IA, ao propor um mecanismo de incorporação de conhecimento de domínio sensível ao contexto do usuário. Ao estruturar fatores pessoais, organizacionais e de mercado, o modelo atende a demandas centrais de sistemas de RH, como suporte à negociação, mitigação de vieses e adoção de abordagens sensíveis ao contexto [Pinto et al. 2025]. Além disso, posiciona-se como um mecanismo de mediação sociotécnica, ao articular a interpretação entre sistemas de IA e diferentes atores humanos.

O modelo define uma estrutura conceitual para a construção de um artefato de explicação contextualizada [Mei et al. 2025], ampliando a XAI tradicional por meio da integração estruturada de fatores relevantes à interpretação da estimativa. A incorporação de conhecimento de domínio para contextualizar explicações também se mostra aplicável a outros domínios caracterizados por assimetria de informação. Nesse sentido, o MEC-AI orienta o desenvolvimento de um mecanismo de recuperação contextual a ser integrado a um modelo de linguagem, responsável por gerar explicações em linguagem natural mais alinhadas ao contexto de uso. Atualmente, a pesquisa encontra-se na fase de refinamento da estrutura contextual e preparação de avaliações com usuários, com o objetivo de validar seu impacto na compreensão e na confiança nas estimativas geradas.

Referências

- Akbari, S. and Hauswirth, M. (2024). Sampling in cloud benchmarking: A critical review and methodological guidelines. In *2024 IEEE International Conference on Cloud Computing Technology and Science (CloudCom)*, pages 160–167. IEEE.
- Akerlof, G. A. (1978). The market for “lemons”: Quality uncertainty and the market mechanism. In *Uncertainty in economics*, pages 235–251. Elsevier.
- Ali, S., Abuhmed, T., El-Sappagh, S., Muhammad, K., Alonso-Moral, J. M., Confalonieri, R., Guidotti, R., Del Ser, J., Díaz-Rodríguez, N., and Herrera, F. (2023). Explainable artificial intelligence (xai): What we know and what is left to attain trustworthy artificial intelligence. *Information fusion*, 99:101805.
- Berger, L. A., Berger, D. R., and Berger, L. A. (2008). *The compensation handbook*, volume 5. McGraw-Hill New York.
- Bertrand, A., Belloum, R., Eagan, J. R., and Maxwell, W. (2022). How cognitive biases affect xai-assisted decision-making: A systematic review. In *Proceedings of the 2022 AAAI/ACM Conference on AI, Ethics, and Society*, pages 78–91.

- Bicharra, A. C. (1992). Active design documents: a new approach for supporting documentation in preliminary routine design.
- Braun, V. and Clarke, V. (2006). Using thematic analysis in psychology. *Qualitative research in psychology*, 3(2):77–101.
- Bujold, A., Roberge-Maltais, I., Parent-Rochelleau, X., Boasen, J., Sénécal, S., and Léger, P.-M. (2024). Responsible artificial intelligence in human resources management: a review of the empirical literature. *AI and Ethics*, 4(4):1185–1200.
- Caccamo, M., Pittino, D., and Tell, F. (2023). Boundary objects, knowledge integration, and innovation management: A systematic review of the literature. *Technovation*, 122:102645.
- Černevičienė, J. and Kabašinskas, A. (2024). Explainable artificial intelligence (xai) in finance: A systematic literature review. *Artificial Intelligence Review*, 57(8):216.
- Corseuil, C. H. L., Foguel, M. N., and Gonzaga, G. (2016). A aprendizagem e a inserção de jovens no mercado de trabalho: uma análise com base na raiz.
- Cullen, Z., Li, S., and Perez-Truglia, R. (2025). What’s my employee worth? the effects of salary benchmarking. *Review of Economic Studies*, page rdaf083.
- Das, S., Chakraborty, S., Sajjan, G., Majumder, S., Dey, N., and Tavares, J. M. R. (2022). Explainable ai for predictive analytics on employee attrition. In *International Conference on Soft Computing and its Engineering Applications*, pages 147–157. Springer.
- Eichinger, F. and Mayer, M. (2022). Predicting salaries with random-forest regression. In *Machine Learning and Data Analytics For Solving Business Problems: Methods, Applications, and Case Studies*, pages 1–21. Springer.
- Fabeyo, S. (2025). Explainable ai in employment decision-making: a systematic review of transparency methods in hiring algorithms. *Issues in Information Systems*, 26(3).
- Fidel, G., Bitton, R., and Shabtai, A. (2020). When explainability meets adversarial learning: Detecting adversarial examples using shap signatures. In *2020 international joint conference on neural networks (IJCNN)*, pages 1–8. IEEE.
- Hooshyar, D. and Yang, Y. (2024). Problems with shap and lime in interpretable ai for education: A comparative study of post-hoc explanations and neural-symbolic rule extraction. *IEEE Access*, 12:137472–137490.
- Klein, H. K. and Myers, M. D. (1999). A set of principles for conducting and evaluating interpretive field studies in information systems. *MIS quarterly*, pages 67–93.
- Lee, A. S. and Liebenau, J. (1997). Information systems and qualitative research. In *Information Systems and Qualitative Research: Proceedings of the IFIP TC8 WG 8.2 International Conference on Information Systems and Qualitative Research, 31st May–3rd June 1997, Philadelphia, Pennsylvania, USA*, pages 1–8. Springer.
- Lundberg, S. (2017). A unified approach to interpreting model predictions. *arXiv preprint arXiv:1705.07874*.
- Mancha, A. and Mattos, E. (2020). Public versus private wage differential in brazilian public firms. *Economia*, 21(1):1–17.

- Marra, T. and Kubiak, E. (2024). Addressing diversity in hiring procedures: a generative adversarial network approach. *AI and Ethics*, pages 1–25.
- Mei, L., Yao, J., Ge, Y., Wang, Y., Bi, B., Cai, Y., Liu, J., Li, M., Li, Z.-Z., Zhang, D., et al. (2025). A survey of context engineering for large language models. *arXiv preprint arXiv:2507.13334*.
- Ministério do Trabalho e Emprego (2025). Relação anual de informações sociais (rais). <https://www.rais.gov.br/sitio/index.jsf>. Acesso em 28 fev. 2026.
- Mohammed, A., Khalifa, G. S., and Alhammedi, F. H. (2025). Evaluating responsible ai adaption: Ethics, bias mitigation, and governance. In *2025 10th International Conference on Information Technology Trends (ITT)*, pages 235–240. IEEE.
- Naudé, M., Adebayo, K. J., and Nanda, R. (2023). A machine learning approach to detecting fraudulent job types. *AI & SOCIETY*, 38(2):1013–1024.
- Özer, Ş. D. İ., Ülke, B., Daniş, F. S., and Orman, G. K. (2022). Salary prediction via sectoral features in turkey. In *2022 International Conference on INnovations in Intelligent SysTems and Applications (INISTA)*, pages 1–6. IEEE.
- Pessach, D., Singer, G., Avrahami, D., Ben-Gal, H. C., Shmueli, E., and Ben-Gal, I. (2020). Employees recruitment: A prescriptive analytics approach via machine learning and mathematical programming. *Decision Support Systems*, 134:113290.
- Pinto, G. B. S., de Mello, C. E., and Garcia, A. C. B. (2025). Explainable ai in labor market applications. *ICAART (3)*, pages 1450–1457.
- Ribeiro, M. T., Singh, S., and Guestrin, C. (2016). ”why should i trust you?” explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*, pages 1135–1144.
- Rigotti, C. and Fosch-Villaronga, E. (2024). Fairness, ai & recruitment. *Computer Law & Security Review*, 53:105966.
- Sarker, S., Xiao, X., and Beaulieu, T. (2013). Guest editorial: Qualitative studies in information systems: A critical review and some guiding principles1. *MIS quarterly*, 37(4):ii–xviii.
- Schultze, U. and Avital, M. (2011). Designing interviews to generate rich data for information systems research. *Information and organization*, 21(1):1–16.
- Sibona, C., Walczak, S., and White Baker, E. (2020). A guide for purposive sampling on twitter. *Communications of the association for information systems*, 46(1):22.
- Siswanto, J. V., Castilani, L. A., Winata, N. H., Nugraha, N. C., and Sagala, N. T. (2023). Salary classification & prediction based on job field and location using ensemble methods. In *2023 International Conference on Computer Science, Information Technology and Engineering (ICCoSITE)*, pages 325–330. IEEE.
- Smith, A. R., Colombi, J. M., and Wirthlin, J. R. (2013). Rapid development: A content analysis comparison of literature and purposive sampling of rapid reaction projects. *Procedia Computer Science*, 16:475–482.
- Spence, M. (1978). Job market signaling. In *Uncertainty in economics*, pages 281–306. Elsevier.

- Star, S. L. and Griesemer, J. R. (1989). Institutional ecology, translations' and boundary objects: Amateurs and professionals in Berkeley's museum of vertebrate zoology, 1907-39. *Social studies of science*, 19(3):387-420.
- Stiglitz, J. E. (1975). The theory of 'screening,' education, and the distribution of income. *The American economic review*, 65(3):283-300.
- Sun, Y., Ji, Y., Zhu, H., Zhuang, F., He, Q., and Xiong, H. (2024). Market-aware long-term job skill recommendation with explainable deep reinforcement learning. *ACM Transactions on Information Systems*.
- Tran, H. X., Le, T. D., Li, J., Liu, L., Liu, J., Zhao, Y., and Waters, T. (2021). Recommending the most effective intervention to improve employment for job seekers with disability. In *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining*, pages 3616-3626.
- Vemulapati, J., Bayyana, A., Bathula, S. H., Tokala, S., Hajarathaiyah, K., and Enduri, M. K. (2023). Empirical analysis of income prediction using deep learning techniques. In *2023 IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS)*, pages 1-6. IEEE.
- Wainer, J. et al. (2007). Métodos de pesquisa quantitativa e qualitativa para a ciência da computação. *Atualização em informática*, 1(221-262):32-33.
- Werth, O., Köhlke, J. P., and Nickerson, R. (2024). Beyond the border—a taxonomic analysis of the adoption of boundary objects in information systems research.
- Zhang, Q., Zhu, H., Sun, Y., Liu, H., Zhuang, F., and Xiong, H. (2021). Talent demand forecasting with attentive neural sequential model. In *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining*, pages 3906-3916.