



www.aileaders-project.eu

SIMULAÇÃO - Desafios éticos

na análise
financeira



Co-funded by
the European Union

Co-funded by the European Union. Views and opinions expressed are however those of the author or authors only and do not necessarily reflect those of the European Union or the Foundation for the Development of the Education System. Neither the European Union nor the entity providing the grant can be held responsible for them.



SIMULAÇÃO

- Desafios éticos na análise financeira

- 01** •  **Resumo** 3
- 02** •  **Introdução** 4
- 03** •  **Apresentação das ferramentas** 5
- 04** •  **Execução da simulação** 6
- 05** •  **Conclusões** 7
- 06** •  **Referências** 8

• 01 Resumo



Tipo de REA

Demonstração/Simulação utilizando o Google Colab (RandomForest vs FairGBM Classifier)

Objetivo/Finalidade

Proporcionar aos estudantes uma exploração prática e crítica de como a tomada de decisões algorítmicas na análise e previsão financeira pode reproduzir desigualdades estruturais, comparando os resultados de métricas de equidade. Esta simulação incentiva a reflexão sobre as dimensões éticas da automação financeira e promove o desenvolvimento de modelos preditivos mais justos e inclusivos.

Resultados de aprendizagem esperados

Ao final da simulação, os estudantes serão capazes de:

- 01** Detetar e interpretar o viés algorítmico na aprovação de crédito;
- 02** Refletir sobre as implicações éticas das decisões financeiras automatizadas.
- 03** Utilizar métricas de equidade para avaliar os resultados do modelo;

Palavras-chave

- Aprendizagem automática
- Classificação
- Preconceitos
- Equidade

Sugerido Abordagem metodológica

Aprendizagem baseada em problemas

NOTA

É necessário ter conhecimentos intermédios de **programação Python** para compreender e trabalhar com o conteúdo deste REA.

• 02 Introdução



Ferramentas de previsão financeira baseadas em IA estão a ser cada vez mais adotadas para automatizar decisões relacionadas com crédito, como aprovações de empréstimos e avaliações de risco (ver, por exemplo, Chen, 2020; Dastile et al., 2020; Chen et al., 2024; Heß & Damásio, 2025). Essas tecnologias oferecem benefícios consideráveis em termos de eficiência, consistência e escalabilidade. No entanto, quando implementadas em contextos historicamente moldados por desigualdades estruturais, elas levantam questões éticas significativas.

Uma questão central é o potencial desses sistemas de replicar — ou mesmo amplificar — preconceitos existentes incorporados nos dados financeiros. Algoritmos que parecem neutros podem, quando treinados com conjuntos de dados tendenciosos ou incompletos, produzir resultados injustos que afetam desproporcionalmente grupos já marginalizados ou vulneráveis.

Um exemplo particularmente convincente é o das mulheres (Orser et al., 2006; Ongena & Popov, 2016; Moro et al., 2017; Beck et al., 2018; De Andrés et al., 2021, entre outros) e indivíduos negros (Chatterji & Seamans, 2012), que continuam a encontrar barreiras no acesso ao crédito de instituições financeiras tradicionais devido a formas interseccionais de discriminação.

Este exercício baseado em simulação convida os alunos a explorar criticamente a interseção entre aprendizagem automática, previsão financeira e equidade. Utilizando um conjunto de dados sintéticos que reflete pedidos de crédito realistas, os estudantes investigarão como atributos como gênero, ocupação, educação e estado civil influenciam os resultados da aprovação de empréstimos. O conjunto de dados foi

deliberadamente construído para codificar padrões subtils de preconceito, oferecendo uma oportunidade prática para detectar, analisar e mitigar disparidades por meio de um conjunto de experiências.

Com base na literatura mais ampla sobre inclusão financeira e lacunas de financiamento, este exercício desafia os estudantes a refletir sobre como os sistemas de IA podem reforçar ou confrontar a injustiça sistémica. Ao fazê-lo, eles não só ganharão competências técnicas em auditoria de equidade e mitigação de preconceitos, mas também desenvolverão uma compreensão crítica das responsabilidades éticas associadas à conceção e implementação de IA em ecossistemas financeiros.



• 03 Apresentação das ferramentas



O cenário principal apresentado nesta simulação centra-se num conjunto de dados sintéticos de pedidos de empréstimos.

Os dados incluem características demográficas e socioeconómicas, tais como

- Género
- Raça
- Idade
- Ocupação
- Nível de escolaridade
- Estado civil

A variável-alvo é a aprovação do empréstimo, modelada como um problema de classificação binária.

Embora o conjunto de dados tenha sido construído para refletir condições realistas, ele incorpora intencionalmente padrões ocultos de preconceito. Por exemplo, mulheres empresárias rurais podem enfrentar taxas de rejeição mais altas do que seus colegas homens ou urbanos, mesmo quando se controlam as qualificações e os fatores de risco. Isso simula como barreiras históricas e sistémicas podem ser replicadas em sistemas automatizados.

O objetivo é investigar duas questões principais

- 01** Os algoritmos de ML “recomendam” de forma desproporcional a rejeição de pedidos de crédito apresentados por indivíduos negros e mulheres em modelos preditivos binários?
- 02** Que fatores estruturais ou algorítmicos podem contribuir para essa disparidade?

• 04 Execução da simulação



01 Acesse o Caderno de Simulação

Aceda a <https://tinyurl.com/2txxdk9s>

02 Execute o código

Execute todas as células do caderno sequencialmente. Certifique-se de que não ocorram erros e que todas as saídas sejam exibidas corretamente. Para isso, clique em reproduzir no canto superior esquerdo de cada célula.

03 Explore o conjunto de dados¹

Analise a estrutura e o conteúdo do conjunto de dados. Preste muita atenção às principais variáveis demográficas, como sexo, ocupação, escolaridade e resultado do empréstimo. Observe quaisquer potenciais desequilíbrios ou padrões que possam indicar preconceito.

04 Analise a equidade

Examine os resultados. Compare as taxas de aprovação entre diferentes grupos demográficos, com foco especial em gênero e raça. Use as métricas de equidade fornecidas no caderno (por exemplo, paridade demográfica, impacto desigual) para quantificar possíveis preconceitos.

05 Compare os resultados

Compare cuidadosamente os resultados do modelo antes e depois de aplicar intervenções de equidade, se incluídas.

06 Reflita sobre as conclusões

Com base nos resultados observados, reflita sobre as implicações éticas e práticas do uso da IA na tomada de decisões financeiras. Considere as compensações entre precisão, eficiência e equidade.

1. Tutorial da ferramenta What If - <https://www.youtube.com/watch?v=jHojeFCc5HE>

• 05 Conclusão



Os dados em que nos baseámos para esta simulação são amplamente utilizados para estudar a equidade e o preconceito na aprendizagem automática, devido à inclusão de atributos sensíveis, como género e raça. São comumente utilizados para prever se o rendimento de um indivíduo excede US\$ 50.000 por ano com base em características como idade, escolaridade, ocupação e estado civil.

A nossa simulação demonstra como os sistemas de previsão financeira baseados em IA, se não forem examinados, podem perpetuar preconceitos estruturais incorporados nos dados históricos.



Elá revela que a precisão preditiva da rejeição de crédito em modelos binários é maior para indivíduos negros e mulheres do que para indivíduos brancos e homens.

• Resumo dos resultados



Precisão na previsão de decisões de rejeição de crédito — ou seja, verdadeiros «negativos» (%)

Negros

97
FEMININO

91%
HOMENS

Branco

94
MULHER

86
MASCULINOS

Mesmo em modelos simplificados como o que temos em mãos, a presença de resultados tendenciosos — como a menor percentagem de falsos negativos nas taxas de rejeição previstas para indivíduos negros e mulheres — destaca a responsabilidade ética dos desenvolvedores e analistas de auditar e refinar os sistemas de IA. Esses resultados reacendem a discussão sobre pontos cegos nos modelos de pontuação de crédito (ver, por exemplo, Robb & Robinson, 2018).

Ao envolverem-se diretamente com métricas de

equidade e estratégias de mitigação, os alunos não só adquirem ferramentas técnicas para identificar preconceitos, mas também desenvolvem uma compreensão mais profunda de como esses preconceitos se manifestam e como podem ser abordados. Este exercício reforça o princípio de que a equidade na IA financeira não é uma preocupação secundária, mas um componente central da inovação responsável e sustentável.

• 06 Referências



- Beck, T., Behr, P., & Madestam, A. (2011). Sexo e crédito: existe preconceito de género na concessão de empréstimos? Documento de discussão do Centro Bancário Europeu, (2011-027).
- Chatterji, A. K., & Seamans, R. C. (2012). Finanças empresariais, cartões de crédito e raça. *Jornal de Economia Financeira*, 106(1), 182-195.
- Chen, T. H. (2020). Conhece o seu cliente? Avaliação de risco bancário com base em aprendizagem automática. *Applied Soft Computing*, 86, 105779.
- Chen, Y., Calabrese, R., & Martin-Barragan, B. (2024). Aprendizagem automática interpretável para conjuntos de dados de pontuação de crédito desequilibrados. *European Journal of Operational Research*, 312(1), 357-372.
- Dastile, X., Celik, T., & Potsane, M. (2020). Modelos estatísticos e de aprendizagem automática na pontuação de crédito: uma revisão sistemática da literatura. *Applied Soft Computing*, 91, 106263.
- De Andrés, P., Gimeno, R., & de Cabo, R. M. (2021). A disparidade de género no acesso ao crédito bancário. *Jornal de Finanças Corporativas*, 71, 101782.
- Heß, V. L., & Damásio, B. (2025). Aprendizagem automática na gestão de risco bancário: mapeando uma década de evolução. *International Journal of Information Management Data Insights*, 5(1), 100324.
- Moro, A., Wisniewski, T. P., & Mantovani, G. M. (2017). O género de um gestor é importante no acesso ao crédito? Evidências a partir de dados europeus. *Journal of banking & finance*, 80, 119-134.
- Ongena, S., & Popov, A. (2016). Preconceito de género e acesso ao crédito. *Revista de Dinheiro, Crédito e Banca*, 48(8), 1691-1724.
- Orser, B. J., Riding, A. L., & Manley, K. (2006). Mulheres empresárias e capital financeiro. *Teoria e prática do empreendedorismo*, 30(5), 643-665.
- Robb, A., & Robinson, D. T. (2018). Testes de preconceito racial nas pontuações de crédito empresarial. *Small Business Economics*, 50, 429-443.



leaders

Acompanhe a nossa jornada



www.aileaders-project.eu



Co-funded by
the European Union

Co-funded by the European Union. Views and opinions expressed are however those of the author or authors only and do not necessarily reflect those of the European Union or the Foundation for the Development of the Education System. Neither the European Union nor the entity providing the grant can be held responsible for them.