



JUSTIÇA ALGORÍTMICA NA CONCESSÃO DE CRÉDITO AOS MEIS: UMA ANÁLISE DE VIESES EM MODELOS DE MACHINE LEARNING

Lucas de Mattos Lima¹, Paulo Ricardo Borré Reis²

¹Acadêmico do Curso de Engenharia de Software, Campus Maringá-PR, Universidade Cesumar - UNICESUMAR. Bolsista ICETI- UniCesumar. polistudy@proton.me

²Orientador, Mestre, Professor Mediador nos cursos de Tecnologia da Informação, UNICESUMAR. paulo.reis@unicesumar.edu.br

RESUMO

Este estudo investiga a presença de vieses algorítmicos em modelos automatizados de concessão de crédito voltados a Microempreendedores Individuais (MEIs) no Brasil. A pesquisa parte da hipótese de que algoritmos de aprendizado supervisionado treinados com dados históricos desbalanceados podem reproduzir desigualdades estruturais, mesmo sem utilizar variáveis sensíveis diretamente. Adota-se uma abordagem quantitativa e aplicada, com uso de modelos de machine learning, treinados sobre bases públicas internacionais e dados sintéticos gerados a partir de distribuições empíricas brasileiras. As métricas de avaliação incluem indicadores tradicionais de desempenho e métricas de justiça algorítmica (demographic parity, equal opportunity, disparate impact), com o uso de ferramentas como AIF360, Fairlearn e SHAP. A coleta de dados será automatizada por scripts feitos em Python e documentada em notebooks reproduzíveis. Espera-se identificar disparidades sistemáticas na concessão de crédito, propor estratégias de mitigação (pré, in e pós-processamento) e oferecer diretrizes para promover maior transparência, explicabilidade e equidade nos sistemas financeiros automatizados voltados à inclusão dos MEIs.

PALAVRAS-CHAVE: Equidade digital; Inclusão financeira; Justiça algorítmica.

1 INTRODUÇÃO

A concessão de crédito é um fator crucial para a sustentabilidade e o crescimento de microempreendedores individuais (MEIs) no Brasil, que representam mais da metade dos negócios ativos no país. No entanto, a expansão de sistemas automatizados de decisão baseados em algoritmos de aprendizado de máquina (ML) levanta sérias preocupações quanto à justiça algorítmica (*algorithmic fairness*) na avaliação de risco de crédito. Modelos supervisionados treinados com dados históricos podem reproduzir padrões discriminatórios já existentes, excluindo sistematicamente indivíduos com características socioeconômicas específicas, mesmo sem utilizar essas variáveis explicitamente.

De acordo com o livro *Fairness and Machine Learning*, critérios de crédito que ignoram a agência dos indivíduos, como características imutáveis (ex.: raça) ou mutáveis sem direito à contestação (ex.: setor de atuação) perpetuam desigualdades estruturais (Barocas; Hardt; Narayanan, 2023). Além disso, análises de pontuação de crédito nos EUA revelam disparidades gritantes: negros e hispânicos possuem distribuições de pontuação significativamente menores do que brancos e asiáticos, mesmo após ajustes estatísticos (Barocas; Hardt; Narayanan, 2023). No Brasil, onde 32% dos MEIs citam o acesso a crédito como principal barreira (SumUp, 2023), a adoção acrítica desses modelos pode agravar exclusões.

Como modelos de crédito para MEIs no Brasil podem estar reproduzindo vieses observados em sistemas como o FICO? Métricas de *fairness* como *separation* (igualdade de taxas de erro) ou *independence* (igualdade de aceitação) podem mitigar essas disparidades, sem inviabilizar o sistema financeiro?

O objetivo deste trabalho é propor a investigação da presença de vieses algorítmicos em modelos de concessão de crédito aplicados a Microempreendedores Individuais (MEIs), focando na identificação de desigualdades sistemáticas, na análise de métricas de justiça



algorítmica e na discussão de mecanismos para promover maior equidade e transparência nos sistemas automatizados.

2 MATERIAIS E MÉTODOS

Esta pesquisa propõe uma abordagem quantitativa e experimental para investigar vieses algorítmicos em modelos de crédito para MEIs, alinhando-se às preocupações éticas e sociais destacadas anteriormente. O método combina análise de dados internacionais com adaptações ao contexto brasileiro, considerando as limitações de dados locais e a necessidade de investigar desigualdades estruturais.

Para contornar a escassez de bases públicas brasileiras com informações sensíveis sobre MEIs, utilizaremos dois conjuntos principais de dados: (1) bases internacionais consagradas em estudos de *fairness* (como HMDA e o *German Credit Dataset*), que permitem análises comparativas de viés racial e socioeconômico; e (2) dados sintéticos gerados a partir de estatísticas oficiais, como as do Instituto Brasileiro de Geografia e Estatística (IBGE) e o Serviço Brasileiro de Apoio às Micro e Pequenas Empresas (SEBRAE), simulando características de MEIs brasileiros. Estes incluirão variáveis tradicionais de crédito (renda, tempo de operação), *proxies* para fatores sensíveis (região como indicador indireto de raça/classe) e padrões de desbalanceamento observados em pesquisas nacionais.

Na etapa de modelagem, implementaremos algoritmos comumente usados em crédito (Regressão Logística, XGBoost), avaliando tanto o desempenho tradicional (Acurácia, AUC-ROC) quanto métricas de justiça algorítmica como *Disparate Impact Ratio* (para diferenças entre regiões) e *Equalized Odds* (para taxas de erro entre grupos). Uma análise específica investigará como *proxies* como CEP e setor atuam como substitutos para características sensíveis.

A abordagem crítica focará em três eixos principais: (1) diagnóstico detalhado de quais variáveis e modelos geram maiores disparidades para MEIs vulneráveis; (2) testes práticos de técnicas de mitigação como *reweighting* (pré-processamento) e ajuste de *thresholds* (pós-processamento), documentando cuidadosamente seus limites; e (3) desenvolvimento de recomendações factíveis para seleção de variáveis menos enviesadas, protocolos de auditoria e requisitos de explicabilidade.

Reconhecemos as limitações inerentes ao uso de dados sintéticos e *proxies* imperfeitas, assim como a necessidade de futura validação com dados reais de instituições financeiras. Todo o processo será documentado em *Python* (utilizando bibliotecas como *scikit-learn*, *Fairlearn* e *SHAP*), com código aberto disponibilizado no *GitHub* para garantir reprodutibilidade. A análise priorizará casos concretos que ilustrem como decisões algorítmicas afetam diferentes perfis de MEIs, conectando resultados técnicos aos desafios sociais discutidos.

Esta metodologia se diferencia por: contextualizar problemas globais de *fairness* na realidade dos MEIs brasileiros; propor alternativas viáveis dentro das limitações de dados locais; e conectar técnicas de *machine learning* com debates sobre políticas públicas, sugerindo como reguladores poderiam utilizar métricas específicas para fiscalizar algoritmos de crédito. Mantemos um foco em contribuições práticas e factíveis, evitando promessas irrealistas enquanto avançamos no entendimento dos desafios de justiça algorítmica no cenário brasileiro.

3 RESULTADOS ESPERADOS

Espera-se que a pesquisa contribua para a compreensão crítica e técnica sobre o impacto de algoritmos de aprendizado de máquina na distribuição de crédito a



microempreendedores individuais (MEIs), especialmente em contextos de desigualdade socioeconômica. Do ponto de vista técnico, espera-se identificar se modelos supervisionados de previsão de inadimplência, quando treinados com dados históricos desbalanceados, reproduzem vieses sistemáticos contra determinados grupos, como mulheres, pessoas negras ou indivíduos de regiões menos favorecidas.

Como resultado, espera-se:

- Verificar a presença ou ausência de viés algorítmico nos modelos de score de crédito aplicados ao conjunto de dados estudado;
- Avaliar o impacto de diferentes métricas de justiça algorítmica (como equal opportunity, demographic parity e individual fairness) no comportamento dos modelos;
- Aplicar e comparar técnicas de mitigação de vieses (pré-processamento, in-processamento e pós-processamento) e analisar seus efeitos na acurácia e na equidade dos modelos;
- Desenvolver ao menos um modelo de crédito justo, calibrado de acordo com uma ou mais métricas de fairness, demonstrando a viabilidade técnica de aplicar justiça algorítmica sem comprometer fortemente a performance preditiva;
- Contribuir para o debate acadêmico e político sobre justiça algorítmica no Brasil, especialmente no setor financeiro.

Além disso, espera-se que o estudo sirva de base para recomendações práticas e éticas para o uso responsável de inteligência artificial no sistema bancário e financeiro, promovendo o acesso justo ao crédito e a inclusão produtiva de grupos historicamente marginalizados.

4 CONSIDERAÇÕES FINAIS

Espera-se que essa pesquisa preencha um lacuna significativa no campo de justiça algorítmica no contexto brasileiro, ao investigar o impacto dos sistemas automatizados nos algoritmos de concessão de crédito destinados a Microempreendedores Individuais (MEIs). A investigação torna-se necessária face à crescente adoção de modelos de *machine learning* pelo setor financeiro, onde, sem a devida auditoria, podem reforçar vieses existentes e gerar impactos negativos na economia nacional.

A principal contribuição acadêmica reside na adaptação de avaliação de *fairness* (tradicionalmente desenvolvidos em contextos europeus e norte-americanos) à realidade socioeconômica brasileira. A utilização de *proxies* como região geográfica e setor de atuação para analisar disparidades algorítmicas demonstra como vieses indiretos e estruturais estão presentes em sistemas de decisão automatizada, oferecendo um *framework* replicável em futuros estudos que considerem a realidade do Brasil.

Além dos motivos supracitados, a pesquisa visa fomentar a elaboração de diretrizes técnicas e recomendações para desenvolvedores, instituições financeiras e órgãos reguladores. Os resultados poderão inspirar a elaboração de políticas públicas e marcos regulatórios para a inteligência artificial no país, onde a inclusão financeira digital deva ser pautada pela equidade.

REFERÊNCIAS

BADGER, E. How redlining's racist effects lasted for decades. *The New York Times*, 2017. Disponível em: <https://www.nytimes.com/2017/08/17/upshot/how-redlinings-racist-effects-lasting-for-decades.html>. Acesso em: 20 set. 2025.



BAROCAS, S.; HARDT, M.; NARAYANAN, A. *Fairness and machine learning: Limitations and opportunities*. MIT Press: Massachusetts, 2023. Disponível em: <https://fairmlbook.org>. Acesso em: 20 set. 2025.

DASTIN, J. Amazon scraps secret AI recruiting tool that showed bias against women. *Reuters*, 2018. Disponível em: <https://www.reuters.com/article/world/insight-amazon-scraps-secret-ai-recruiting-tool-that-showed-bias-against-women-idUSKCN1MK0AG/>. Acesso em: 20 set. 2025.

GOVERNO FEDERAL. Ministério do Empreendedorismo, da Microempresa e da Empresa de Pequeno Porte. Secretaria de Microempresa e Empresa de Pequeno Porte. Diretoria Nacional de Registro Empresarial e Integração. Mapa de Empresas – Boletim 1º Quadrimestre 2024. *Governo Federal*, 2024. Disponível em: <https://www.gov.br/empresas-e-negocios/pt-br/mapa-de-empresas/boletins/mapa-de-empresas-boletim-1o-quadrimestre-2024.pdf>. Acesso em: 20 set. 2025.

SUMUP. Pesquisa de Acesso ao Crédito para MEIs no Brasil. Relatório técnico. *SumUp*, 2023. Disponível em: <https://drive.google.com/file/d/1F1q7qRpFHAP8eIcMxDV8CMKXn-XwUjU/view?pli=1>. Acesso em: 20 set. 2025.