



**UNIVERSIDADE
FEDERAL RURAL
DE PERNAMBUCO**



Melissa Araújo Pacheco

**Uma análise de vieses de gênero, raça e localização
geográfica em modelos de predição de evasão em IES com
foco na área de STEM**

Recife

Fevereiro de 2026

Melissa Araújo Pacheco

Uma análise de vieses de gênero, raça e localização geográfica em modelos de predição de evasão em IES com foco na área de STEM

Artigo apresentado ao Curso de Bacharelado em Sistemas de Informação da Universidade Federal Rural de Pernambuco, como requisito parcial para obtenção do título de Bacharel em Sistemas de Informação.

Universidade Federal Rural de Pernambuco – UFRPE
Departamento de Estatística e Informática
Curso de Bacharelado em Sistemas de Informação

Orientador: Gabriel Alves

Recife
Fevereiro de 2026

Melissa Araújo Pacheco

Uma análise de vieses de gênero, raça e localização geográfica em modelos de predição de evasão em IES com foco na área de STEM

Artigo apresentado ao Curso de Bacharelado em Sistemas de Informação da Universidade Federal Rural de Pernambuco, como requisito parcial para obtenção do título de Bacharel em Sistemas de Informação.

Aprovada em: 12 de Fevereiro de 2026.

BANCA EXAMINADORA

Gabriel Alves de Albuquerque Junior (Orientador)
Departamento de Estatística e Informática
Universidade Federal Rural de Pernambuco

Cleyton Vanut Cordeiro de Magalhães
Departamento de Estatística e Informática
Universidade Federal Rural de Pernambuco

Uma análise de vieses de gênero, raça e localização geográfica em modelos de predição de evasão em IES com foco na área de STEM

Melissa Pacheco ¹, Gabriel Alves ¹

¹Departamento de Estatística e Informática – Universidade Federal Rural de Pernambuco
Rua Dom Manuel de Medeiros, s/n, - CEP: 52171-900 – Recife – PE – Brasil

melissa.apacheco@ufrpe.br, gabriel.alves@ufrpe.br

Resumo. *A evasão no ensino superior é crítica, e modelos de Machine Learning usados para combatê-la podem replicar desigualdades. Este trabalho audita um modelo de predição de evasão treinado com dados reais, utilizando métricas de justiça e Explainable AI (SHAP). Apesar da acurácia global de 87%, detectou-se uma dicotomia de erros: um viés punitivo contra estudantes de STEM (altos falsos positivos) e um viés de negligência em relação a mulheres (altos falsos negativos), invisibilizando alunas em risco real. O SHAP confirmou que gênero e localização influenciam indevidamente as decisões, evidenciando que a validação ética é indispensável para evitar a exclusão automatizada na gestão acadêmica.*

Abstract. *Dropout in higher education is critical, and Machine Learning models used to address it may replicate inequalities. This work audits a dropout prediction model using real data, fairness metrics, and Explainable AI (SHAP). Despite 87% global accuracy, results reveal a dichotomy of errors: a punishment bias against STEM students (high false positives) and a negligence bias towards women (high false negatives), rendering at-risk female students invisible. SHAP analysis confirmed that gender and location unduly influence decisions, highlighting that ethical validation is essential to prevent automated exclusion in academic management.*

1. Introdução

1.1. Contexto do problema e objetivos do estudo

A evasão no ensino superior constitui, há anos, um problema relevante no cenário acadêmico mundial, gerando impactos sociais, institucionais e econômicos [Silva Filho et al. 2007]. No Brasil, esse cenário é particularmente alarmante: aproximadamente 25% dos ingressantes em cursos de bacharelado desistem logo no primeiro ano, e apenas 49% dos estudantes conseguem concluir a graduação em até três anos após o tempo previsto — uma taxa de retenção significativamente inferior à média de 70% observada em países da OCDE [OECD 2025]. A persistência desse fenômeno agrava as disparidades de renda, visto que a conclusão do ensino superior no país representa um incremento salarial médio de 148% em comparação ao ensino médio, um dos maiores retornos financeiros do mundo [OECD 2025]. Diante desse contexto, instituições de ensino superior (IES) têm adotado novas tecnologias com o objetivo de

mitigar esse fenômeno [Romero and Ventura 2010]. Entre essas iniciativas, destaca-se o uso de técnicas de *Machine Learning* (aprendizagem de máquina) para a construção de modelos de previsão de evasão. A eficácia dessas abordagens é corroborada por revisões sistemáticas da literatura, que apontam uma tendência crescente no uso de modelos preditivos para identificar precocemente estudantes em situação de risco de evasão [Rastrollo-Guerrero et al. 2020], subsidiando a gestão acadêmica e orientando ações de assistência estudantil [Alyahyan and Düştegör 2020].

Entretanto, tais modelos são treinados a partir de grandes volumes de dados históricos, os quais refletem desigualdades estruturais presentes na sociedade e, consequentemente, no corpo discente das instituições. Tais assimetrias são visíveis no mercado de trabalho e na educação, onde o Brasil apresenta um hiato de gênero acentuado: 29% das mulheres entre 18 e 24 anos encontram-se fora do sistema educacional e do mercado de trabalho (NEET), frente a 19% dos homens [OECD 2025]. Um exemplo recorrente é observado nos cursos das áreas STEM (Ciência, Tecnologia, Engenharia e Matemática), historicamente marcados pela sub-representação de mulheres [INEP 2024]. De forma semelhante, estudantes pertencentes a grupos racialmente minorizados frequentemente enfrentam condições desiguais ao longo de sua trajetória acadêmica, configurando-se como grupos potencialmente vulneráveis à evasão.

Nesse cenário, a sub-representação de determinados grupos pode levar à incorporação de vieses nos modelos de previsão de evasão, resultando em previsões desiguais e potencialmente injustas. Diante disso, o objetivo principal deste trabalho é identificar, analisar e quantificar a presença de vieses em modelos de previsão de evasão escolar, à luz dos princípios da justiça algorítmica e da análise de explicabilidade (*Explainable Artificial Intelligence – XAI*).

Para alcançar esse objetivo, este estudo busca responder às seguintes perguntas de pesquisa:

1. PP1: Os modelos de previsão de evasão apresentam viés algorítmico significativo, especificamente em relação aos estudantes da área de STEM?
2. PP2: De que maneira os atributos sensíveis, isoladamente ou em interseção, alteram a natureza do erro cometido pelo modelo?
3. PP3: A utilização de técnicas de explicabilidade (XAI) é eficaz para identificar os mecanismos de decisão que geram essas injustiças algorítmicas?

Visando responder a essas questões, a metodologia adotada contempla etapas voltadas à investigação de possíveis vieses algorítmicos. O presente trabalho insere-se no contexto das iniciativas do Observatório de Dados da Graduação (ODG) da Universidade Federal Rural de Pernambuco (UFRPE), laboratório responsável pelo desenvolvimento da plataforma SABIA (System of Academic Business Intelligence and Analytics), cuja arquitetura e objetivos foram apresentados em [Marques et al. 2023].

Dando continuidade às investigações do grupo, este estudo apoia-se em premissas estabelecidas por trabalhos sobre modelos de Learning Analytics explicáveis [Barbosa et al. 2024] e sobre o impacto do gênero na sobrevivência acadêmica em STEM [Cavalcanti et al. 2025]. Assim, o processo metodológico desta pesquisa avança ao realizar investigação de viés em um classificador treinado a partir de dados institucionais. O foco recai na comparação do desempenho entre subgrupos vulneráveis e na aplicação de

técnicas de explicabilidade para diagnosticar se os atributos mais relevantes contribuem para a incorporação de novos vieses ou para a perpetuação dos padrões discriminatórios já identificados nas análises de sobrevivência anteriores.

Nesse cenário, o presente trabalho busca contribuir para a identificação e a compreensão mais profunda de vieses algorítmicos em modelos de previsão de evasão no ensino superior, utilizando dados reais de uma universidade pública brasileira. Ao investigar o comportamento desses modelos frente a grupos historicamente sub-representados e mensurar o impacto de atributos sensíveis nas previsões, pretende-se oferecer uma visão crítica sobre as potencialidades do uso de aprendizado de máquina na gestão acadêmica. A aplicação de métodos de explicabilidade, portanto, não serve apenas à validação técnica, mas permite discutir como a transparência algorítmica pode auxiliar na detecção de padrões injustos e fomentar práticas institucionais mais responsáveis. Assim, a pesquisa insere-se no debate contemporâneo sobre justiça algorítmica na educação, defendendo o desenvolvimento de sistemas preditivos que ponderem não apenas o desempenho estatístico, mas também seus efeitos éticos e sociais.

2. Referencial teórico

2.1. O Fenômeno da Evasão Escolar

Este trabalho adota a definição da Comissão Especial de Estudos sobre a Evasão nas Universidades Públicas Brasileiras, que conceitua o evadido como o aluno que não se diplomou e não mantém mais vínculo com o curso de origem. É importante salientar que esse mesmo documento estabelece que o fenômeno não é unidimensional, classificando-o em três tipos distintos [ANDIFES 1996]:

1. Evasão de Curso: Desligamento do curso de origem, podendo haver permanência na instituição (troca interna).
2. Evasão da Instituição: Saída da instituição, com possível reingresso em outra.
3. Evasão do Sistema: Abandono definitivo ou temporário do ensino superior.

Para fins desta pesquisa, adota-se o primeiro conceito (Evasão de Curso), visto que o modelo preditivo visa auxiliar a gestão acadêmica na retenção do estudante em sua graduação original.

A evasão representa uma perda institucional crítica, pois implica o desligamento definitivo do estudante antes da diplomação, gerando impactos que extrapolam a esfera acadêmica e atingem severamente as dimensões econômica e social, no caso das instituições públicas.

Sob a ótica financeira, o fenômeno traduz-se em desperdício de recursos públicos e ineficiência do sistema educacional. Estudos do Instituto de Pesquisa Econômica Aplicada (IPEA) indicam que a evasão no ensino superior gera um custo social elevado ao impedir o acúmulo potencial de capital humano, fundamental para a produtividade e o desenvolvimento econômico do país. Além disso, a alta taxa de desistência em universidades públicas implica que o investimento estatal realizado na formação do discente não retorna à sociedade, caracterizando uma perda direta de eficiência alocativa dos recursos orçamentários. A pesquisa também observou que a evasão em instituições privadas é maior, e que alunos com apoio financeiro têm maior chance de conclusão [Gomes and Hirata 2022].

Simultaneamente, no âmbito social, a interrupção da trajetória acadêmica atua como um limitador da mobilidade e perpetuador de desigualdades. A conclusão do curso superior permanece como um determinante central para a renda no Brasil. Pesquisas recentes do FGV IBRE apontam que, apesar de oscilações no mercado, o “prêmio salarial” do ensino superior continua elevado: trabalhadores com diploma universitário chegam a ganhar mais que o dobro daqueles com apenas o ensino médio, confirmando que a escolarização é o principal vetor de ascensão socioeconômica. Assim, a evasão não apenas frustra projetos individuais, mas cristaliza estratificações sociais preexistentes [Schymura 2024].

Dessa forma, torna-se evidente que a evasão configura um problema de elevado impacto público, justificando a urgência de iniciativas — como a proposta neste trabalho — que busquem compreender, prever e mitigar esse fenômeno.

2.2. *Learning Analytics* no Ensino Superior

Learning Analytics (LA) é um campo de estudo que se dedica à coleta, análise e interpretação de dados educacionais com o objetivo de compreender o comportamento dos estudantes e apoiar a tomada de decisões em contextos de ensino e aprendizagem [Siemens 2013]. No ensino superior, essa abordagem tem sido utilizada para analisar trajetórias acadêmicas e identificar padrões de desempenho. A aplicação dessas técnicas é particularmente relevante para antecipar situações de risco, como a evasão discente, fenômeno que atinge níveis críticos nas áreas de STEM (Ciências, Tecnologia, Engenharia e Matemática). Estudos nacionais, como o de Saccaro et al. (2019), demonstram através de análise de sobrevivência que fatores como suporte financeiro e gênero influenciam significativamente o tempo de permanência e o risco de abandono nesses cursos [Saccaro et al. 2019].

A aplicação de LA permite que instituições utilizem dados já disponíveis em seus sistemas acadêmicos — como histórico de matrícula, desempenho em disciplinas e características sociodemográficas — para gerar informações que subsidiam ações práticas. O processo ocorre em um ciclo contínuo de retroalimentação, conforme ilustrado na Figura 1, onde os dados gerados pelos alunos são transformados em métricas que orientam intervenções.

Modelos analíticos e preditivos inseridos nesse ciclo podem indicar estudantes com maior probabilidade de evasão, possibilitando intervenções institucionais mais precoces e direcionadas [Ferguson 2012]. Essa detecção é vital em cursos de Computação, onde a evasão apresenta dinâmicas específicas e taxas elevadas que demandam estratégias de retenção baseadas em evidências quantitativas robustas, conforme apontado por [Alvim et al. 2024]. Dessa forma, o foco não está apenas na análise retrospectiva, mas também no suporte à gestão acadêmica e ao planejamento de políticas educacionais.

Entretanto, a utilização de LA levanta desafios importantes, especialmente no que se refere à equidade e justiça. Uma vez que os modelos são treinados a partir de dados históricos, eles podem reproduzir ou amplificar desigualdades já existentes entre diferentes grupos de estudantes. Nesse contexto, pesquisas recentes destacam a necessidade de transcender a simples predição, propondo a construção dinâmica de modelos de LA que sejam explicáveis e justos para o acompanhamento de estudantes de graduação [Barbosa et al. 2024]. Assim, torna-se fundamental avaliar não apenas o desempenho

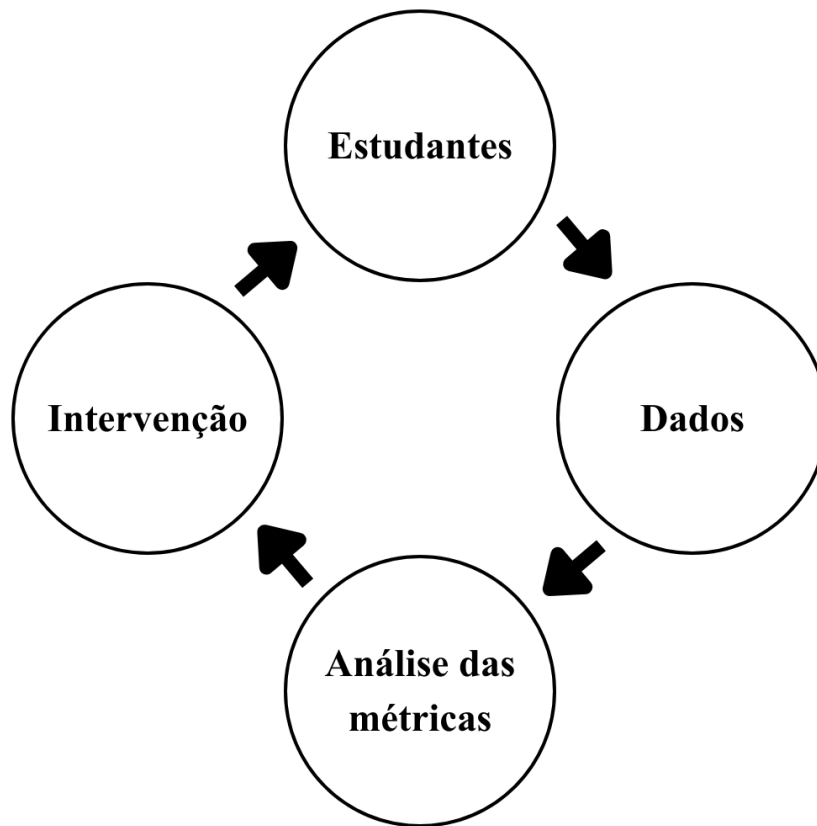


Figura 1. O Ciclo de Learning Analytics [Clow 2012].

global dos algoritmos, mas também seu comportamento específico para com grupos vulneráveis, garantindo que os sistemas analíticos não resultem em tratamentos injustos ou que reforcem estereótipos e discriminação no ambiente educacional.

2.3. *Machine Learning* na Previsão da Evasão

O trabalho de Kelleher define a Aprendizagem de Máquina (*Machine Learning* - ML) como um processo automatizado capaz de reconhecer e aprender padrões em grandes volumes de dados [Kelleher et al. 2020]. No contexto da evasão acadêmica, essa técnica é aplicada para analisar dados históricos e construir modelos preditivos de conclusão ou abandono. Em suma, o modelo utiliza informações existentes para prever a trajetória de um aluno e seu provável desfecho, identificando se há uma maior inclinação à graduação ou à evasão.

Considerando que um aluno em uma instituição de ensino possui muitas características, inferir padrões a partir de um grande volume de atributos e observações torna-se inviável sem o uso de métodos automatizados. Um modelo preditivo consegue encontrar relações entre as variáveis (*features*) e compreender como essas variáveis influenciam o resultado, ou variável alvo (*target variable*).

O problema da predição da evasão é formulado como um problema de aprendizado supervisionado, isto é, o modelo aprende com dados que já têm um resultado final

conhecido (evadido ou formado), caracterizando-o como um problema de classificação. Assim, o modelo aprende a enquadrar um indivíduo em uma classe existente.

2.4. Desigualdades Educacionais e Justiça Algorítmica

Diante das preocupações associadas ao uso de modelos preditivos em contextos educacionais, este trabalho adota uma delimitação conceitual específica. O termo “grupos vulneráveis” refere-se a estudantes que, no contexto educacional, estão sujeitos a desigualdades estruturais, enquanto a expressão “atributos sensíveis” é utilizada na análise algorítmica para indicar variáveis cuja utilização pode resultar em decisões preditivas injustas ou discriminatórias.

No ensino superior brasileiro, essas desigualdades manifestam-se de forma evidente entre diferentes áreas do conhecimento. Dados do Censo da Educação Superior indicam que, em 2024, cursos associados às áreas de Ciência, Tecnologia, Engenharia e Matemática (STEM) apresentaram menor participação feminina entre os concluintes, com destaque para Computação e Tecnologias da Informação e Comunicação, nas quais apenas 16,7% dos concluintes eram mulheres, e para Engenharia, Produção e Construção, com 35,8% de participação feminina [INEP 2024].

Essas assimetrias de gênero refletem diferenças mais amplas de acesso, permanência e conclusão no ensino superior, observadas também em relação a outros recortes, como raça/cor e área de conhecimento, conforme apontado por levantamentos do INEP em 2024. Na literatura sobre modelos preditivos, há evidências de que tais desigualdades podem se refletir no desempenho dos algoritmos, uma vez que os modelos aprendem padrões a partir de dados históricos, podendo reproduzir ou amplificar disparidades existentes entre grupos de estudantes.

Nesse contexto, características como gênero e raça, bem como variáveis correlacionadas a elas, podem influenciar as previsões dos modelos preditivos, resultando em desempenhos distintos entre grupos e, potencialmente, em decisões injustas. Por esse motivo, atributos como gênero e raça são tratados na literatura como “atributos sensíveis”, isto é, variáveis cujo uso ou influência indireta requer cautela na análise algorítmica [Barocas and Selbst 2016].

A literatura de justiça algorítmica apresenta definições distintas, muitas vezes em tensão. Hardt et al. contrastam a *Demographic Parity* (Paridade Demográfica), que exige taxas de seleção idênticas entre grupos — sendo ideal para contextos onde os rótulos históricos são inerentemente enviesados ou se busca reparação social direta —, com a *Equalized Odds* (Chances Igualadas). Esta última, ao focar no equilíbrio das taxas de erro (falsos positivos e negativos), é tecnicamente mais adequado quando o rótulo alvo é objetivo e as taxas base de prevalência diferem legitimamente entre as populações [Hardt et al. 2016].

Para o contexto educacional deste trabalho, embora ambas as métricas sejam essenciais para uma auditoria robusta, a *Equalized Odds* assume maior importância. Dado que a evasão é um evento factual e não uma avaliação subjetiva, o imperativo ético reside em garantir que o modelo não erre desproporcionalmente entre os grupos, evitando tanto a negligência de estudantes em risco (falsos negativos) quanto a estigmatização injusta de alunos que permanecerão (falsos positivos).

Diante desse cenário, torna-se relevante avaliar se modelos preditivos aplicados ao contexto educacional apresentam desempenhos homogêneos entre diferentes grupos de estudantes. A análise de justiça algorítmica, nesse sentido, não se limita à acurácia global do modelo, mas busca identificar possíveis discrepâncias sistemáticas na forma como diferentes grupos são afetados pelas previsões. Assim, este trabalho adota uma perspectiva de auditoria de viés, examinando o comportamento do modelo de previsão de evasão em relação a grupos considerados vulneráveis no contexto educacional, bem como a influência de atributos sensíveis em suas decisões.

2.5. Explicabilidade e transparência em modelos preditivos

No contexto da auditoria de justiça algorítmica, a avaliação do desempenho entre grupos não é suficiente quando não se compreende como o modelo produz suas decisões. Embora modelos preditivos possam apresentar bom desempenho em métricas tradicionais, como acurácia, muitos carecem de transparência quanto ao seu processo decisório. Esses modelos, frequentemente caracterizados como “caixa-preta”, possuem estruturas complexas que dificultam a compreensão de como as previsões são produzidas [Lipton 2018], comprometendo sua explicabilidade (*Explainable Artificial Intelligence* – XAI). Como consequência, um modelo pode apresentar resultados aparentemente satisfatórios sem que seja possível verificar se suas decisões são coerentes, éticas ou justas, especialmente em contextos sensíveis.

Diante dessas limitações, técnicas de explicabilidade têm sido propostas no campo da XAI com o objetivo de tornar compreensível o comportamento de modelos complexos. Entre essas técnicas, destaca-se o *SHapley Additive exPlanations* (SHAP), que permite estimar a contribuição de cada variável para a predição de um modelo individual ou globalmente [Lundberg and Lee 2017]. Ao fornecer explicações consistentes e comparáveis entre diferentes observações, o SHAP tem sido amplamente utilizado como ferramenta de auditoria de modelos preditivos, possibilitando a análise do impacto das variáveis sobre as decisões algorítmicas e a identificação de possíveis vieses em relação a grupos sensíveis.

Dessa forma, a explicabilidade torna-se um componente essencial na avaliação de modelos preditivos aplicados ao contexto educacional, pois permite complementar as métricas de desempenho e justiça algorítmica com uma análise do processo decisório do modelo, especialmente em cenários que envolvem grupos vulneráveis e atributos sensíveis.

3. Trabalhos Relacionados

Na literatura sobre justiça algorítmica, há um estudo que formaliza os critérios de Igualdade de Oportunidades e Igualdade de Chances como requisitos de equidade em aprendizado supervisionado [Hardt et al. 2016]. Os autores discutem as limitações das métricas tradicionais e propõem uma metodologia de pós-processamento eficiente. Essa abordagem ajusta os limiares de decisão do modelo para equilibrar as taxas de acerto entre grupos protegidos, evidenciando, contudo, um *trade-off* inerente: a satisfação estrita das restrições de equidade implica, frequentemente, em uma redução marginal na utilidade global (ou acurácia) do preditor em comparação ao seu desempenho máximo irrestrito.

No contexto educacional brasileiro, um estudo comparativo investigou a aplicação de classificadores para prever a evasão em múltiplos campi de um Instituto Federal

[Filho et al. 2020]. Ao avaliar métricas como a área sob a curva ROC (AUC) e a Medida-F (*F-measure*), os autores constataram que o algoritmo *Gradient Boosting* apresentou desempenho superior na maioria dos cenários testados. Para além da performance preditiva, um achado crucial da pesquisa reside na heterogeneidade dos fatores de risco: demonstrou-se que a importância das variáveis (*feature importance*) varia drasticamente entre diferentes unidades da mesma instituição. Por exemplo, atributos influentes em um campus mostraram-se irrelevantes em outro, corroborando a premissa desta tese de que a localização geográfica atua como uma variável determinante para o contexto da evasão, exigindo análises sensíveis às especificidades locais.

Outra contribuição importante é a de Saccaro et al. (2019), que aplicaram a técnica de Análise de Sobrevida aos dados do Censo da Educação Superior (2009-2014) para investigar a evasão especificamente nas áreas de Ciência, Computação e Engenharia. O estudo identificou padrões demográficos claros: ser do sexo masculino e possuir idade mais avançada são fatores que reduzem significativamente o tempo de permanência no curso. Por outro lado, os autores demonstraram quantitativamente que o suporte financeiro e a integração acadêmica atuam como fortes fatores de proteção: estudantes que recebem bolsas ou participam de atividades extracurriculares apresentam taxas de retenção superiores, corroborando a necessidade de políticas públicas de assistência estudantil para mitigar o desperdício de recursos investidos na formação de capital humano [Saccaro et al. 2019].

Ainda no cenário nacional, outra pesquisa relevante propõe uma abordagem distinta ao integrar dados internos da universidade com indicadores do Censo Demográfico para prever a evasão utilizando *Random Forest* [Brito et al. 2020]. Diferentemente de trabalhos focados no desempenho acadêmico (notas), este estudo utilizou exclusivamente atributos pré-ingresso para identificar perfis de risco. A metodologia consistiu em três experimentos com redução progressiva de atributos, resultando em uma acurácia média de aproximadamente 70% para diferentes áreas do conhecimento, com destaque para os cursos de Engenharia, que obtiveram os melhores desempenhos preditivos.

Um dos achados mais impactantes refere-se à importância das variáveis (*feature importance*): ao desconsiderar notas, o modelo identificou que atributos macroestruturais e sociais — especificamente acesso à água e esgoto, taxa de fecundidade, esperança de vida e raça — apresentaram maior relevância para a classificação da evasão do que o gênero. Essa constatação reforça a hipótese de que a evasão em universidades públicas é fortemente influenciada por condicionantes socioeconômicos externos à sala de aula. O presente trabalho se distingue ao deslocar o foco dos determinantes sociais externos para os indicadores acadêmicos internos, buscando compreender como o desempenho e as características do curso influenciam a predição da evasão.

Alinhada à necessidade de ferramentas de auditoria, a proposta de Barbosa et al. (2024) apresenta um sistema para a construção dinâmica de modelos de Learning Analytics explicáveis e justos. Diferente de abordagens estáticas, o sistema gera modelos adaptáveis, um deles alcançou acurácia de até 95% em testes controlados. Utilizando a técnica SHAP, o trabalho identificou que o número de cancelamentos de matrícula figura entre os atributos de maior relevância preditiva [Barbosa et al. 2024].

No domínio educacional internacional, Kizilcec e Lee (2020) alertam teorica-

mente para os riscos de viés oculto em modelos preditivos [Kizilcec and Lee 2022]. Validando essa preocupação empiricamente, Gardner, Brooks e Kizilcec (2019) avaliaram a equidade em cursos massivos (MOOCs) comparando cinco classificadores distintos, incluindo Redes Neurais (LSTM), SVM e Árvores de Decisão. Ao aplicar a métrica ABROCA (*Absolute Between-ROC Area*) para mensurar a área entre as curvas de desempenho de diferentes grupos demográficos, o estudo revelou que a complexidade algorítmica não garante justiça: no cenário testado, o classificador simples *Naive Bayes* apresentou o menor viés (menor ABROCA), superando abordagens baseadas em *Deep Learning* como LSTM [Gardner et al. 2019]. Enquanto Gardner et al. focam na comparação de arquiteturas em ambientes virtuais de aprendizagem, este estudo direciona-se à validação de um modelo aplicado à gestão de uma universidade pública presencial. Nesse cenário, a análise expande-se para além da performance global, utilizando o SHAP para investigar como atributos sensíveis específicos influenciam a decisão do classificador.

Expandindo a análise para o domínio de crédito, Das et al. (2023) investigaram a justiça algorítmica no mercado hipotecário, contrastando técnicas modernas de ML com a tradicional Regressão Logística. Os resultados evidenciaram a robustez dos modelos complexos, com o classificador *Weighted Ensemble* alcançando uma AUC de 0,926, superando significativamente os 0,717 do método clássico. Contudo, o estudo alerta para o custo na transparência: embora a análise de importância de atributos (*Permutation Feature Importance*) tenha identificado o histórico de crédito como preditor global central, a complexidade dos modelos impõe barreiras para explicações locais a solicitantes rejeitados. Além disso, observaram-se falhas na justiça individual, onde candidatos de grupos minoritários tiveram crédito negado enquanto vizinhos não-minoritários com perfis similares obtiveram aprovação [Das et al. 2023].

O Quadro 1 apresenta uma comparação sintética entre os trabalhos relacionados, considerando domínio de aplicação, modelos utilizados, critérios de justiça adotados e a presença ou não de técnicas de explicabilidade.

Quadro 1. Comparação entre o presente estudo e trabalhos relacionados.

Trabalho	Domínio	Modelo(s)	Métrica de Justiça	Técnica de XAI
Este trabalho	Educação superior	<i>Random Forest</i>	Igualdade de Chances e Paridade Demográfica	SHAP global e por subgrupo
[Brito et al. 2020]	Educação superior	<i>Random Forest</i>	Não avalia	<i>Feature importance</i>
[Gardner et al. 2019]	MOOCs	Redes Neurais (LSTM), Regressão Logística, SVM, Árvores de Decisão (CART) e <i>Naive Bayes</i>	<i>Absolute Between-ROC Area</i> (ABROCA)	Não usa
[Das et al. 2023]	Mercado de Crédito (Hipotecas)	<i>Weighted Ensemble</i> (Melhor), <i>Gradient Boosting</i> (<i>XGBoost</i> , <i>CatBoost</i> , <i>LightGBM</i>), <i>Random Forest</i> e Regressão Logística	Equidade de Grupo (<i>Group Fairness</i>) e Justiça Individual (vizinhos)	Limitada (<i>Permutation Feature Importance</i> global)

A análise sintetizada no Quadro 1 evidencia que, embora a literatura avance na mensuração de viés e no desempenho preditivo, persiste uma lacuna na integração efetiva entre equidade e explicabilidade local. Enquanto trabalhos como [Gardner et al. 2019] e [Das et al. 2023] diagnosticam disparidades em modelos complexos, eles carecem de mecanismos que justifiquem decisões individuais para os gestores. Este trabalho preenche essa lacuna ao adotar o framework SHAP como elo central, permitindo não apenas monitorar métricas de justiça, mas também explicar o porquê da classificação de risco para cada estudante, unindo assim alta acurácia com a transparência necessária para a tomada de decisão ética.

4. Metodologia

Para facilitar a compreensão do percurso metodológico adotado, a Figura 2 apresenta um esquema ilustrativo das principais etapas da pesquisa. O fluxo inicia-se com a formalização do problema e a seleção dos dados institucionais, avançando para as etapas de pré-processamento, que englobam a definição de subgrupos, seleção de variáveis, construção do rótulo e a divisão dos dados. A fase de modelagem consistiu no treinamento do algoritmo Random Forest utilizando o conjunto de treino geral. Por fim, a validação dos resultados é estruturada em três níveis sequenciais e complementares: a avaliação do desempenho preditivo global, a auditoria de justiça algorítmica focada nos subgrupos sensíveis e, conclusivamente, a análise de explicabilidade do modelo com SHAP.




Figura 2. Esquema ilustrativo das etapas metodológicas adotadas na pesquisa.

4.1. Problema de Pesquisa

Esta pesquisa possui natureza quantitativa e aplicada, com abordagem exploratória e experimental [Gil 2008]. A investigação utiliza dados acadêmicos de natureza numérica e categórica, analisados por meio de técnicas estatísticas e algoritmos de aprendizado de máquina, com o objetivo de compreender a evasão discente e avaliar possíveis manifestações de viés em modelos preditivos. O caráter exploratório decorre da análise de padrões de desempenho entre diferentes grupos de estudantes, especialmente alunos de STEM, enquanto o componente experimental está associado à avaliação do desempenho do modelo de predição sob diferentes configurações de teste.

Para operacionalizar a investigação, o problema de pesquisa foi modelado computacionalmente como uma tarefa de classificação binária. O objetivo central consistiu em treinar o classificador *Random Forest* para aprender padrões em dados históricos e prever a situação final do estudante.

Além da acurácia preditiva, a definição do problema incorpora uma dimensão crítica de auditoria algorítmica. A modelagem foi delimitada para investigar especificamente se o algoritmo, ao tentar maximizar seus acertos, acaba por penalizar ou negligenciar subgrupos sensíveis — com ênfase na área de conhecimento (STEM), gênero e localização do campus (UACSA/UAST). Portanto, o problema técnico não se resume apenas a prever evasão, mas diagnosticar como os atributos sensíveis influenciam essa decisão probabilística.

4.2. Entendimento e Seleção dos Dados Institucionais

Os dados utilizados consistem em registros acadêmicos e sociodemográficos da Universidade Federal Rural de Pernambuco (UFRPE), acessados no contexto das atividades do Observatório de Dados da Graduação (ODG). O conjunto de dados utilizado corresponde ao *DataFrame* de vínculos por período, que reúne informações dos discentes ao longo de seu vínculo com a instituição. Trata-se de uma base de natureza longitudinal, uma vez que um mesmo estudante pode apresentar múltiplos registros associados aos diferentes períodos cursados. O conjunto contempla informações acadêmicas — como histórico de períodos, carga horária cursada e desempenho ao longo do curso — bem como informações sociodemográficas, tratadas de forma anonimizada, de modo a preservar o sigilo dos discentes. Para demonstrar, na Tabela 13 constam os tipos e a descrição de alguns desses dados.

Os dados já apresentavam padronização institucional, mas foram submetidos a etapa adicional de inspeção e validação antes das fases de modelagem, visando identificar colunas e anos com células vazias. Também foi realizada uma etapa de compreensão dos dados e análise exploratória, voltada à observação de padrões gerais e à detecção de possíveis anomalias. Essa etapa é detalhada na Seção 5.

Considerando que a base original abrange registros históricos de décadas, contemplando diferentes estruturas curriculares e normativas acadêmicas, foi estabelecido um recorte temporal e institucional compatível com os objetivos desta pesquisa. O conjunto filtrado incluiu discentes que ingressaram entre 2013 e 2024, esse intervalo de anos permitiu observar percursos acadêmicos completos, equilibrando a necessidade de registros recentes com o tempo mínimo para integralização dos cursos. Além disso, foram considerados apenas períodos e tipo de curso regulares.

Além disso, a modalidade de ensino à distância (EAD) não foi considerada neste estudo, em razão da elevada heterogeneidade de seu corpo discente e da presença de padrões de evasão substancialmente distintos daqueles observados no ensino presencial. A Unidade Acadêmica de Belo Jardim (UABJ) também foi excluída da análise por se tratar de um campus recente, não apresentando, até o momento, discentes com situação final de formação que permitissem a análise do desfecho acadêmico. Sendo assim, foram considerados apenas estudantes vinculados aos campi SEDE (Recife), UACSA (Cabo de Santo Agostinho) e UAST (Serra Talhada).

Por fim, para as etapas de modelagem e avaliação, o conjunto de dados foi restringido a discentes cujo vínculo tenha sido finalizado, ou seja, alunos que ainda estão cursando não são contemplados. Isso permite a definição clara do rótulo preditivo (*label*), utilizado como variável alvo (*target variable*) do modelo:

- **Classe Positiva (1):** Representa o desfecho de interesse para a detecção, englobando os registros com status *Evadido*, indicando o abandono.
- **Classe Negativa (0):** Composta pelos registros de alunos com status *Formado*, que representam o caso de sucesso acadêmico.

O conjunto filtrado final continha apenas registros da UFRPE que correspondem a:

- Períodos regulares.
- Cursos regulares.
- Alguma das unidades acadêmicas; SEDE, UAST ou UACSA.
- Alunos que ingressaram entre 2013 e 2024.
- Alunos que não estão mais vinculados à instituição (formados e evadidos).

Após os filtros, o conjunto passou a ter 158.148 registros, correspondentes a 26.872 alunos. Sendo esta a configuração utilizada nas etapas subsequentes de modelagem preditiva, avaliação de desempenho e auditoria de justiça algorítmica.

4.3. Definição dos Subgrupos, Variáveis, Rótulo e Divisão Treino/Teste

A preparação dos dados incluiu a inspeção de valores ausentes, tratamento de inconsistências e seleção das variáveis relevantes para a previsão. Identificadores diretos foram removidos, e atributos que configuram vazamento de informação (*data leakage*) foram excluídos, a fim de evitar que o modelo tenha acesso a dados que não estariam disponíveis no momento da predição em um cenário real [Kaufman et al. 2012]. No pré-processamento das colunas remanescentes, algumas variáveis categóricas foram codificadas por meio de *One-Hot Encoding*, e valores ausentes foram tratados com *SimpleImputer*, utilizando a mediana para inteiros e o valor de “Não informado” no caso de categorias.

Adicionalmente, variáveis categóricas sensíveis foram transformadas em variáveis binárias para facilitar o agrupamento e a análise de subgrupos. Destaca-se a decisão metodológica de incluir a unidade de ensino como um atributo sensível, utilizando-a como uma variável *proxy* para renda e vulnerabilidade social. Na literatura estatística e econômica, uma *proxy* é definida como uma variável que, embora não seja diretamente relevante por si só, serve como substituta para uma variável não observável ou difícil de mensurar, com a qual possui forte correlação [Wooldridge 2016].

Essa substituição justifica-se pelas marcantes disparidades regionais da instituição: enquanto a unidade SEDE situa-se na capital do estado (Recife, PE), a UACSA localiza-se no município de Cabo de Santo Agostinho, a 35 km da capital, e a UAST encontra-se em Serra Talhada, no interior do estado, a 410 km de distância. A localização atua, portanto, como um indicador indireto de contextos socioeconômicos distintos, influenciando o comportamento de evasão observado na Seção 5.

Para a execução da auditoria de justiça algorítmica, foi necessária a definição formal dos grupos de análise, permitindo o cálculo de métricas de disparidade (como *Equalized Odds* e *Demographic Parity*). Como a maioria dos algoritmos de detecção de vies opera sob uma lógica binária de grupo *protegido* (vulnerável) em relação ao grupo de *referência* (privilegiado), realizou-se a binarização dos atributos sensíveis. Esse procedimento isolou a característica de interesse, atribuindo o valor positivo (1) à condição de vulnerabilidade ou sub-representação histórica a ser investigada, conforme a seguinte codificação:

- **Área:** 1 para alunos de STEM.
- **Gênero:** 1 para mulheres.
- **Raça vulnerável:** 1 para discentes autodeclarados PPIQ (Pretos, Pardos, Indígenas ou Quilombolas).
- **Unidade acadêmica:** 1 para alunos pertencentes aos campi UACSA ou UAST (distantes da capital), e 0 para pertencentes à SEDE.

A lista dos outros atributos numéricos e categóricos utilizados no treino consta no Anexo (Tabela 13).

A divisão entre treino e teste foi realizada pelo método *holdout* (80%/20%), preservando a proporção original das classes. Com o objetivo de evitar vazamento de dados decorrente da estrutura longitudinal da base, antes da divisão, os discentes foram previamente agrupados por identificador único, garantindo que registros do mesmo estudante não estivessem simultaneamente nos conjuntos de treino e teste. Após o agrupamento, a divisão dos dados foi feita por meio da função `GroupShuffleSplit` da biblioteca `scikit-learn`.

4.4. Treinamento do Modelo *Random Forest*

O modelo adotado foi o *Random Forest*, selecionado devido à sua capacidade de mitigar o impacto de dados ruidosos, facilidade em lidar com variáveis heterogêneas e aptidão para capturar relações não lineares no conjunto de dados [Breiman 2001]. Além disso, trata-se de um modelo compatível com a aplicação de técnicas de explicabilidade utilizadas posteriormente, particularmente o SHAP [Lundberg and Lee 2017].

Para configuração das árvores de decisão, os hiperparâmetros de maior impacto — como número de árvores, profundidade máxima e número mínimo de amostras por folha

— foram ajustados manualmente, enquanto os demais permaneceram em seus valores padrão.

O modelo foi treinado utilizando os dados filtrados descritos, de modo a refletir o cenário institucional real. Em seguida, realizou-se um teste geral, e os desempenhos obtidos nos conjuntos de treino e teste foram comparados, com o objetivo de identificar possíveis incongruências e indícios de *overfitting*.

4.5. Avaliação do Desempenho Preditivo

A avaliação foi conduzida pelas métricas *Accuracy*, *Precision*, *Recall* e *F1-Score*. No entanto, a *Accuracy* foi interpretada com cautela, visto que esta métrica pode apresentar resultados enganosamente otimistas em bases de dados desbalanceadas. Por isso, a análise priorizou a *Precision* e a *Recall*, considerando sua maior robustez para a identificação de possíveis disparidades de desempenho entre grupos sensíveis no contexto da previsão de evasão discente.

Essas métricas são calculadas a partir da matriz de confusão, que organiza as predições do modelo em quatro categorias: verdadeiros positivos (TP), falsos positivos (FP), verdadeiros negativos (TN) e falsos negativos (FN) [Mitchell et al. 2021]. Essa estrutura possibilitou analisar não apenas o desempenho global do classificador, mas também a natureza e a distribuição dos erros cometidos em relação às classes. As métricas adotadas foram:

- **Acurácia:** Representa a proporção global de acertos do modelo sobre o total de exemplos.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

- **Precisão (*Precision*):** Avalia a confiabilidade da predição feita pelo modelo para uma determinada classe. Matematicamente, é a proporção de acertos dentro do que o modelo classificou como pertencentes àquela classe. Uma precisão alta indica que o modelo raramente emite “alarmes falsos” para a categoria em questão.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2)$$

- **Revocação (*Recall*):** Mede a capacidade do modelo de identificar ou cobrir todos os exemplos reais de uma classe específica. Representa a proporção de indivíduos pertencentes à classe que foram corretamente identificados pelo algoritmo. Um *Recall* alto indica que o modelo deixou passar poucos casos despercebidos (poucos falsos negativos).

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3)$$

- **F1-Score:** estabelece a média harmônica entre precisão e revocação.

Por fim, ressalta-se que as métricas de avaliação foram calculadas de forma estratificada por classe — Formada (0) e Evadida (1) — comparando-se os resultados nos

conjuntos de treino e teste. Essa abordagem granular justifica-se pela necessidade de diagnosticar a capacidade de generalização do modelo: a proximidade entre os valores de treino e teste é o principal indicador de ausência de overfitting (ajuste excessivo). Ademais, a divisão por classe é imperativa em problemas de classificação desbalanceados, pois impede que o alto volume de acertos na classe majoritária (formação) mascare eventuais deficiências na identificação da classe de interesse (evasão), garantindo assim uma aferição transparente da real eficácia preditiva do algoritmo.

Assim, no caso da predição da evasão, a métrica mais importante para aferir o desempenho do modelo é o *Recall* para classe Evadida, pois identificar os verdadeiros evadidos é mais urgente do que identificar corretamente os formados. Pois, num cenário de assistência estudantil, negligenciar um evasor é mais crítico e danoso do que auxiliar alunos sem necessidade.

4.6. Avaliação de Justiça Algorítmica por Subgrupo

Este trabalho adotou um método de avaliação de justiça em pós-processamento, no qual o modelo foi treinado de forma convencional e, posteriormente, seu comportamento foi auditado por meio da análise de desempenho discriminada por grupos sensíveis. Diferentemente de estratégias de pré-processamento ou de modificações no algoritmo durante o treinamento, o foco esteve na avaliação *ex post* do modelo, visando à identificação de possíveis disparidades, conforme discutido na literatura sobre justiça algorítmica.

A avaliação de justiça do modelo foi realizada a partir de duas frentes complementares: (i) a comparação de métricas de desempenho entre o geral, grupos sensíveis e intersecções entre estes, e (ii) a análise da explicabilidade das decisões do modelo. Essa abordagem seguiu práticas consolidadas em estudos de detecção de viés em modelos preditivos [Barocas et al. 2023].

Assim, foram examinados grupos considerados vulneráveis ou historicamente sujeitos a desigualdades estruturais, como estudantes STEM, PPIQ, Mulheres e alunos fora do campus SEDE. Para facilitar a análise de justiça, as colunas binárias (usadas no treino) foram utilizadas para fazer as colunas de intersecção entre essas quatro *features* e para delimitar todos os subgrupos.

Para fundamentar a análise comparativa subsequente, a Tabela 1 apresenta a distribuição quantitativa dos subgrupos no conjunto de teste utilizado para a auditoria, este que representa 20% do total de dados filtrados. A caracterização amostral evidencia a representatividade de cada categoria, permitindo ponderar a robustez estatística das métricas de justiça que serão discutidas na seção de resultados, especialmente para as interseccionalidades com menor volume de dados.

A Tabela 1 evidencia que, embora alguns grupos possuam ampla representatividade, as interseccionalidades apresentam volumes amostrais reduzidos (como no caso de *Mulher, PPIQ, STEM, Unidade e Mulher, STEM, Unidade*), o que exige cautela na interpretação estatística, pois há maior chance de vieses.

Tabela 1. Quantitativo e Proporção dos Subgrupos no Conjunto de Teste

Subgrupo	N	%
TOTAL (Teste)	31.725	100,00
PPIQ	19.767	62,31
Mulher	13.921	43,88
STEM	11.730	36,97
Unidade	9.224	29,07
Mulher, PPIQ	8.501	26,80
PPIQ, STEM	7.318	23,07
PPIQ, Unidade	6.252	19,71
UAST	6.198	19,54
STEM, Unidade	4.869	15,35
Mulher, Unidade	4.048	12,76
Mulher, STEM	3.353	10,57
PPIQ, STEM, Unidade	3.137	9,89
UACSA	3.026	9,54
Mulher, PPIQ, Unidade	2.864	9,03
Mulher, PPIQ, STEM	2.175	6,86
Mulher, STEM, Unidade	1.544	4,87
Mulher, PPIQ, STEM, Unidade	1.083	3,41

Após a definição e quantificação dos subgrupos, procedeu-se à construção de uma matriz consolidada de desempenho e justiça, detalhada na Seção 6. Diferentemente da avaliação global, que mascara comportamentos locais, essa abordagem calcula as métricas individualmente para cada subgrupo sensível e suas interseções. A escolha das métricas que compõem essa matriz foi orientada pelo impacto social dos erros do modelo no contexto educacional:

- **Taxa de Falsos Negativos (FNR):** mede a *negligência* do modelo. É a proporção de casos positivos reais que o modelo errou. A fórmula é dada pela divisão dos Falsos Negativos (FN) pelo total de positivos reais (FN + VP):

$$FNR = \frac{FN}{FN + VP}$$

No contexto de evasão, um alto FNR em um grupo vulnerável significa que o modelo falha em identificar estudantes que precisam de ajuda, invisibilizando o risco. Por esse motivo, esta métrica foi uma das mais importantes para a análise de justiça.

- **Taxa de Falsos Positivos (FPR):** mede a *punição* ou erro de alarme falso. É a proporção de casos negativos reais que o modelo classificou incorretamente como positivos.

$$FPR = \frac{FP}{FP + VN}$$

Um alto FPR indica que o modelo tende a rotular incorretamente estudantes bem-sucedidos daquele grupo como prováveis evasores, o que pode gerar alocação ineficiente de recursos.

- **Diferença de Paridade Demográfica (DPD):** Mede a diferença absoluta na taxa de aprovação (predição positiva) entre dois grupos (Grupo A e Grupo B), por exemplo, sendo um grupo pertencente a uma categoria vulnerável e o outro não. Sendo N_A o total de indivíduos do grupo A e \hat{Y}_A os preditos como evasão nesse grupo:

$$DPD = \left| \frac{\sum \hat{Y}_A}{N_A} - \frac{\sum \hat{Y}_B}{N_B} \right|$$

Embora seja uma métrica rigorosa de igualdade de resultados, ela pode ser enganosa se as taxas reais de evasão forem naturalmente diferentes entre os grupos. Ela foi usada como auxílio na análise.

- **Diferença de Chances Igualadas (EOD):** Também adotada como métrica principal. Ela verifica se o modelo tem a mesma taxa de acerto para todos. O EOD calcula a diferença máxima entre as Taxas de Verdadeiros Positivos (TPR) e Falsos Positivos (FPR) dos grupos:

$$EOD = \max(|TPR_A - TPR_B|, |FPR_A - FPR_B|)$$

Essa métrica é considerada mais robusta para a educação, pois exige que o modelo tenha a mesma qualidade preditiva para todos os subgrupos, sem forçar artificialmente o mesmo número de classificações positivas [Hardt et al. 2016].

Para a quantificação das disparidades, optou-se pelo cálculo da diferença absoluta ($Metrica_A - Metrica_B$) em detrimento da razão ($Metrica_A/Metrica_B$). Essa escolha justifica-se pela estabilidade numérica: métricas baseadas em razão tornam-se voláteis e tendem a inflar desproporcionalmente quando o denominador (taxa do grupo de referência) é muito pequeno, distorcendo a percepção da gravidade do viés. Além disso, a diferença oferece maior interpretabilidade prática para a gestão educacional, pois expressa a magnitude da injustiça diretamente em pontos percentuais de estudantes afetados, ao invés de uma proporção relativa.

4.7. Explicabilidade do Modelo com SHAP por Subgrupo

Posteriormente, realizou-se a etapa de explicabilidade por meio de gráficos *SHAP Beeswarm*, que indicaram a contribuição de cada variável para as previsões do modelo em nível global, técnica proposta por Lundberg e Lee [Lundberg and Lee 2017]. Foram examinados tanto os resultados gerais quanto os específicos dos grupos sensíveis mais críticos, com o objetivo de verificar se o modelo adota padrões decisórios consistentes ou se apresenta comportamentos distintos dependendo do grupo analisado. Essa validação é crucial para assegurar que o algoritmo não esteja atribuindo pesos desproporcionais a determinados atributos apenas para subgrupos específicos (viés de tratamento), o que indicaria que o modelo está aprendendo estereótipos ou utilizando variáveis *proxy* para discriminação, em vez de avaliar o risco acadêmico de forma isonômica. Além da magnitude da contribuição dos atributos, foi observado o sentido da influência de cada variável, isto é, se desloca a predição à classe *Formado* ou *Evadido*.

4.8. Ferramentas utilizadas

A implementação do modelo foi realizada em *Python*, utilizando um conjunto de bibliotecas voltadas para ciência de dados e análise preditiva. A manipulação e preparação

dos dados foram conduzidas com o auxílio das bibliotecas *Pandas* e *Scikit-learn*, que fornecem recursos para imputação de valores faltantes, codificação de variáveis categóricas e construção de *pipelines* de processamento. Para visualização exploratória, foram empregadas as bibliotecas *Plotly* e *Matplotlib*, permitindo tanto gráficos interativos quanto figuras estáticas utilizadas no relatório final.

O modelo preditivo adotado, *Random Forest*, foi implementado a partir do módulo `sklearn.ensemble`. A etapa de justiça utilizou métricas da biblioteca *Fairlearn*. Já a etapa de explicabilidade utilizou a biblioteca *SHAP*, que possibilitou gerar interpretações globais, por grupos sensíveis, visando à compreensão dos fatores com maior influência nas previsões. A divisão entre os conjuntos de treino e teste, bem como o cálculo das métricas de desempenho (*accuracy*, *precision*, *recall* e *F1*), foram executados por meio de funções disponibilizadas também pelo *scikit-learn*.

4.9. Ameaças à Validade e Limitações do Estudo

A condução desta pesquisa está sujeita a restrições que impactam diferentes dimensões do estudo. No que tange às ameaças à validade interna, destaca-se que o modelo foi treinado exclusivamente com dados acadêmicos e administrativos. A ausência de outros fatores determinantes para a evasão — como saúde mental, crise financeira familiar e situação empregatícia — restringe a capacidade explicativa do algoritmo e pode ocultar as verdadeiras causalidades dos padrões detectados. Além disso, a escassez de amostras em certos subgrupos e interseções demográficas pode gerar instabilidade estatística nas métricas de justiça, exigindo cautela na interpretação dos resultados para essas categorias (Tabela 1).

Simultaneamente, a restrição dos dados a uma única instituição impõe barreiras à validade externa dos achados. Como o estudo baseia-se em registros exclusivos da UFRPE, as dinâmicas de viés observadas refletem a realidade específica de uma universidade pública do Nordeste brasileiro, com forte presença de ações afirmativas e campi descentralizados. Consequentemente, os padrões aqui diagnosticados não são automaticamente generalizáveis para universidades privadas ou instituições de outras regiões do país com perfis curriculares distintos.

Adicionalmente, identifica-se uma limitação crítica quanto à representatividade de gênero nos dados. Embora a instituição de origem (UFRPE) possua políticas consolidadas de inclusão e possibilite, em seus sistemas acadêmicos, o registro de nome social e de categorias de identidade de gênero que transcendem o binarismo, tais variáveis não constavam na base de dados disponibilizada para este estudo, o que inviabilizou, inclusive, o uso de dados sintéticos. Consequentemente, a auditoria de justiça algorítmica ficou restrita às categorias “feminino” e “masculino”, resultando na invisibilidade estatística de estudantes transgêneros e não-binários. Essa binarização forçada dos atributos sensíveis impede a detecção de possíveis vieses de predição contra esses grupos minoritários.

Por fim, estabelecem-se as delimitações de escopo da proposta. O trabalho possui um foco estritamente diagnóstico (auditoria), restringindo-se à identificação e explicação dos vieses, sem avançar para a implementação de técnicas de mitigação ativa. Entende-se que o diagnóstico robusto é uma etapa prévia indispensável a qualquer intervenção corretiva. Da mesma forma, a análise limitou-se ao algoritmo *Random Forest*, não comparando arquiteturas de Aprendizado Profundo que poderiam apresentar comportamentos

distintos.

5. Análise Exploratória

Após os filtros descritos na Seção 4, sobraram os discentes regulares que ingressaram entre 2013 e 2024, nos cursos ofertados em três unidades acadêmicas da instituição, tendo os cursos da área de Ciência, Tecnologia, Engenharia e Matemática (STEM) como eixo central da análise. Vale frisar que, no treino do modelo, só foram utilizados registros de alunos com situação final conhecida e encerrada como *Evadido* ou *Formado*. A base ficou com 158.148 (26.872 alunos).

5.1. Comparação Contextual entre Cursos STEM e o Conjunto da Instituição

A Tabela 2 apresenta uma comparação entre os registros do conjunto total de discentes, segmentando-os entre cursos de STEM e Não STEM. Esta tabela considera a natureza longitudinal da base de dados, na qual existem múltiplas entradas (linhas) para registrar a trajetória acadêmica de um mesmo aluno ao longo do tempo. Estes dados refletem exatamente o que o modelo recebe nas etapas de treino e teste.

Tabela 2. Comparação Geral de Registros por Área.

Grupo	Registros	% Formados	% Evadidos
Geral	158.148	41,27%	58,73%
Não STEM	100.361	49,50%	50,50%
STEM	57.787	26,97%	73,03%

Observa-se que os dados de evasão e conclusão nos cursos que não são de STEM apresentam certo equilíbrio. No entanto, no conjunto geral da instituição, surge uma discrepância na distribuição, que é agravada quando observada no contexto de STEM, onde o número de registros de evadidos é quase três vezes superior ao de formados. A tabela confirma que a evasão na área de STEM supera a média geral. Ao comparar diretamente cursos de STEM e Não STEM, a taxa de evasão apresenta um aumento de aproximadamente 23%.

A Tabela 3, por sua vez, exhibe a distribuição de alunos únicos, isolando os indivíduos em vez dos registros de trajetória. Esta visão permite compreender a demografia real dos estudantes em cada cenário.

Tabela 3. Comparação Geral dos Alunos por Área.

Grupo	Alunos	% Formados	% Evadidos
Geral	26.872	23,79%	76,21%
Não STEM	16.221	30,63%	69,37%
STEM	10.651	13,38%	86,62%

Quando contabilizada a quantidade real de estudantes, nota-se que o volume de registros longitudinais tende a suavizar a disparidade real entre evasão e formação. Ao

analisar os alunos únicos, a proporção de formados nos cursos Não STEM é mais que o dobro da observada nos cursos de exatas. Isso torna a diferença entre os contextos acadêmicos ainda mais evidente, indicando que alunos em cursos STEM enfrentam dificuldades significativamente maiores para atingir a formação.

5.2. Caracterização por Campus

A Tabela 4 detalha a distribuição dos alunos de evadidos e formados nas três unidades acadêmicas.

Tabela 4. Distribuição de Alunos por Campus e Situação Final (Geral).

Campus	Situação Final	Quantidade	% Geral	% Campus
SEDE	Evadido	13.443	50,03%	73,94%
SEDE	Formado	4.737	17,63%	26,06%
UACSA	Evadido	2.837	10,56%	93,14%
UACSA	Formado	209	0,78%	6,86%
UAST	Evadido	4.198	15,62%	74,35%
UAST	Formado	1.448	5,39%	25,65%

É importante contextualizar que, diferentemente da SEDE e da UAST, que possuem uma oferta multidisciplinar, a unidade UACSA oferta exclusivamente cursos de engenharia. Dado que a evasão é historicamente mais frequente nessas áreas, essa característica contribui para que a proporção bruta de evadidos na UACSA seja substancialmente maior que nos campi mistos.

A Tabela 5 mostra que os cursos que não são STEM sempre apresentam uma maior proporção de formados se comparados às taxas em STEM e às gerais, comprovando mais uma vez que cursos de exatas enfrentam mais problemas com evasão em todos os campi.

Já a Tabela 6 apresenta a distribuição dos alunos filtrando-se apenas os cursos de STEM em cada campus.

Tabela 5. Distribuição de Alunos por Campus e Situação Final (Não STEM).

Campus	Situação Final	Quantidade	% Geral	% Campus
SEDE	Evadido	8.588	52,94%	69,11%
SEDE	Formado	3.838	23,66%	30,89%
UAST	Evadido	2.664	16,42%	70,20%
UAST	Formado	1.131	6,97%	29,80%

Tabela 6. Distribuição de Alunos por Campus e Situação Final (STEM)

Campus	Situação Final	Quantidade	% Geral	% Campus
SEDE	Evadido	4.855	45,58%	84,38%
SEDE	Formado	899	8,44%	15,62%
UACSA	Evadido	2.837	26,64%	93,14%
UACSA	Formado	209	1,96%	6,86%
UAST	Evadido	1.534	14,40%	82,87%
UAST	Formado	317	2,98%	17,13%

A comparação restrita ao universo STEM revela um dado crítico: mesmo nivelando a área de conhecimento, o fenômeno da evasão se manifesta de forma mais intensa na UACSA (93,14%) do que nos cursos de STEM da SEDE (84,38%) e UAST (82,87%). Isso sugere que fatores além da dificuldade intrínseca ao curso influenciam a permanência discente. Esta disparidade será investigada detalhadamente na seção de resultados.

Mesmo comparando apenas cursos STEM em todas as unidades, o fenômeno da evasão ainda se manifesta de forma diferente na UACSA. Isso será investigado apropriadamente na Seção 6, em que haverá uma análise qualitativa mais detalhada para identificar possíveis fatores complementares que agravam a evasão nesse campus.

5.3. Caracterização por Gênero em Diferentes Áreas

A Tabela 7 apresenta a participação feminina em cada contexto acadêmico e sua distribuição em cada situação final. A coluna de Proporção mostra quanto dos registros são femininos em relação ao total naquele contexto, enquanto as últimas colunas são complementares e se referem à distribuição dos registros femininos entre os dois desfechos. É possível observar que a concentração de mulheres está nos cursos Não STEM, enquanto a proporção de mulheres em STEM é o que abaixa a média geral de Instituição.

Tabela 7. Representatividade e Taxas de Formados e Evadidos por Área (Gênero Feminino).

Contexto	Alunas	% Proporção	% Formadas	% Evadidas
Instituição (geral)	11.385	42,37%	30,94%	69,06%
Não STEM	8.405	51,82%	35,46%	64,54%
STEM	2.980	27,98%	18,19%	81,81%

Tabela 8. Representatividade e Taxas de Formados e Evadidos por Área (Gênero Masculino).

Contexto	Alunos	% Proporção	% Formados	% Evadidos
Instituição (geral)	15.487	57,63%	18,54%	81,46%
Não STEM	7.816	48,18%	25,45%	74,55%
STEM	7.671	72,02%	11,51%	88,49%

A análise conjunta das Tabelas 7 e 8 revela uma dicotomia importante entre representatividade e desempenho acadêmico. Inicialmente, observa-se a clara segregação de áreas: enquanto o gênero masculino domina os registros em cursos de STEM (72,02% dos alunos), o gênero feminino é minoritário nesta área (27,98%), concentrando-se majoritariamente nos cursos Não STEM.

No entanto, ao analisar as taxas de conclusão (coluna *%Formados*), nota-se que o desempenho feminino é superior em todos os cenários analisados. No contexto geral da instituição, 30,94% das alunas do conjunto se formaram, enquanto entre os homens essa taxa cai para apenas 18,54%.

Esse padrão de maior eficiência acadêmica feminina se mantém mesmo dentro da área de STEM, um ambiente onde elas são minoria numérica. Onde 18,19% das alunas se formaram, comparados a apenas 11,51% dos alunos masculinos.

Os dados indicam que, embora os homens ingressem em maior volume nos cursos de exatas e tecnologia, eles apresentam uma probabilidade significativamente maior de evasão (88,49% evadiram). Em contrapartida, as mulheres, apesar de enfrentarem barreiras de entrada que resultam em menor representatividade, demonstram taxas de formação superiores uma vez inseridas no curso. Portanto, a alta evasão observada nos cursos de STEM é impulsionada majoritariamente pelo desempenho do subgrupo masculino.

5.4. Caracterização por Raça em Diferentes Áreas

Essa análise foca na proporção e na distribuição dos discentes pertencentes a raças vulneráveis (Pretos, Pardos, Indígenas e Quilombolas - PPIQ) e não vulneráveis (Branços e Amarelos) em cada área.

Nas Tabelas 9 e 10, a Proporção indica os alunos do grupo analisado em relação ao total de alunos da área, esse conjunto total considera todas as raças, bem como alunos sem autodeclaração conhecida. Assim, vale ressaltar que as proporções de alunos com registros faltantes em cada área são 5,98% (Geral), 6,53% (Não STEM) e 5,14% (STEM).

As colunas de formados e evadidos são complementares e se referem ao grupo racial analisado na área em questão.

Tabela 9. Representatividade e Taxas de Formados e Evadidos por Área (PPIQ).

Contexto	Alunos	% Proporção	% Formados	% Evadidos
Instituição (geral)	16.967	63,14%	23,47%	76,53%
Não STEM	10.289	63,43%	29,91%	70,09%
STEM	6.678	62,70%	13,55%	86,45%

Tabela 10. Representatividade e Taxas de Formados e Evadidos por Área (Branco e Amarelo).

Contexto	Alunos	% Proporção	% Formados	% Evadidos
Instituição (geral)	8.298	30,88%	24,22%	75,78%
Não STEM	4.872	30,04%	31,57%	68,43%
STEM	3.426	32,17%	13,78%	86,22%

Ao observar as tabelas, é perceptível que os alunos PPIQ, por mais que sejam considerados um grupo vulnerável, são maioria numérica, sempre representando mais de 60% dos registros em cada uma das áreas. No entanto, os dois grupos apresentam proporção equivalente de formados e evadidos em todas as áreas.

5.5. Considerações

A análise exploratória evidencia que os grupos vulneráveis apresentam dinâmicas de evasão distintas, confirmando a heterogeneidade do fenômeno. Observa-se que estudantes das áreas de STEM evadem com maior frequência em comparação às demais áreas (Tabela 3). Em contrapartida, ao analisar o recorte de gênero, nota-se que as mulheres evadem menos em todas as áreas analisadas (Tabelas 7 e 8). Esse padrão de permanência feminina persiste mesmo nos cursos de STEM, onde elas constituem uma minoria numérica, sugerindo que fatores de retenção específicos podem estar atuando sobre esse grupo.

Adicionalmente, a infraestrutura e o contexto local (representados pela variável Campus) manifestam o fenômeno da evasão de maneira desigual. A UACSA, composta majoritariamente por cursos de engenharia, apresenta proporções de evasão significativamente superiores às demais unidades acadêmicas, cenário que se mantém mesmo quando a comparação é restringida apenas a estudantes de STEM em todos os campi (Tabela 6). Contudo, a análise deve ser feita com cuidado, considerando a quantidade e o maior desbalanceamento de dados utilizáveis dessa unidade.

Por fim, a análise isolada do atributo raça não revelou disparidades acentuadas nas taxas de evasão. Contudo, é fundamental destacar uma característica demográfica deste conjunto de dados: diferentemente de outros contextos onde grupos racializados são minoria, aqui eles representam a maioria numérica em todas as áreas (Tabelas 9 e 10). Essa predominância quantitativa é um fator crítico que deve ser considerado nas etapas subsequentes, especialmente nas análises por subgrupo e interseccionalidade, para garantir que a representatividade numérica não mascare vulnerabilidades específicas.

6. Resultados

O foco da análise serão os subgrupos vulneráveis da UFRPE. A representação desses grupos é detalhada na Tabela 1. O termo *Unidade* se refere a registros de alunos fora do Campus SEDE (UAST e UACSA).

A análise inicia-se pela avaliação do modelo geral para cada curso, seguida pela exploração da explicabilidade das decisões através dos valores SHAP e pela auditoria de justiça por grupos sensíveis.

6.1. Desempenho Geral do Modelo

Nesta subseção, detalha-se o desempenho do modelo nos conjuntos de treino e teste (Tabela 11). A análise prioriza a métrica *Recall* para a classe Evadida, dada sua importância crítica em minimizar a negligência, ou seja, os falsos negativos (Evadidos erroneamente classificados como Formados). O suporte se refere à quantidade de registros utilizados, considerando a base longitudinal.

Tabela 11. Resultados de Classificação: Comparação entre Treino e Teste

Conjunto	Classe	Precision	Recall	F1-Score	Suporte
Treino	Formada	0,82	0,91	0,86	52.425
	Evadida	0,93	0,86	0,89	73.998
			Accuracy	0.88	126.423
Teste	Formada	0,79	0,90	0,84	12.840
	Evadida	0,92	0,84	0,88	18.885
			Accuracy	0.87	31.725

A análise comparativa entre os desempenhos de treino e teste demonstra a robustez do modelo e a ausência de *overfitting* significativo. Observa-se uma consistência métrica entre as duas etapas: a Acurácia global apresentou uma variação marginal de apenas 1 ponto percentual (de 0,88 no treino para 0,87 no teste). Crucialmente, as métricas da classe de interesse (Evadida) mantiveram-se estáveis, com o *F1-Score* variando minimamente de 0,89 para 0,88 e o *Recall* apresentando uma leve oscilação natural de 0,86 para 0,84. Essa proximidade nos resultados indica que o classificador foi capaz de capturar os padrões generalizáveis dos dados de evasão, em vez de apenas memorizar ruídos específicos do conjunto de treinamento.

Para validar a eficácia do modelo além do desbalanceamento natural das classes, comparou-se sua capacidade de detecção (*Recall*) com a prevalência histórica de evasão, que representa a chance de acerto de uma escolha aleatória proporcional.

No cenário geral de teste, e considerando que a taxa base de registros de evadidos é de aproximadamente 60% dos registros (Tabela 2), o modelo proposto (*Recall*: 84%) apresenta um ganho real (*lift*) de 24 pontos percentuais.

Tais resultados evidenciam que o algoritmo supera a mera reprodução de estatísticas de frequência, sendo capaz de identificar padrões comportamentais e acadêmicos genuínos para a predição da evasão.

Com o uso do SHAP para a explicabilidade, é possível visualizar a hierarquia de importância atribuída pelo modelo aos atributos dos discentes. A Figura 3 apresenta o gráfico *Beeswarm*, que revela quais variáveis exerceram maior impacto na classificação global, bem como a direção dessa influência. No eixo vertical, os atributos estão ordenados por relevância (soma das contribuições absolutas); no eixo horizontal, o valor SHAP indica o deslocamento da predição: valores positivos (à direita) aumentam a probabili-

dade de evasão, enquanto valores negativos (à esquerda) indicam tendência à formação. As cores representam a magnitude da variável original, onde o vermelho indica valores altos e o azul, valores baixos.




Figura 3. Gráfico *Beeswarm* do Modelo Geral

Observa-se que a estrutura de decisão do modelo é predominantemente relacionada ao desempenho acadêmico e baseada no histórico escolar. As quatro características mais relevantes foram:

- Média final (*media_final*);
- Quantidade de aprovações acumuladas (*qtd_aprovacoes_acum*);
- Quantidade de reprovações acumuladas (*qtd_reprovacoes_acum*);
- Duração do vínculo em número de períodos acumulados (*duracao_vinculo*)

O comportamento do modelo diante dessas variáveis demonstra coerência pedagógica. No topo do gráfico, a concentração de pontos vermelhos (notas altas) à esquerda no atributo *media_final* indica que essa característica influencia fortemente a predição para a classe Formada. Ou seja, o bom desempenho acadêmico é o principal redutor do risco de evasão, mesmo que haja casos de evasão com notas altas. Consonante com isso, poucas *qtd_aprovacoes_acum* (pontos azuis à direita) atuam como o maior impulsor para a classe Evadida, enquanto valores médios (pontos roxos à esquerda) tendem a deslocar a predição para formação.

No caso da *qtd_reprovacoes_acum*, os baixos valores (pontos azuis à esquerda) são fortemente ligados à predição de formação, enquanto o lado da evasão (direita) contém uma maior variedade de valores, em que costumam ser altos (em vermelho) ou médios (em roxo). Já para a variável *duracao_vinculo*, uma menor duração desloca a predição para evasão, isso reflete o notável fenômeno da evasão ser mais alto nos primeiros períodos.

Dentre os atributos sensíveis ou sociodemográficos, destacam-se:

1. **Pertencimento a STEM** (*is_stem*): É o atributo não acadêmico de maior peso (5ª posição). O modelo atribui valores SHAP positivos (risco de evasão) para estudantes dessa área (pontos vermelhos à direita), capturando a tendência histórica da instituição onde cursos de exatas apresentam percentuais de evadidos superiores (73% dos registros, Tabela 2).
2. **Gênero** (*is_mulher*): Ocupa uma posição de relevância superior a variáveis como turno ou modalidade de ingresso (7ª posição). Crucialmente, observa-se que o gênero feminino (pontos vermelhos) tende a deslocar a predição para a esquerda (formação), indicando que, na visão global do modelo, ser mulher atua como um fator que diminui delas de serem classificadas como Evadidas.
3. **Campus UACSA** (*is_uacsa*): Embora tenha um impacto global menor que STEM ou Gênero, esta variável figura entre as dez mais relevantes. Observa-se claramente que o pertencimento a este campus (pontos vermelhos) desloca a predição para a direita (valores SHAP positivos). Isso confirma que o modelo incorporou a alta taxa histórica de evasão dessa unidade (93%) como um penalizador automático, aumentando a probabilidade de risco para qualquer aluno matriculado lá, independentemente de outros fatores.

6.2. Análise de Justiça

A Tabela 12 apresenta uma análise comparativa detalhada do desempenho preditivo, confrontando os resultados do teste geral com os obtidos em subgrupos vulneráveis e suas intersecções. Para além das métricas tradicionais de performance, a avaliação incorpora indicadores fundamentais de equidade, abrangendo a Taxa de Falsos Negativos (FNR) e a Taxa de Falsos Positivos (FPR), bem como medidas de disparidade entre grupos, especificamente a Diferença de Paridade Demográfica (DPD) e a Diferença de Chances Igualadas (EOD). Ressalta-se que os valores destacados em negrito na tabela sinalizam os cenários onde as métricas críticas de justiça (FNR e EOD) apresentaram desempenho inferior ao observado no cenário geral, evidenciando potenciais focos de negligência algorítmica ou desigualdade de oportunidades para os grupos afetados.

Considerando as métricas de desempenho detalhadas por subgrupos, os resultados confirmam a eficácia do modelo em comparação à prevalência histórica (*Dummy*). Tomando como referência o percentual geral de evadidos de aproximadamente 60% (Tabela 2), observa-se que, mesmo no cenário de menor desempenho registrado (unidade UAST, com *Recall* de 79%), o modelo assegura um ganho real (*lift*) de aproximadamente 19 pontos percentuais.

Essa robustez se mantém consistente nos subgrupos críticos, como nos cursos de STEM, onde a taxa histórica de evasão atinge 73% (Tabela 2). Diante dessa linha de base elevada, o modelo alcançou um *Recall* de 92%, superando o cenário base também em 19

Tabela 12. Métricas de Justiça e Desempenho Detalhadas por Subgrupos

Grupo	Precision	Recall	F1-Score	FNR	FPR	DPD	EOD
GERAL	0,92	0,84	0,88	0,16	0,10	-	-
STEM	0,94	0,92	0,93	0,08	0,17	0,28	0,14
Mulher	0,91	0,80	0,85	0,20	0,08	0,19	0,06
PPIQ	0,93	0,84	0,88	0,16	0,10	0,01	0,01
Unidade	0,96	0,87	0,91	0,13	0,08	0,07	0,04
UAST	0,95	0,79	0,86	0,21	0,05	0,11	0,06
UACSA	0,97	0,96	0,96	0,04	0,28	0,38	0,18
Mulher, PPIQ	0,92	0,80	0,86	0,20	0,07	0,14	0,05
Mulher, STEM	0,93	0,89	0,91	0,11	0,13	0,10	0,06
Mulher, Unidade	0,94	0,82	0,87	0,18	0,06	0,09	0,04
PPIQ, STEM	0,95	0,92	0,93	0,08	0,15	0,23	0,11
STEM, Unidade	0,97	0,93	0,95	0,07	0,13	0,28	0,11
PPIQ, Unidade	0,96	0,86	0,91	0,14	0,07	0,04	0,04
PPIQ, STEM, Unidade	0,97	0,93	0,95	0,07	0,10	0,24	0,10
Mulher, STEM, Unidade	0,95	0,89	0,92	0,11	0,11	0,13	0,05
Mulher, PPIQ, STEM	0,93	0,89	0,91	0,11	0,11	0,06	0,05
Mulher, PPIQ, Unidade	0,92	0,81	0,86	0,19	0,07	0,11	0,04
Mulher, PPIQ, STEM, Unidade	0,94	0,88	0,91	0,12	0,11	0,08	0,04

pontos percentuais. Isso demonstra que o algoritmo não apenas acompanha a tendência dos dados, mas agrega valor preditivo significativo em todos os cenários analisados.

De modo geral, a Precisão manteve-se elevada, superando a média global em subgrupos de localização (UAST, UACSA) e na área de STEM.

O subgrupo de *STEM* apresentou *F1-Score* superior ao Geral em 5 pontos percentuais. Isso é esperado dada a alta taxa histórica de evasão na área (73,03%, Tabela 2), o que facilita a detecção da classe positiva. Contudo, este grupo registrou altos índices de disparidade (FPR: 0,17; DPD: 0,28), indicando um viés punitivo. A análise do SHAP Geral (Figura 3) corrobora estatisticamente essa interpretação: a variável *is_stem* figura como um dos principais preditores não acadêmicos, impulsionando a probabilidade de evasão (valores à direita) e levando o modelo a “alarmar” com mais frequência, mesmo para alunos com notas razoáveis.

Seguindo a tendência do grupo *STEM*, o grupo *UACSA* apresenta o cenário punitivo mais crítico (FPR: 0,28; DPD: 0,38), agravado pelo fato de a unidade ofertar exclusivamente cursos de exatas. Contudo, o viés excede a natureza da área: com uma taxa de evasão (84,17%) superior até mesmo à média dos cursos *STEM* de outras unidades, o modelo incorporou esse histórico extremo como uma penalidade geográfica cumulativa. A análise do SHAP Geral confirma que a variável *is_uacsa* adiciona risco extra à predição, punindo o estudante duplamente — pelo curso e pelo campus —, uma generalização perigosa sobre um grupo que representa apenas 9,54% da amostra de teste (Tabela 1).

Em contrapartida, e de forma mais crítica sob a ótica da permanência estudantil, observa-se um padrão sistemático de negligência (altas taxas de Falsos Negativos), que é o erro mais grave e danoso que o modelo pode cometer.

A grupo *UAST* apresentou o pior *Recall* (0,79) e a maior Taxa de Falsos Negativos (FNR: 0,21). O fato de este campus possuir a menor evasão histórica (Tabela 4) induz o modelo a um comportamento conservador. O SHAP confirma que a ausência de penalidades geográficas (como ocorre na UACSA) faz com que o modelo subestime o risco de evasão, deixando de identificar um em cada cinco alunos que efetivamente evadirão.

Esse fenômeno de negligência é ainda mais evidente no recorte de Gênero. O subgrupo *Mulher* teve o pior *F1-Score* (0,85) e a segunda maior taxa de Falsos Negativos (FNR: 0,20). A análise do SHAP Geral (Figura 3) é fundamental para compreender a raiz dessa disparidade: a variável *is_mulher* aparece deslocando a predição para a esquerda (formação). Ou seja, o modelo aprendeu a tratar o gênero feminino como um fator que propicia a formação. Embora a menor evasão feminina seja estatisticamente verídica (Tabela 7), esse peso negativo cria um ponto cego algorítmico: alunas em risco acadêmico real têm sua probabilidade de evasão atenuada apenas por serem mulheres, resultando na omissão de alertas (alto FNR) e na invisibilização de quem precisa de suporte.

A análise racial (subgrupo *PPIQ*) mostrou métricas alinhadas ao Geral e baixíssima disparidade (DPD e EOD: 0,01). O SHAP valida essa neutralidade ao não atribuir destaque ou direção forte à variável racial (Figura3), refletindo a dominância demográfica deste grupo, de 62,31% (Tabela 1), na calibração do modelo.

Por fim, a análise interseccional revela a propagação das falhas críticas do sistema, evidenciadas pelas métricas de justiça priorizadas nesta avaliação: a EOD e a FNR. Sob a ótica do EOD, observa-se uma disparidade técnica impulsionada pelo viés de estigmatização. As intersecções *PPIQ*, *STEM* e *STEM, Unidade* registraram desequilíbrios relativamente altos (EOD: 0,11), causados fundamentalmente pelo excesso de “alarmes falsos” (FPR moderado). Isso indica que, para estudantes *PPIQ* e de exatas, o modelo peca pelo excesso de rigor, desperdiçando recursos de assistência com quem não evadiria.

Entretanto, é na métrica de FNR que reside a falha social mais grave: a negligência. Enquanto os grupos de *STEM* sofrem com o excesso de acusações de evasão (punição), a intersecção *Mulher, Unidade* sofre com a invisibilidade. O FNR deste grupo (0,18) subiu para quase o dobro da média geral, indicando que a combinação de gênero e contexto local cria “pontos cegos” onde o algoritmo falha sistematicamente em detectar o risco de evasão. Essa negligência interseccional é perigosa porque, ao contrário do erro de punição (que ao menos alerta o gestor), o erro de negligência (FNR) silencia o problema. Alunas em risco real em determinados campi são classificadas incorretamente como “seguras” pelo modelo, retirando-as da fila de prioridade para intervenção pedagógica. Portanto, embora o EOD aponte para ajustes necessários na calibração de grupos de exatas, o alto FNR em recortes femininos e geográficos constitui o risco mais imediato para a eficácia da política de permanência estudantil.

6.3. Explicabilidade na Identificação e Compreensão de Vieses

A análise detalhada da explicabilidade com SHAP busca responder à PP3, auxiliando na interpretação e validação dos resultados de justiça discutidos anteriormente. Esta seção foca na análise de gráficos *Beeswarm* para observar quais atributos foram mais relevantes e como influenciaram a predição do modelo em cada subgrupo vulnerável. Embora as métricas de desempenho tenham sugerido a existência de viés, é na visualização da

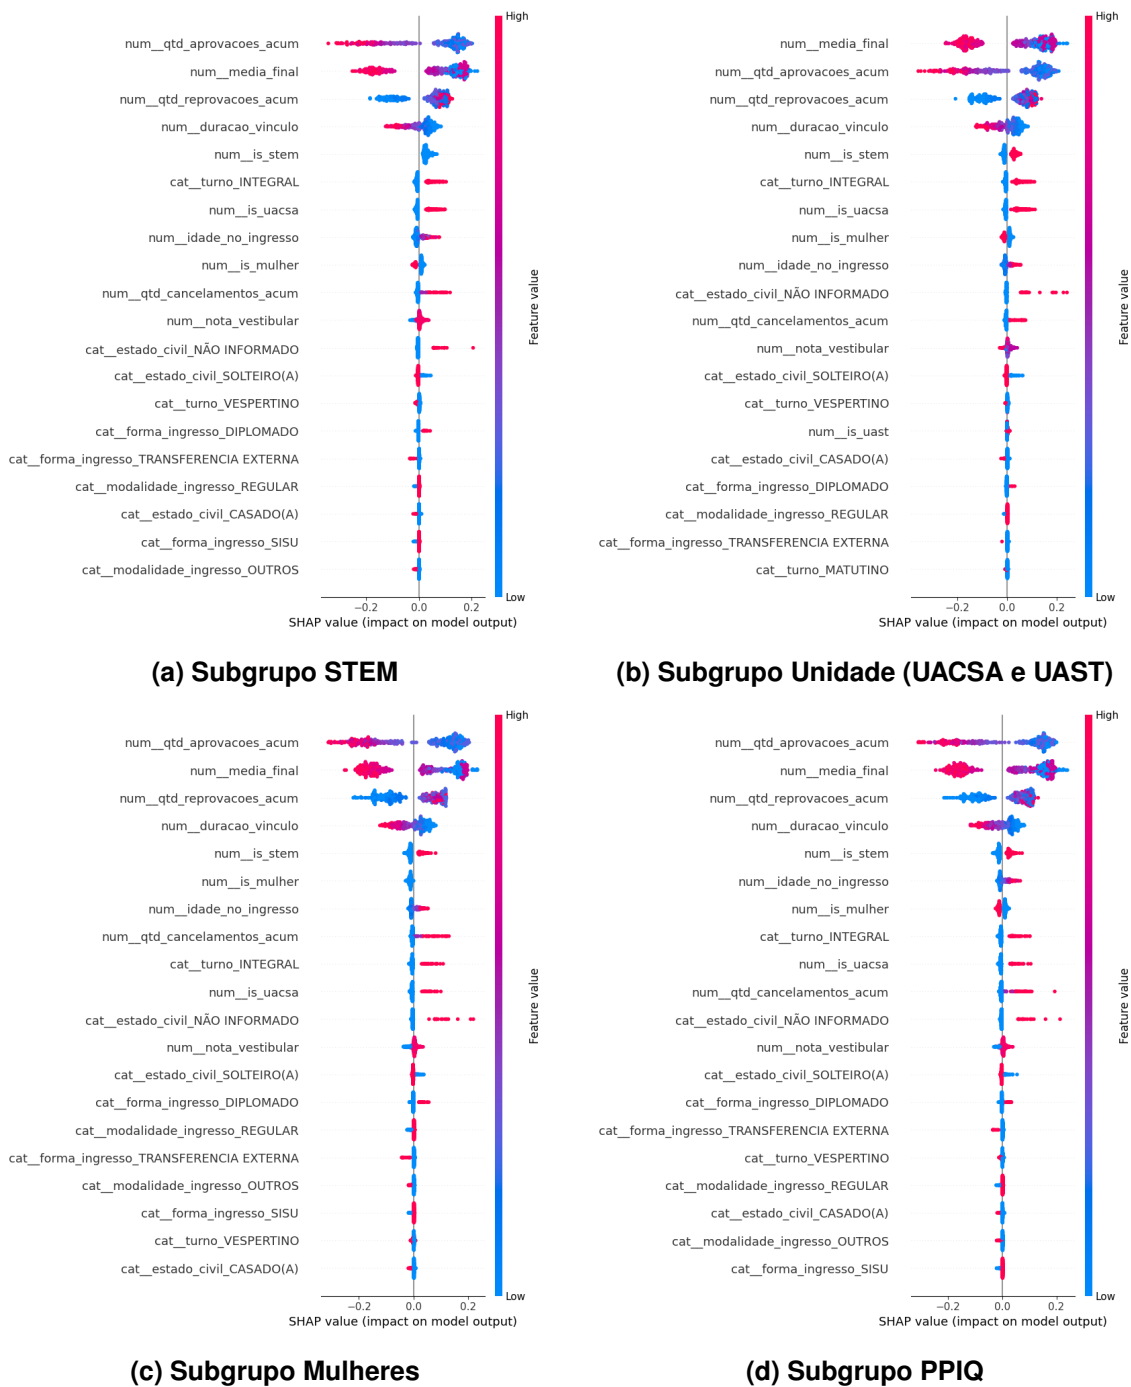


Figura 4. Comparativo de explicabilidade SHAP Beeswarm.

importância dos atributos que o mecanismo desse comportamento se torna claro.

Na Figura 4, são apresentados quatro gráficos, gerados exclusivamente a partir de registros pertencentes aos subgrupos analisados (STEM, Unidade, Mulheres e PPIQ), totalizando 500 amostras aleatórias em cada visualização.

Assim como observado no gráfico Geral (Figura 3), a comparação entre os subgrupos revela a repetição de alguns padrões estruturais de decisão. A *qtd_aprovacoes_acum* está no topo em todos os gráficos (a, c e d), menos no da Unidade (b), em

que a *media_final* ocupa o topo do *ranking* de importância. E, no caso da *qtd_reprovações_acum* e da *media_final*, ainda é possível observar mais cores do lado direito (evasão) em comparação ao oposto. Além disso, os valores SHAP se tornam mais graduais quando se trata da *qtd_aprovações_acum* e *duracao_vinculo*, não apresentando grandes acúmulos numa posição só, mas sim uma variação menos abrupta do lado esquerdo (formação).

Quanto aos outros atributos, *is_stem* e *is_uacsa* parecem consistentemente como impulsionadores da probabilidade de evasão. Da mesma forma, uma *idade_no_ingrso* mais alta aparece frequentemente associada a maior chance de evasão (pontos vermelhos à direita).

A semelhança estrutural entre esses gráficos é um sinal positivo de consistência, indicando que o modelo não altera radicalmente sua lógica de decisão baseada no mérito acadêmico ao avaliar diferentes grupos. Contudo, é na influência marginal dos atributos sensíveis que se explicam as disparidades de justiça (FPR e FNR) discutidas na seção anterior.

Na Figura 4 (gráficos *a* e *b*), observa-se que as variáveis indicadoras de STEM e UACSA (pontos vermelhos) deslocam sistematicamente a predição para a direita (valores positivos). Esse incremento na probabilidade de evasão atua como uma penalidade fixa, explicando o Viés Punitivo (alto FPR) na Tabela 12: alunos desses grupos já partem de um patamar de risco mais elevado na ótica do algoritmo, facilitando classificações incorretas de evasão (falsos positivos).

Por outro lado, no gráfico *c* (Figura 4), referente ao subgrupo de *Mulheres*, a variável de gênero atua na direção oposta. Nota-se que ser do gênero feminino (pontos vermelhos na variável *is_mulher*) tende a deslocar a predição para a esquerda (valores negativos). Isso confirma visualmente a hipótese do Viés de Negligência: o modelo utiliza o gênero feminino como um fator redutor de risco (fator de proteção). Consequentemente, alunas que apresentam sinais acadêmicos de alerta podem ter sua gravidade atenuada por esse peso negativo, resultando na alta taxa de Falsos Negativos (FNR) observada (Tabela 12).

Por fim, a análise expande-se para as interseccionalidades, onde múltiplos atributos sensíveis coexistem no mesmo indivíduo. A Figura 5 apresenta os gráficos para os subgrupos *Mulher, PPIQ* e *Mulher, PPIQ, Unidade*.

A visualização destes cenários complexos revela um fenômeno de interação competitiva entre os vieses detectados isoladamente:

- No gráfico *a* (Figura 5), observa-se a coexistência de dois vetores opostos de influência. Enquanto a variável *is_stem* (quando presente/vermelha) empurra a predição para a direita (risco/punição), a variável *is_mulher* empurra simultaneamente para a esquerda (proteção/negligência). O atributo racial, novamente, não figura entre os determinantes principais, confirmando a neutralidade observada anteriormente.
- No gráfico *b* (Figura 5), que representa a máxima interseccionalidade (incluindo localização), a tensão decisória se intensifica. Nota-se que as variáveis de risco (*is_stem* e *is_uacsa*) somam forças para deslocar a predição para a evasão. Contudo, o atributo de gênero (*is_mulher*) permanece atuando como um fator atenu-

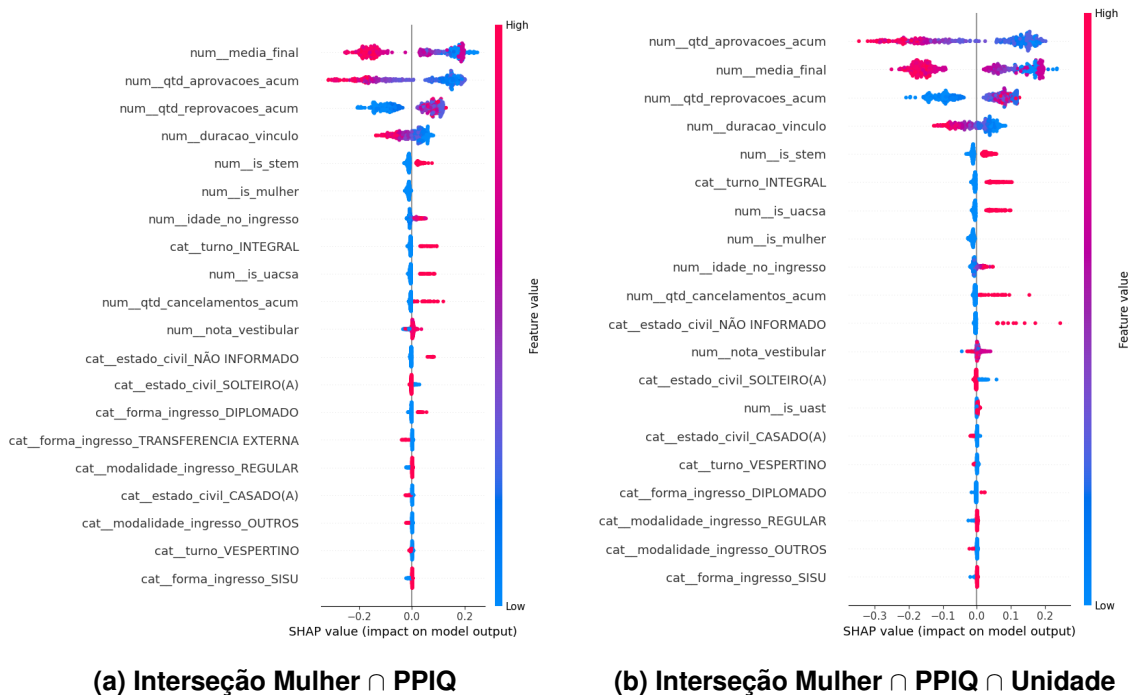


Figura 5. Comparativo de explicabilidade SHAP Beeswarm para interseccionalidades.

ante, reduzindo a probabilidade final.

Como mostrado na Tabela 12, mesmo em cenários geográficos e acadêmicos punitivos (UACSA/STEM), o “fator de permanência” atribuído ao gênero feminino é forte o suficiente para atenuar o risco percebido pelo modelo. Essa dinâmica resulta na persistência da negligência, evidenciada pelas altas taxas de Falsos Negativos nos grupos Mulher, PPIQ (FNR: 0,20) e Mulher, PPIQ, Unidade (FNR: 0,19), mesmo dentro de contextos que, estruturalmente, sofreriam punição. O modelo, ao tentar equilibrar esses pesos conflitantes, acaba por falhar na identificação correta de alunas que, apesar de estarem em situações de risco (Engenharías/UACSA), são classificadas incoerentemente apenas pelo seu gênero.

7. Respostas às Perguntas de Pesquisa

Esta seção sintetiza os achados descritos na Seção 6, com foco nas respostas para as questões norteadoras definidas no início da pesquisa.

7.1. PP1: Os modelos de previsão de evasão apresentam viés algorítmico significativo, especificamente em relação aos estudantes da área de STEM?

Sim, os resultados obtidos (Tabela 12) confirmam a existência de um viés punitivo específico. A auditoria algorítmica conduzida neste trabalho demonstrou que estudantes da área de STEM são desproporcionalmente “acusados” pelo classificador. Embora o modelo tenha alta sensibilidade para este grupo, a análise do presente trabalho revelou uma taxa elevada de Falsos Positivos (FPR), rotulando incorretamente estudantes formados como evadidos com maior frequência do que no grupo geral. Conclui-se que esse comportamento deriva da forte correlação histórica entre a área de exatas e a evasão (aprendida pelo modelo durante o treinamento), resultando em uma generalização excessiva que estigmatiza o estudante de STEM como um provável evasor.

7.2. PP2: De que maneira os atributos sensíveis, isoladamente ou em interseção, alteram a natureza do erro cometido pelo modelo?

A Tabela 12, elaborada a partir da metodologia de avaliação combinada (desempenho e justiça), foi crucial para responder a essa questão. O estudo evidenciou que o comportamento do modelo está condicionado diretamente pela taxa base de evasão histórica de cada grupo protegido. Foi possível diagnosticar, por exemplo, que o subgrupo *PPIQ*, devido a sua ampla representatividade numérica na amostra (62,31%) e com percentuais de evadidos parecidos com os que não pertencem ao grupo (menos de 2% de diferença em todas as áreas), acabou moldando o comportamento padrão do classificador, apresentando métricas de justiça alinhadas ao desempenho geral e atuando como um fator de neutralidade nas intersecções.

Em contrapartida, esta investigação detectou disparidades críticas: grupos com maior percentual de evadidos, como no caso dos subgrupos *STEM* (86,62%) e *UACSA* (93,14%), tendem a ter mais erros de Falsos Positivos (FPR) (0,17 e 0,28 respectivamente). Enquanto os com menor percentual de evadidos, no caso dos subgrupos *Mulher* (69,06%) e *UAST* (74,35%), sofrem de erros de Falsos Negativos (FNR) (0,20 e 0,21 respectivamente), caracterizando o achado como viés de negligência; o erro mais grave que o modelo pode cometer na classificação. Ambos os tipos de erros costumam vir acompanhados de altas diferenças de Paridade Demográfica (DPD) (como de 0,38 na *UACSA* e 0,28 em *STEM*) e Chances Iguais (EOD) (0,18 na *UACSA* e 0,14 em *STEM*), sendo que a combinação dessas métricas na análise foi decisiva para entender o comportamento do modelo para com cada subgrupo.

Quanto às interseccionalidade dos grupos, elas acabaram acompanhando o tipo de viés das vulnerabilidades presentes no recorte. Os testes realizados demonstraram que a característica de ser mulher foi a que mais propagou viés em outros subgrupos, como observado em *Mulher, PPIQ* e *Mulher, PPIQ, Unidade*, ao notar a alta posição da variável *is_mulher* nos gráficos da Figura 5.

7.3. PP3: A utilização de técnicas de explicabilidade (XAI) é eficaz para identificar os mecanismos de decisão que geram essas injustiças algorítmicas?

A implementação da técnica SHAP neste estudo provou-se indispensável, permitindo não apenas visualizar, mas explicar a origem das disparidades métricas observadas na Tabela 12.

A inspeção detalhada dos gráficos *Beeswarm* (Figuras 3, 4 e 5) desvendou a direção da influência de cada atributo sensível. Validou-se empiricamente que a variável *is_stem* (Figura 4 a) atua impulsionando a probabilidade de evasão (valores de SHAP positivos, à direita), o que justifica o viés punitivo observado. Inversamente, foi demonstrado que a variável *is_mulher* (Figura 4 c) exerce, predominantemente, uma força contrária em direção à classe Formada (valores à esquerda), ilustrando a negligência observada no FNR.

Além disso, o XAI foi fundamental para evidenciar a disparidade geográfica: pertencer à unidade *UACSA* adiciona risco à predição (evasão), enquanto a variável *UAST* tem impacto reduzido. A análise explicativa também confirmou a ausência da variável racial (*PPIQ*) entre os preditores de maior impacto no gráfico global, corroborando a

descoberta de neutralidade observada nas métricas de erro para este grupo, indicando que a raça, neste conjunto de dados específico, não foi utilizada pelo modelo como fator discriminante primário.

8. Conclusão

O presente estudo confirmou a premissa de que a aplicação de tecnologias de Machine Learning na educação, embora promissora para mitigar a evasão, carrega o risco de reproduzir desigualdades estruturais históricas. Ao investigar um modelo de previsão treinado com dados da UFRPE, no contexto do projeto ODG, esta pesquisa cumpriu seu objetivo principal ao identificar, analisar e quantificar vieses algorítmicos, evidenciando empiricamente que a alta acurácia global pode mascarar disparidades severas de justiça para grupos vulneráveis.

As respostas às perguntas de pesquisa permitiram diagnosticar uma dicotomia preocupante na natureza do erro algorítmico, que oscila entre a punição e a negligência. Em resposta à PP1 e PP2, os resultados mostraram que o modelo reproduz estigmas históricos contra estudantes de áreas de STEM e de campi específicos (UACSA), gerando um viés punitivo caracterizado pelo excesso de falsos positivos. Simultaneamente, e de forma mais crítica, a análise detectou um viés de negligência em relação ao gênero feminino e campi com menor taxa base de evasão (UAST), onde o modelo falha em identificar estudantes em risco (altos Falsos Negativos), invisibilizando quem necessita de suporte.

Adicionalmente, em resposta à PP3, a aplicação de técnicas de XAI (SHAP) mostrou-se fundamental nesta pesquisa não apenas para validar estatisticamente essas métricas, mas para expor os mecanismos de decisão do “caixa-preta”. Foi possível explicitar que o modelo aprendeu a associar o gênero feminino à permanência de forma generalista, criando um “ponto cego” que prejudica a identificação de alunas que fogem dessa regra estatística.

Esses achados fundamentam implicações diretas para a gestão acadêmica. A utilização acrítica deste modelo para orientar políticas de assistência estudantil poderia resultar, paradoxalmente, no desperdício de recursos com alunos que não evadiriam (no caso de STEM) e na desassistência de estudantes femininas que efetivamente abandonarão o curso. Portanto, a transparência algorítmica deixa de ser um requisito técnico opcional e consolida-se, à luz destes resultados, como uma exigência ética para a implementação de sistemas preditivos em instituições públicas.

8.1. Trabalhos Futuros

Como exposto na Seção 4, esta pesquisa não contou com dados que identifiquem explicitamente estudantes transgêneros, o que torna a detecção de padrões de evasão desse grupo um desafio metodológico. Sugere-se como trabalho futuro a utilização de bases de dados que contemplem a diversidade de gênero real observada no corpo discente. Em instituições que possuem políticas de inclusão consolidadas, o atributo do nome social pode ser utilizado como uma variável *proxy* para a identificação dos alunos transgêneros. Além disso, propõe-se uma investigação comparativa para verificar se o ambiente institucional mais acolhedor e as políticas de assistência estudantil dessas universidades resultam em taxas de evasão nesse grupo menores do que a média nacional. Na escassez de dados quantitativos de transgeneridade, recomenda-se a adoção de análises qualitativas para aprofundar a compreensão das barreiras específicas enfrentadas por esses estudantes.

Além disso, dado o caráter diagnóstico deste estudo, a continuidade da pesquisa deve priorizar a implementação de intervenções corretivas. Sugere-se a exploração de técnicas de pós-processamento para o ajuste de limiares de decisão, visando garantir a Igualdade de Oportunidades (*Equalized Odds*) sem comprometer a acurácia global do sistema [Hardt et al. 2016]. Recomenda-se, simultaneamente, a realização de estudos qualitativos junto a gestores acadêmicos para validar a interpretabilidade das explicações geradas pelo SHAP e a incorporação de variáveis socioeconômicas mais detalhadas. Tais avanços permitiriam refinar a distinção do risco individual, reduzindo a dependência de generalizações demográficas e fortalecendo a confiança institucional para a adoção de ferramentas de suporte à permanência estudantil.

9. Anexo

Tabela 13. Dicionário de Atributos e Variáveis do Modelo de Previsão de Evasão

Atributo	Tipo	Descrição
nota_vestibular	Numérica (Contínua)	Nota obtida no processo seletivo de entrada (ex: ENEM).
media_final	Numérica (Contínua)	Média global acumulada do discente até o momento da observação.
idade_no_ingresso	Numérica (Contínua)	Idade do discente no momento de ingresso na instituição.
qtd_aprovacoes_acum	Numérica (Inteira)	Quantidade total de disciplinas concluídas com aprovação.
qtd_reprovacoes_acum	Numérica (Inteira)	Quantidade total de disciplinas em que o discente foi reprovado.
qtd_cancelamentos_acum	Numérica (Inteira)	Quantidade total de disciplinas canceladas ou trancadas.
duracao_vinculo	Numérica (Inteira)	Tempo de permanência do aluno na instituição (contado em períodos).
is_mulher	Binária (Inteira)	Variável indicando o gênero (1 para feminino, 0 para masculino).
is_assistido	Binária (Inteira)	Variável indicando se o discente recebe auxílio estudantil.
is_nao_branco	Binária (Inteira)	Variável indicando se o discente se autodeclara preto, pardo, indígena ou quilombola.
is_stem	Binária (Inteira)	Variável indicando se o curso pertence à área de STEM (Ciências, Tecnologia, Engenharia e Matemática).
is_funcionario	Binária (Inteira)	Variável indicando se o discente possui vínculo empregatício com a instituição.

Continua na próxima página.

Tabela 13. Continuação

Atributo	Tipo	Descrição
is_uast / is_uacsa	Binária (Inteira)	Variáveis indicando a unidade acadêmica (campus) do curso.
forma_ingresso	Catagórica (Nominal)	Modalidade de entrada na instituição (ex: SiSU, Transferência, Diplomado).
turno	Catagórica (Nominal)	Turno de realização do curso (Matutino, Vespertino, Noturno ou Integral).
estado_civil	Catagórica (Nominal)	Estado civil declarado pelo discente (ex: Solteiro, Casado).
modalidade_ingresso	Catagórica (Nominal)	Tipo de vaga ocupada no ingresso (Regular e Outros).

Referências

- Alvim, Í. V. et al. (2024). Evasão nos cursos de graduação em computação no brasil.
- Alyahyan, E. and Düşteğör, D. (2020). Predicting academic success in higher education: literature review and best practices. *International journal of educational technology in higher education*, 17(1):3.
- ANDIFES (1996). Diplomação, retenção e evasão nos cursos de graduação em instituições de ensino superior públicas. Technical report, Comissão Especial de Estudos sobre a Evasão nas Universidades Públicas Brasileiras, Brasília.
- Barbosa, T., Freitas, N., Cavalcanti, L., Batista, M. d. C. M., Gouveia, R., and Alves, G. (2024). Construção dinâmica de modelos de learning analytics explicáveis e justos aplicados ao acompanhamento de estudantes de graduação. In *Simpósio Brasileiro de Informática na Educação (SBIE)*, pages 1918–1930. SBC.
- Barocas, S., Hardt, M., and Narayanan, A. (2023). *Fairness and machine learning: Limitations and opportunities*. MIT press.
- Barocas, S. and Selbst, A. D. (2016). Big data’s disparate impact. *Calif. L. Rev.*, 104:671.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1):5–32.
- Brito, B., Mello, R., and Alves, G. (2020). Identificação de atributos relevantes na evasão no ensino superior público brasileiro. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação*, pages 1032–1041, Porto Alegre, RS, Brasil. SBC.
- Cavalcanti, L., Freitas, N., Marques, E., Batista, M., Lima, S., Mello, R., Cristino, C., and Alves, G. (2025). Avaliação do impacto do gênero e da assistência estudantil sobre a sobrevivência dos estudantes em cursos de stem. In *Anais do XXXVI Simpósio Brasileiro de Informática na Educação*, pages 731–745, Porto Alegre, RS, Brasil. SBC.
- Clow, D. (2012). The learning analytics cycle: closing the loop effectively. In *Proceedings of the 2nd international conference on learning analytics and knowledge*, pages 134–138.

- Das, S., Stanton, R., and Wallace, N. (2023). Algorithmic fairness. *Annual Review of Financial Economics*, 15(1):565–593.
- Ferguson, R. (2012). Learning analytics: drivers, developments and challenges. *International journal of technology enhanced learning*, 4(5-6):304–317.
- Filho, F., Vinuto, T., and Leal, B. (2020). Análise de classificadores para predição de evasão dos campi de uma instituição de ensino federal. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação*, pages 1132–1141, Porto Alegre, RS, Brasil. SBC.
- Gardner, J., Brooks, C., and Baker, R. (2019). Evaluating the fairness of predictive student models through slicing analysis. In *Proceedings of the 9th international conference on learning analytics & knowledge*, pages 225–234.
- Gil, A. C. (2008). *Métodos e técnicas de pesquisa social*. 6. ed. Editora Atlas SA.
- Gomes, M. and Hirata, G. (2022). Determinantes da evasão no ensino superior: uma abordagem de riscos competitivos. *Pesquisa e Planejamento Econômico*.
- Hardt, M., Price, E., and Srebro, N. (2016). Equality of opportunity in supervised learning. *Advances in neural information processing systems*, 29.
- INEP (2024). Apresentação do censo da educação superior 2024. Technical report, Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira, Brasília. Acesso em: 23 dez. 2025.
- Kaufman, S., Rosset, S., Perlich, C., and Stitelman, O. (2012). Leakage in data mining: Formulation, detection, and avoidance. *ACM Transactions on Knowledge Discovery from Data (TKDD)*, 6(4):1–21.
- Kelleher, J. D., Mac Namee, B., and D’arcy, A. (2020). *Fundamentals of machine learning for predictive data analytics: algorithms, worked examples, and case studies*. MIT press.
- Kizilcec, R. F. and Lee, H. (2022). Algorithmic fairness in education. In *The ethics of artificial intelligence in education*, pages 174–202. Routledge.
- Lipton, Z. C. (2018). The mythos of model interpretability: In machine learning, the concept of interpretability is both important and slippery. *Queue*, 16(3):31–57.
- Lundberg, S. M. and Lee, S.-I. (2017). A unified approach to interpreting model predictions. In Guyon, I., Luxburg, U. V., Bengio, S., Wallach, H., Fergus, R., Vishwanathan, S., and Garnett, R., editors, *Advances in Neural Information Processing Systems*, volume 30. Curran Associates, Inc.
- Marques, E., Cavalcanti, L., Barbosa, T., and Alves, G. (2023). Sabia: Uma plataforma para auxiliar a gestão baseada em evidências nas instituições de ensino superior. In *Workshop de Aplicações Práticas de Learning Analytics em Instituições de Ensino no Brasil (WAPLA)*, pages 71–80. SBC.
- Mitchell, S., Potash, E., Barocas, S., D’Amour, A., and Lum, K. (2021). Algorithmic fairness: Choices, assumptions, and definitions. *Annual review of statistics and its application*, 8(1):141–163.
- OECD (2025). *Education at a Glance 2025: OECD Indicators*. OECD Publishing, Paris.

- Rastrollo-Guerrero, J. L., Gómez-Pulido, J. A., and Durán-Domínguez, A. (2020). Analyzing and predicting students' performance by means of machine learning: A review. *Applied Sciences*, 10(3).
- Romero, C. and Ventura, S. (2010). Educational data mining: a review of the state of the art. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (applications and reviews)*, 40(6):601–618.
- Saccaro, A., França, M. T. A., and Jacinto, P. d. A. (2019). Fatores associados à evasão no ensino superior brasileiro: um estudo de análise de sobrevivência para os cursos das áreas de ciência, matemática e computação e de engenharia, produção e construção em instituições públicas e privadas. *Estudos Econômicos (São Paulo)*, 49(2):337–373.
- Schymura, L. G. (2024). Diferencial salarial do ensino superior cai no brasil, mas nível ainda é elevado e recompensador. *Revista Conjuntura Econômica*, 78(10):8–11.
- Siemens, G. (2013). Learning analytics: The emergence of a discipline. *American Behavioral Scientist*, 57(10).
- Silva Filho, R. L. L., Motejunas, P. R., Hipólito, O., and Lobo, M. B. d. C. M. (2007). A evasão no ensino superior brasileiro. *Cadernos de pesquisa*, 37:641–659.
- Wooldridge, J. M. (2016). *Introductory econometrics a modern approach*. South-Western cengage learning.