



www.aileaders-project.eu

Modelos de IA tendenciosos utilizados para pontuação de crédito



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.

Este documento é um estudo de caso sobre como dados tendenciosos ou não representativos podem levar a resultados indesejáveis, discriminação e exclusão através do uso de serviços automatizados de pontuação de crédito. O estudo de caso analisa o surgimento e o crescimento de sistemas automatizados de decisão de crédito que utilizam algoritmos para analisar vários pontos de dados para avaliar a solvabilidade de um indivíduo e decidir aprovar ou recusar um pedido de crédito.

O caso centra-se no funcionamento dos sistemas de pontuação de crédito, utilizando uma simulação para ilustrar que tipo de pontos de dados recolhem e que tipo de dados pessoais utilizam para tomar decisões. O estudo de caso também nos sensibiliza para as questões geradas por conjuntos de dados tendenciosos ou não representativos e como estes podem tornar os sistemas de pontuação de crédito injustos, funcionando como barreiras e não como melhorias na forma como os cidadãos podem aceder a serviços de crédito e empréstimo em condições justas.

Objetivo/Finalidade

O objetivo deste estudo de caso é aumentar a consciencialização sobre o potencial dos sistemas automatizados de pontuação de crédito para melhorar o acesso ao crédito, bem como sobre os desafios e riscos para a privacidade e a discriminação que a utilização destes sistemas acarreta, particularmente quando são utilizados conjuntos de dados tendenciosos e também quando os modelos são treinados com dados que não são representativos de algumas populações.



Resultados de aprendizagem esperados

- 01** O aluno será capaz de **identificar** riscos éticos nos modelos de pontuação de crédito e propor medidas corretivas.
- 02** O aluno **compreenderá** as principais questões éticas nas aplicações de IA para empréstimos e pontuação de crédito, incluindo preconceito, discriminação, transparência e privacidade de dados.

Abordagem metodológica sugerida

Este caso funciona melhor como aprendizagem baseada em problemas, na qual os instrutores devem orientar uma discussão com os alunos, uma vez que estes se familiarizaram com conceitos relacionados com o acesso ao crédito, serviços de pontuação de crédito, bem como práticas contemporâneas de solicitação de crédito e empréstimos. São fornecidos tópicos para discussão, preocupações e possíveis soluções, mas os instrutores devem incentivar os alunos a pensar por conta própria e a identificar outras possíveis preocupações que possam ter. São fornecidos exemplos e leituras complementares através de links, bem como do acesso a uma simulação destinada a ilustrar que tipo de dados pessoais são usados na avaliação de crédito automatizada e que tipos de resultados esses sistemas produzem.



Palavras-chave

Empréstimos, pontuação de crédito, privacidade e proteção de dados pessoais, transparência, preconceito, discriminação

Acesso automatizado ao crédito

Talvez já tenha visto várias ofertas online de empresas de cartões de crédito que prometem aprovar um cartão de crédito novo (e a linha de crédito correspondente) em apenas um ou dois dias. Algumas prometem calcular o seu limite de crédito em poucos minutos e autorizar a sua utilização «imediatamente».

Talvez já tenha visto várias ofertas online de empresas de cartões de crédito que prometem aprovar um cartão de crédito novo (e a linha de crédito correspondente) em apenas um ou dois dias. Algumas prometem calcular o seu limite de crédito em poucos minutos e autorizar a sua utilização «imediatamente». Os pedidos de crédito automatizados online tornaram o processo mais fácil e muito mais rápido, calculando a pontuação de crédito quase instantaneamente. Isso pode fornecer às empresas recomendações e/ou aprovações automatizadas sobre uma variedade de produtos financeiros — não apenas cartões de crédito, mas também outros produtos, como empréstimos pessoais ou hipotecas, ao mesmo tempo em que calcula e faz uma oferta sobre as taxas de juros que devem ser pagas por cada um desses produtos.

As pontuações de crédito são modelos baseados em computador que correlacionam uma série de fatores com a probabilidade de que alguém possa entrar em incumprimento no pagamento da sua dívida. Por outras palavras, uma pontuação de crédito representa a solvabilidade de alguém ou a sua capacidade e fiabilidade para reembolsar um determinado empréstimo. As pontuações de crédito baseiam-se no histórico de crédito de uma pessoa, construído em torno de uma série de pontos de dados, tais como o número de contas que possui e há quanto tempo cada uma está aberta, os seus níveis totais de dívida, os seus registos de reembolso, os tipos de empréstimos que possui, a duração das suas transações de crédito, a proporção da dívida que está a utilizar e se solicitou novas contas num determinado período de tempo. Ao utilizar esses dados, as pontuações de crédito podem separar os bons riscos de crédito dos maus e classificar os potenciais mutuários para prever a sua probabilidade de incumprimento.

No setor financeiro, os bancos e as instituições financeiras utilizam as pontuações de crédito para tomar decisões de financiamento; as seguradoras utilizam-nas para avaliar o perfil de risco dos segurados; os retalhistas utilizam-nas para planos de parcelamento; as concessionárias de automóveis utilizam-nas para avaliar a elegibilidade e os termos do financiamento de automóveis; etc.. Até mesmo as empresas de telecomunicações recorrem à pontuação de crédito para decidir se uma pessoa é elegível para planos pós-pagos ou para determinar se podem “oferecer” um

telefone novo para ser financiado e pago em prestações.

A inteligência artificial e a aprendizagem automática

utilizam modelos estatísticos e análise de dados para tornar o processo de avaliação de crédito mais rápido e simplificado. Isto permite maior rapidez e, potencialmente, maior precisão e confiança nas decisões de empréstimo. Nos últimos anos, o setor bancário e de crédito começaram a oferecer vários produtos **FinTech** (*tecnologia financeira*) que oferecem soluções automatizadas para a tomada de decisões de crédito.

As decisões de crédito baseadas em IA podem potencialmente **melhorar a eficiência e o desempenho, reduzindo os custos para as instituições financeiras, o que também pode beneficiar os consumidores, expandindo o acesso ao crédito ou tornando-o menos caro**.¹ «Os novos modelos de alto desempenho permitem que os bancos definam parâmetros de empréstimo (e capital) com mais precisão e, assim, aprimorem a sua capacidade de aprovar clientes com boa capacidade de crédito e rejeitar propostas de clientes que não têm boa capacidade de crédito ou não podem arcar com mais dívidas. Na verdade, os bancos (e empresas de tecnologia financeira) que implementaram esses novos modelos já aumentaram a receita, reduziram as taxas de perda de crédito e obtiveram ganhos significativos de eficiência graças a decisões mais precisas e automatizadas²».

No entanto, existem vários riscos e desvantagens que exploraremos durante este estudo de caso. Entre eles está a falta de explicabilidade ou a incapacidade de explicar por que os programas tomam decisões. Outro é o impacto desigual ou a discriminação que pode afetar certos grupos mais do que outros devido às práticas comerciais (como a forma como se tomam decisões de empréstimo). Isso, como veremos, está diretamente relacionado ao uso de dados falhos ou tendenciosos para tomar decisões de crédito, o que pode resultar em um acesso mais difícil e não mais fácil ao crédito para alguns coletivos, agravando assim a desigualdade no acesso ao crédito³.

- 1 Serviço de Investigação do Congresso. (2023). *Inteligência artificial generativa: visão geral, questões e perguntas para o Congresso* (Relatório CRS n.º IF12399). <https://crsreports.congress.gov/product/pdf/IF/IF12399>
- 2 Dash, R., Kremer, A., & Petrov, A. (2021). *Conceção de modelos de decisão de crédito de última geração*. McKinsey & Company. <https://www.mckinsey.com/capabilities/risk-and-resilience/our-insights/designing-next-generation-credit-decisioning-models>
- 3 Andrews, E. L. (6 de agosto de 2021). *Como dados falhos agravam a desigualdade no crédito*. Stanford HAI. <https://hai.stanford.edu/news/how-flawed-data-aggravates-inequality-credit>

Modelos de dados e decisões de crédito baseadas em IA

Crédito baseado em IA - Vantagens específicas

As decisões de empréstimo tomadas com a ajuda da Inteligência Artificial têm vantagens potenciais que vão além das melhorias na eficiência e da redução dos custos associados à disponibilização de crédito às pessoas, tornando-o menos dispendioso.

Potencialmente, a aprendizagem automática na pontuação de crédito também pode expandir o número e a natureza dos pontos de dados que influenciam a avaliação da solvabilidade das pessoas, bem como pode oferecer a possibilidade de criar pontuações para comunidades que têm sido cronicamente sub-bancarizadas e conceder **acesso a soluções bancárias e de empréstimo para comunidades inteiras e indivíduos** que têm sido tradicionalmente excluídos das instituições financeiras formais. Ao oferecer alternativas através da incorporação de uma gama mais ampla de dados, a **pontuação baseada em IA** «permite a avaliação de

indivíduos sem histórico de crédito tradicional, examinando fontes de dados alternativas, como transações online, interações nas redes sociais, hábitos de navegação ou uso de aplicativos móveis».⁴ Para aqueles com registos bancários e financeiros tradicionais, a pontuação baseada em IA pode fornecer uma análise mais precisa e aprimorada para tornar as decisões de pontuação de crédito e empréstimos mais precisas. Para aqueles que não possuem históricos tradicionais, ela pode oferecer a possibilidade de acesso a crédito e outros serviços bancários.

Fontes de dados tradicionais de pontuação de crédito

- cartões de crédito e linhas de crédito abertas
- empréstimos para automóveis
- hipotecas
- histórico de pagamentos de crédito
- históricos de consultas de crédito
- pedidos de falência

Fontes alternativas de dados de pontuação de crédito

- dados de fluxo de caixa
- pagamentos de contas
- dados de aluguer
- registos de emprego
- registos de infrações de trânsito ou disputas
- padrões de utilização de dados de telecomunicações e telemóveis
- dados de redes sociais
- dados comportamentais
- pagamentos de impostos

Imagem 1. Exemplos de dados de crédito tradicionais e alternativos.

Fonte: <https://www.afi-global.org/wp-content/uploads/2025/02/Alternative-Data-for-Credit-Scoring.pdf>

Atualmente, há uma grande parte da população mundial considerada como consumidores invisíveis ao crédito (sem acesso) ou com crédito insuficiente (acesso precário em más condições). Só nos Estados Unidos, estima-se que 45 milhões de consumidores não sejam atendidos ou sejam mal atendidos pelos modelos de crédito tradicionais⁵. Em países como a Índia e a África do Sul, mais da metade da população não tem boas opções para acessar crédito⁶. Onde havia acesso, existe o potencial de torná-lo mais justo e eficiente, enquanto onde não era possível ter acesso ao crédito, existe o potencial de finalmente torná-lo acessível, garantindo também que esse acesso seja igualmente eficiente e justo.

Existe um grande potencial para modelos de pontuação de crédito mais inclusivos e sustentáveis que, por sua vez, podem promover o progresso e a segurança financeira para uma população mais ampla; mais pessoas do que nunca têm o potencial de ter acesso a serviços bancários e financeiros que, por sua vez, podem dar lugar a produtos de empréstimo mais competitivos no mercado, o que pode acabar por tornar o crédito mais acessível⁷.

Então, por que estamos preocupados que as decisões de crédito baseadas em IA possam aumentar, e não diminuir, a exclusão financeira?

4 Bag, S. (2024). IA e pontuação de crédito: a vantagem algorítmica e a precaução. Observer Research Foundation. <https://www.orfonline.org/expert-speak/ai-and-credit-scoring-the-algorithmic-advantage-and-precaution>

5 TransUnion. (2022). Mais de 45 milhões de americanos não têm acesso ao crédito ou têm acesso insuficiente; aproximadamente 20% passam a ter crédito ativo a cada dois anos. TransUnion. https://newsroom.transunion.com/more-than-45-million-americans-are-either-credit-unserved-or-underserved--approximately-20-migrate-to-being-credit-active-every-two-years#_edn1

6 Equipa Svitla. (2024). Aprendizagem automática para pontuação de crédito: benefícios, modelos e desafios de implementação. Svitla Systems. <https://svitla.com/blog/machine-learning-for-credit-scoring/>

7 Aliança para a Inclusão Financeira. (2025). Dados alternativos para pontuação de crédito. <https://www.afi-global.org/wp-content/uploads/2025/02/Alternative-Data-for-Credit-Scoring.pdf>

Pontuação de crédito e uso de dados pessoais

Processo de aprovação de crédito: a pontuação de crédito e a aprovação de crédito envolvem processos complexos que ocorrem nos bastidores para que uma decisão seja tomada

Este processo inclui informações fornecidas pelo requerente, pelo banco ou entidade financeira, por uma agência de crédito e por uma agência de pontuação de crédito. Uma pessoa e as outras entidades fornecem uma grande quantidade de dados para o processo, incluindo os dados pessoais do requerente. Aqui está uma imagem que mostra de forma resumida como o processo funciona. Como se pode ver, ela não apenas mapeia as entidades envolvidas, mas também mostra as camadas de segurança utilizadas para proteger os dados empregados para a pontuação de crédito e a decisão subsequente.



Imagem 2. Um diagrama que descreve o processo de pontuação de crédito e decisão de empréstimo.

te: https://huggingface.co/spaces/zama-fhe/encrypted_credit_scoring

O formulário apresenta perguntas sobre o perfil do usuário para avaliação de crédito. No topo, há uma pergunta: 'Which of the following do you actively hold or own?' com opções 'Car', 'Property' (selecionada) e 'Mobile phone'. Abaixo, há quatro sliders para: 'Number of children' (valor 3), 'Household size' (valor 3), 'Income' (valor 35900) e 'Age' (valor 30). Cada slider tem uma barra deslizante e um valor numérico fixo à direita. No canto superior direito da imagem, há um círculo laranja com o texto 'CLIQUE PARA VER' e uma seta apontando para o formulário.

Para ilustrar como esse processo funciona e que tipo de dados é necessário inserir para que a sua capacidade de crédito seja avaliada e para que seja tomada a decisão de conceder acesso ao crédito, como um cartão de crédito, **clique na imagem a seguir**. Será demonstrada uma simulação de pontuação de crédito que fornecerá uma avaliação da probabilidade de uma pessoa obter a aprovação de um cartão de crédito.

Os desafios e riscos dos Dados tendenciosos e não representativos

Preocupações com a explicabilidade

Embora os modelos de aprendizagem automática para pontuação de crédito e empréstimos ofereçam várias vantagens, também existem algumas preocupações sérias sobre transparência, justiça e o potencial de reforço de preconceitos, o que, por sua vez, pode levar à exclusão de crédito, e não à inclusão.



Uma preocupação específica é a **falta de explicabilidade** ou a incapacidade de explicar por que os programas de aprendizagem automática tomam determinadas decisões após analisar os dados introduzidos. Este é um problema para os utilizadores dos sistemas, reguladores e terceiros, que podem não ser capazes de compreender e explicar por que um programa agiu de determinada forma e porquê. A capacidade da IA de «reagir a grandes volumes de entradas diversas, além do alcance da capacidade cognitiva humana, também é o calcanhar de Aquiles do ML, uma vez que essa complexidade é frequentemente opaca em termos do processo de tomada de decisão que precede uma decisão».⁸ O Machine Learning que toma decisões tão complexas que não são facilmente interpretadas ou explicadas por humanos é geralmente referido como **Black Box ML** ou **Black Box AI**.⁹

Este é um desafio significativo, porque **limita a transparência e a responsabilização**. Quando um requerente é recusado para um empréstimo, o credor deve ser capaz de explicar o motivo da recusa. Se os credores não conseguirem explicar suficientemente como é que os sistemas automatizados chegaram à decisão, os requerentes podem não ter elementos suficientes para contestar a decisão e podem sentir-se indefesos, minando a confiança na própria instituição

financeira. Além disso, os credores devem garantir que podem fundamentar as suas decisões, a fim de cumprir a legislação que pode exigir que as decisões de crédito e empréstimo tenham motivos claros a serem divulgados aos consumidores.¹⁰

Outro problema é que a **Black Box AI** atrapalha os esforços para melhorar o sistema. Se uma decisão não for adequada, «é **extremamente difícil analisar por que o erro foi cometido ou determinar o que precisa ser feito para corrigir o modelo**».¹¹

Ser capaz de explicar as decisões da IA também é essencial para ganhar a confiança dos utilizadores e garantir que as decisões sejam justas e equitativas, razão pela qual **os métodos para auditar esses sistemas se tornam essenciais**. A explicabilidade geralmente deve concentrar-se em explicar por que «essa entrada específica leva a esse resultado específico»¹², mas algo que é também essencial saber é quais são os dados internos que formam as estruturas de um programa específico. Na secção seguinte, focamo-nos em questões relacionadas com os dados utilizados para treinar os sistemas, que são, em última análise, combinados com os dados específicos enviados por um utilizador e permitem ao sistema de IA gerar uma decisão específica.

⁸ King's College London. (s.d.). Os desafios da explicabilidade da IA. <https://www.kcl.ac.uk/challenges-of-ai-explainability>

⁹ Kosinski, M. (29 de outubro de 2024). O que é IA de caixa preta e como funciona? IBM.

<https://www.ibm.com/think/topics/black-box-ai>

¹⁰ Serviço de Investigação do Congresso. (2023). Inteligência artificial generativa: visão geral, questões e perguntas para o Congresso (Relatório CRS n.º IF12399). <https://crsreports.congress.gov/product/pdf/IF/IF12399>

¹¹ King's College London. (s.d.). Os desafios da explicabilidade da IA. <https://www.kcl.ac.uk/challenges-of-ai-explainability>

¹² Gilpin, L. H., Bau, D., Yuan, B. Z., Bajwa, A., Specter, M., & Kagal, L. (2018). Explicando explicações: uma visão geral da interpretabilidade da aprendizagem automática. ArXiv. <https://arxiv.org/abs/1806.00069>

A falta de diversidade dos conjuntos de dados e os dados imprecisos ou errados

Conforme explicado anteriormente, dados e algoritmos tendenciosos podem fazer com que a tomada de decisão automatizada leve a resultados que colocam em desvantagem aqueles que têm dificuldade em obter um bom crédito ou mesmo serviços financeiros. Minorias e grupos de baixo rendimento geralmente sofrem com esses preconceitos de maneira desproporcional.

No entanto, pesquisas mostram que esse não é o único problema. Resultados diferentes para minorias e majorias não estão relacionados apenas com o preconceito, mas também com o facto de que grupos minoritários e de baixo rendimento têm menos dados nos seus históricos de crédito, porque geralmente são sub-representados no acesso ao crédito¹³. Isso significa que, quando esses dados são usados para calcular uma pontuação de crédito e essa pontuação de crédito é usada para fazer uma previsão sobre incumprimento de empréstimos, essa previsão será menos precisa.

É essa falta de precisão que leva à desigualdade, não apenas o preconceito.¹⁴ A falta de diversidade nos conjuntos de dados para treinar modelos de aprendizagem automática resulta em danos a comunidades específicas, o que aumenta a desigualdade.

As desigualdades sistémicas persistem na curadoria de conjuntos de dados e na desigualdade de acesso. Em alguns campos, isso deve-se também à desigualdade de oportunidades de participar na construção desses conjuntos de dados¹⁵.

O desempenho de qualquer sistema de IA é fortemente determinado pelos conjuntos de dados que analisa usando estatísticas, porque os seus resultados vêm da identificação de padrões nos dados: «A qualidade do conjunto de dados subjacente a um sistema de IA é crucial para a sua eficácia.»¹⁶ No contexto dos empréstimos e do acesso ao crédito, «é um ciclo que se perpetua... Concedemos empréstimos às pessoas erradas e uma parte da população nunca tem a oportunidade de acumular os dados necessários para obter um empréstimo no futuro.»¹⁷

O risco do preconceito algorítmico

Embora uma das vantagens da análise automatizada de pedidos de crédito possa ser a redução da subjetividade no processo de tomada de decisão para a concessão de um empréstimo, existe o risco de que esses processos consolidem «preconceitos e discriminações existentes contra grupos definidos por raça, sexo, orientação sexual e outros atributos»¹⁸, alguns dos quais são categorias especiais de dados pessoais protegidos por lei.¹⁹

Isso ocorre porque os conjuntos de dados geralmente contêm decisões passadas tomadas por instituições financeiras ou porque não contêm dados suficientes sobre determinados grupos, o que pode levar à discriminação.

Se **clique na imagem a seguir**, poderá aceder a uma notícia que explica como o sistema automatizado

de aprovação de cartões de crédito da Apple Card, fornecido pela Goldman Sachs, levou a reclamações de suposta discriminação contra candidatas do sexo feminino, que alegaram ter recebido limites de crédito mais baixos ou terem sido negadas, mesmo que seus maridos tivessem sido aprovados e recebido taxas melhores.



- 13 Blattner, L., & Nelson, S. (2021). Quanto custa o ruído? Dados e disparidades no crédito ao consumidor. ArXiv. <https://arxiv.org/abs/2105.07554>
- 14 Heaven, W. D. (2021). O preconceito não é o único problema com as pontuações de crédito – e não, a IA não pode ajudar. MIT Technology Review. <https://www.technologyreview.com/2021/06/17/1026519/racial-bias-noisy-data-credit-scores-mortgage-loans-fairness-machine-learning/>
- 15 Arora, A., Alderman, J. E., Palmer, et al. (2023). O valor das normas para conjuntos de dados de saúde em aplicações baseadas em inteligência artificial. BMJ Health & Care Informatics, 30(1), e100888. <https://doi.org/10.1136/bmjhci-2023-100888>
- 16 Boch, A., & Kriebitz, A. (29 de setembro de 2023). Diversidade na IA - Rumo a uma declaração do problema. Human Technology Foundation. <https://www.human-technology-foundation.org/news/diversity-in-ai-towards-a-problem-statement>
- 17 Heaven, W. D. (2021). O preconceito não é o único problema com as pontuações de crédito - e não, a IA não pode ajudar. MIT Technology Review. <https://www.technologyreview.com/2021/06/17/1026519/racial-bias-noisy-data-credit-scores-mortgage-loans-fairness-machine-learning/>
- 18 Garcia, A. C. B., Garcia, M. G. P., & Rigobon, R. (2024). Discriminação algorítmica no domínio do crédito: o que sabemos sobre isso? AI & Society, 39, 2059–2098. <https://doi.org/10.1007/s00146-023-01676-3>
- 19 Artigo 9.º do Regulamento Geral sobre a Proteção de Dados: <https://gdpr-info.eu/art-9-gdpr/>

A **recusa de acesso aos mercados de crédito pode ser discriminatória** quando as decisões são enviesadas com base nesses preconceitos pré-existentes. Também pode manifestar-se devido a um tratamento diferenciado que oferece condições mais desfavoráveis àqueles que sofrem discriminação, tais como taxas diferentes e menos vantajosas ou taxas de juro mais elevadas.²⁰

O preconceito nos conjuntos de dados pode **criar mais barreiras ao acesso a serviços financeiros para populações tradicionalmente carentes** que já tinham dificuldade em aceder a esses serviços. Os sistemas tradicionais de pontuação de crédito penalizam aqueles sem histórico formal de crédito, mas mesmo os sistemas que utilizam dados não tradicionais, se apresentarem preconceitos nas suas decisões ou reforçarem os preconceitos dos seus criadores, podem **reforçar a exclusão**, afetando de forma desigual as comunidades carentes.

O **acesso limitado a serviços financeiros tradicionais por certos coletivos pode perpetuar as disparidades de riqueza**. A discriminação passada neste campo levou a efeitos de longo prazo na riqueza geracional geral de certos grupos, com consequências como «propriedade limitada de habitação, oportunidades empresariais reduzidas e disparidades de riqueza geracionais».²¹

Se não forem cuidadosamente concebidos e implementados, **os modelos de IA irão «perpetuar as desigualdades»**²², anulando qualquer possível impacto positivo de um processo de tomada de decisão que reduz a subjetividade apenas no papel, uma vez que acarreta os preconceitos estruturais já presentes na sociedade.

De onde vêm os preconceitos

Os preconceitos algorítmicos podem ter diferentes origens, **incluindo dados de treino tendenciosos**, que podem ser dados históricos que refletem preconceitos sociais existentes. Isto é conhecido como «preconceito dentro, preconceito fora» ou quando um modelo é treinado com dados relacionados a resultados já tendenciosos. É provável que a IA apenas replique os problemas do passado.

A **falta de diversidade** não está presente apenas nos dados. Ela também pode aparecer nas **equipas de design de produtos**: «A homogeneidade entre cientistas de dados e programadores contribui para a perpetuação do preconceito nos sistemas de IA.»²³

A falta de experiência ou compreensão das comunidades carentes pode fazer com que aqueles que projetam os sistemas e fornecem os dados de treino não percebam as suas dificuldades, desafios ou situações específicas, o que pode levar a uma análise imprecisa dos seus históricos de crédito.

Decisões tendenciosas **podem reforçar-se e consolidar-se ao longo do tempo**, à medida que os sistemas fazem avaliações cada vez mais incorretas que são então consideradas válidas, gerando **ciclos de feedback** em que recusas incorretas de crédito para um grupo específico se refletem nos **dados de treino futuros, perpetuando ainda mais a desigualdade e a injustiça**.²⁴

20 Garcia,, A. C. B., Garcia, M. G. P., & Rigobon, R. (2024). Discriminação algorítmica no domínio do crédito: o que sabemos sobre ela? *IA e Sociedade*, 39, 2059–2098. <https://doi.org/10.1007/s00146-023-01676-3>

21 Nuka, T. F., & Osedahunsi, B. O. (2024). Do preconceito ao equilíbrio: integrando DEI em sistemas financeiros impulsionados por IA para promover a equidade de crédito. *International Journal of Science and Research Archive*, 13(2), 1189–1206. <https://doi.org/10.30574/ijrsa.2024.13.2.2257>

22 Nuka, T. F., & Osedahunsi, B. O. (2024). Do preconceito ao equilíbrio: Integrando DEI em sistemas financeiros orientados por IA para promover a equidade de crédito. *Arquivo da Revista Internacional de Ciência e Pesquisa*, 13(2), 1189–1206. <https://doi.org/10.30574/ijrsa.2024.13.2.2257>

23 Nuka, T. F., & Osedahunsi, B. O. (2024). Do preconceito ao equilíbrio: Integrando DEI em sistemas financeiros orientados por IA para promover a equidade de crédito. *Arquivo da Revista Internacional de Ciência e Pesquisa*, 13(2), 1189–1206. <https://doi.org/10.30574/ijrsa.2024.13.2.2257>

24 Nuka, T. F., & Osedahunsi, B. O. (2024). Do preconceito ao equilíbrio: Integrando DEI em sistemas financeiros orientados por IA para promover a equidade de crédito. *Arquivo da Revista Internacional de Ciência e Pesquisa*, 13(2), 1189–1206. <https://doi.org/10.30574/ijrsa.2024.13.2.2257>

Sobre o estudo de caso

Este estudo de caso oferece aos professores a possibilidade de promover discussões em sala de aula sobre vários tópicos relacionados à **inclusão e exclusão financeira**, entre eles os **potenciais e riscos da pontuação de crédito automatizada e das decisões de crédito automatizadas**.

Primeiro, pode começar com uma **discussão sobre pontuação de crédito baseada em IA e serviços financeiros baseados em IA**, discutindo os **méritos da automatização** e o **potencial** do uso de diferentes tipos de **conjuntos de dados para atender a várias populações e focar na inclusão**.

Depois de aprender sobre o **processo de aprovação de crédito**, deve **concentrar-se no uso de dados pessoais para esse tipo de decisão**, uma vez que os modelos baseados em IA exigem conjuntos de dados não apenas para treinamento, mas também para que os utilizadores insiram dados pessoais, conforme demonstrado pela **simulação na página 5 deste estudo de caso**.

Aqui estão algumas sugestões para os seus alunos:



- Acha que há **riscos para a privacidade das pessoas e a proteção de dados pessoais**?
- Se sim, por que acha que **é importante proteger os dados pessoais**?
- Que **consequências** os clientes podem enfrentar se os seus **dados forem divulgados**?
- Além de fugas de dados e outras ameaças à cibersegurança, **que outros riscos pode associar à utilização de dados pessoais para tomar decisões de concessão de empréstimos**?

Deve discutir os desafios com os seus alunos, um por um, e **depois concentrar-se nas soluções**. O estudo de caso inclui algumas referências e leituras adicionais nos anexos abaixo, mas um exercício interessante é dividir os alunos em grupos e pedir-lhes que façam alguma pesquisa para **encontrar possíveis soluções para cada uma das questões apresentadas**. Um ou mais grupos podem concentrar-se na pesquisa sobre questões de explicabilidade, outros em soluções relacionadas ao problema da diversidade nos conjuntos de dados e outros ainda em vieses algorítmicos em geral. Após fazer alguma pesquisa, pode pedir aos alunos que **façam uma breve apresentação para apresentar as soluções que poderiam implementar**.

Pode instruir os alunos a **procurarem soluções que vão desde métodos regulatórios e legislativos até soluções mais técnicas**. Existem ótimos recursos online que abordam esses tópicos, então também é

uma **boa oportunidade para que eles realizem algumas pesquisas nas quais pensem criticamente e identifiquem fontes confiáveis** que proponham **soluções válidas**.

Por fim, se achar que se encaixa no contexto da sua aula, pode **discutir os benefícios e as armadilhas da tendência geral de automatizar a tomada de decisões que podem afetar a vida das pessoas, bem como a necessidade de, pelo menos, ter humanos a supervisionar essas decisões**. Pode articular uma **discussão interessante sobre a necessidade de interação humana e a concessão de oportunidades aos requerentes de crédito versus os méritos das decisões auxiliadas pela automação ou mesmo delegadas a sistemas de IA e o potencial das decisões que eliminam a subjetividade**. Isso é desejável? Isso é mesmo possível? Ou, pelo contrário, algum grau de subjetividade e agência humana é necessário para decisões justas?



Leitura adicional

- Aliança para a Inclusão Financeira. (2025). Dados alternativos para pontuação de crédito. <https://www.afi-global.org/wp-content/uploads/2025/02/Alternative-Data-for-Credit-Scoring.pdf>
- Alonso, A., & Carbó, J. M. (2022). Precisão das explicações dos modelos de aprendizagem automática para decisões de crédito (Documento de Trabalho n.º 2222). Banco de España. <https://www.bde.es/f/webbde/SES/Secciones/Publicaciones/PublicacionesSerias/DocumentosTrabajo/22/Files/dt2222e.pdf>
- Blattner, L., & Nelson, S. (2022). Como dados falhos agravam a desigualdade no crédito. Stanford Graduate School of Business. <https://hai.stanford.edu/news/how-flawed-data-aggravates-inequality-credit>
- Dash, R., Kremer, A., & Petrov, A. (2021). Concebendo modelos de decisão de crédito de última geração. McKinsey & Company. <https://www.mckinsey.com/capabilities/risk-and-resilience/our-insights/designing-next-generation-credit-decisioning-models>
- Heaven, W. D. (2021). O preconceito não é o único problema com as pontuações de crédito – e não, a IA não pode ajudar. MIT Technology Review. <https://www.technologyreview.com/2021/06/17/1026519/racial-bias-noisy-data-credit-scores-mortgage-loans-fairness-machine-learning/>
- Kelion, L. (2019). Cartão de crédito «sexista» da Apple investigado por regulador dos EUA. BBC News. <https://www.bbc.com/news/business-50365609>
- Mensalvas, E., Guzmán, M. A. & Ruiz Bonilla, S. (2022). ML aplicado ao risco de crédito: Construindo modelos explicáveis. <https://blogs.upm.es/catedra-idanae/wp-content/uploads/sites/698/2022/10/Idanae-3Q22.pdf>
- ODSC. (2022). A IA deve decidir quem recebe um empréstimo? Medium. <https://odsc.medium.com/should-ai-decide-who-gets-a-loan-83c6f259081b>