

Construção dinâmica de modelos de learning analytics explicáveis e justos aplicados ao acompanhamento de estudantes de graduação

Tarcísio Barbosa¹, Nathan Freitas¹, Lhaislla Cavalcanti¹
Maria da Conceição Moraes Batista¹, Roberta Gouveia¹ e Gabriel Alves¹

¹Universidade Federal Rural de Pernambuco (UFRPE)
Recife — PE — Brasil

{tarcisio.bcosta, nathan.freitas, lhaislla.cavalcanti,
maria.cmbatista, roberta.gouveia, gabriel.alves}@ufrpe.br

Abstract. *With the growing use of AI in various fields, there is an urgent need for metrics and tools that assist in building explainable, transparent, and ethical models, particularly within the educational context. Thus, it is not sufficient for a model to merely perform well; it is essential to understand how it classifies individuals and to identify potential biases in this classification. This paper proposes a system that aids in this process, aiming to identify the risk of student dropout in higher education. It uses students' attributes to build classification models that are both explainable and fair. In addition to providing charts that clarify how the student was classified, performance metrics are also presented across different groups, such as gender or race, to detect algorithmic biases.*

Resumo. *Com a crescente utilização da IA em diferentes áreas do conhecimento, urge a adoção de métricas e ferramentas que auxiliem na construção de modelos explicáveis, transparentes e éticos, especialmente no contexto educacional. Assim, não é suficiente que um modelo possua um bom desempenho, mas é necessário saber como o modelo está classificando um indivíduo e identificar possíveis vieses na classificação. Esse trabalho propõe um sistema que auxilia nessa atividade, a fim de identificar o risco de evasão dos estudantes no ensino superior. Os atributos dos discentes são utilizados para construir modelos de classificação explicáveis e justos. Assim, além de gráficos que explicam como o estudante foi classificado, as métricas de desempenho também são apresentadas por grupos como gênero ou raça a fim de identificar vieses algorítmicos.*

1. Introdução

O avanço contínuo da tecnologia possibilitou o surgimento de novas abordagens que substituem os métodos tradicionais de registro de informações, impulsionando a fundamentação das decisões organizacionais em evidências. À medida que as organizações geram, captam e armazenam cada vez mais dados, desenvolvem-se ferramentas analíticas para auxiliar a formulação de planos estratégicos [de Mesquita et al. 2021].

Abordagens direcionadas a área educacional, como *Learning Analytics* (LA), permitem a obtenção de dados através da interação dos estudantes no ambiente educacional [Zapparolli et al. 2017]. Essas ferramentas abrangem processos que vão desde a

coleta e análise dos dados até a predição de eventos, exercendo um impacto significativo nos sistemas onde se aplicam. Elas permitem, por exemplo, a obtenção de indicadores, comparação de fatores que influenciam no progresso dos estudantes nas instituições de ensino e a identificação de perfis de estudantes propensos ao fenômeno da evasão [Marques et al. 2023]. A evasão estudantil é um conceito amplo que abrange várias variáveis. No entanto, podem-se destacar fatores cruciais que fundamentam a análise, como a evasão de curso, instituição e sistema [MEC 2014].

Nesse contexto, os gestores educacionais se preocupam em interpretar os resultados das técnicas aplicadas, como os modelos de aprendizado de máquina, e têm se empenhado significativamente em garantir que esses sistemas sejam éticos, transparentes e compreensíveis para todos os envolvidos. A Explicabilidade em Inteligência Artificial (XAI) [Gunning et al. 2019] surge como um meio de garantir essa transparência e a explicabilidade de como os algoritmos tomam decisões, o que é essencial para estabelecer a confiança nos modelos treinados e compreender o impacto das intervenções baseadas em IA na educação.

Este trabalho propõe o desenvolvimento de um painel voltado à análise do desempenho e perfil dos alunos. Criado no *System of Academic Business Intelligence and Analytics (SABIA)*, um dashboard que dá suporte à gestão baseada em evidências em instituições do ensino superior agregando conceitos como o *Learning Analytics (LA)* [Marques et al. 2023], o painel tem como ênfase na identificação de padrões e evidências que possam prevenir a evasão. Com esse recurso, gestores poderão tomar decisões estratégicas e criar um ambiente de aprendizado mais eficaz, direcionando políticas de inclusão e suporte aos perfis estudantis com maior risco de abandono.

Este painel permite avaliar o impacto de cada perfil de aluno na probabilidade de conclusão ou evasão do curso, possibilitando a análise da influência de cada variável. Também oferece a capacidade de construir e analisar classificadores, fornecendo métricas de desempenho, explicabilidade e importância das características. Além disso, são apresentadas métricas de justiça, revelando diferenças nas métricas de desempenho por fatores como gênero, raça ou unidade acadêmica, o que está diretamente relacionado à vulnerabilidade socioeconômica dos estudantes.

2. Trabalhos Relacionados

A plataforma SABIA permite explorar, por meio de sua arquitetura, sua capacidade de apoiar decisões estratégicas em instituições de ensino. O estudo de [Marques et al. 2023] analisou a plataforma, demonstrando sua eficácia na análise de grandes volumes de dados educacionais com técnicas preditivas e descritivas. Ele evidenciou como a plataforma fornece dados que permitem intervenções bem fundamentadas, permitindo uma alocação mais eficiente de recursos pelos gestores.

Dentro das abordagens da plataforma, é possível observar estudos como a alteração na matriz curricular influenciou o desempenho acadêmico dos alunos de Licenciatura em computação na Universidade Federal Rural de Pernambuco (UFRPE) [Silva 2024]. Utilizando indicadores de qualidade e dados do ENADE, o estudo mostrou que as mudanças curriculares implementadas resultaram em um impacto positivo no desempenho dos estudantes, evidenciando a importância do SABIA auxílio na análise de decisões estratégicas.

Diante da importância da prevenção da evasão escolar, [Zapparolli et al. 2017] expõe os resultados de ferramentas desenvolvidas utilizando técnicas de *Business Intelligence* e *Learning Analytics*. Além disso, é apresentada uma ferramenta, chamada FAG, que fornece relatórios analíticos e consolidados com visões sistêmicas e transversais. E, com esses relatórios, os professores e gestores podem acompanhar detalhadamente as ações de seus alunos, para que possam tomar medidas para evitar a evasão. Vale mencionar também o trabalho de [Filho et al. 2020], que destaca a prevenção da evasão como algo mais importante do que as ações reativas a esse problema. Assim, define-se a evasão estudantil como um problema de classificação, com o objetivo de gerar modelos para prever a evasão discente utilizando classificadores de *Machine Learning*, ou aprendizagem de máquina. Essa atuação faz com que a equipe pedagógica possa tomar decisões que diminuam a ocorrência da evasão estudantil. Adotando conceitos semelhantes de análise de modelos de *machine learning* no contexto educacional, este trabalho propõe uma abordagem mais dinâmica e interativa com os modelos, permitindo sua construção nas mãos do próprio usuário.

Para melhor compreensão dos resultados do treinamento dos modelos de aprendizado de máquina é possível ter um ênfase nas suas interpretabilidade. A explicabilidade contribui para sua robustez, permitindo um processo iterativo de *feedback*. Isso proporciona uma experiência ao usuário que possibilita a compreensão do modelo, habilitando o usuário a tomar as decisões necessárias [Khosravi et al. 2022]. Apesar dos dados educacionais apresentarem muitas fontes de ruído é importante garantir a justiça, responsabilidade, transparência e a ética nos processos que não envolvem apenas interesses para os estudantes, mas professores, administradores educacionais e até os pais.

Sob esse ponto de vista, estudos como o de [Carvalho et al. 2023], aplicam LIME para explicar a predição da evasão na Universidade Federal de Pelotas (UFPEL), utilizando *clusters* e centróides. Técnicas como SHAP e Counterfactual foram usadas para analisar o desempenho escolar em São Paulo com o exame SARESP [Neto et al. 2021], mostrando que algumas características como escolas com menos turmas e mais alunos têm baixo desempenho. O trabalho também investiga a aplicação da SHAP para entender a evasão, combinando princípios de justiça com *Business Intelligence* e *Analytics*.

3. Método

Nesta seção, será descrita a proposta do sistema voltado para a previsão de evasão e conclusão dos estudantes, descrevendo seu funcionamento desde a ingestão dos dados até a apresentação dos resultados na tela para o usuário, através da plataforma do SABIA. Foi elaborado um fluxograma (Figura 1) ilustrando este processo.

3.1. Ingestão e tratamento de dados

A partir dos dados oriundos do sistema de gestão acadêmica da Universidade Federal Rural de Pernambuco (UFRPE) e de bases públicas como o Censo da Educação Superior, disponibilizada pelo Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira (INEP), foi criado um *Data Lake* (DL) com dados a serem utilizados no SABIA. Neste sistema, cada página e seus respectivos painéis possuem seu próprio *Data Mart*, onde são realizados a ingestão e tratamento de dados a fim de garantir melhor desempenho. *Data Marts* são subconjuntos do DL e refinadas para casos de uso mais específicos, de acordo com os requerimentos do usuário [Marques et al. 2023].

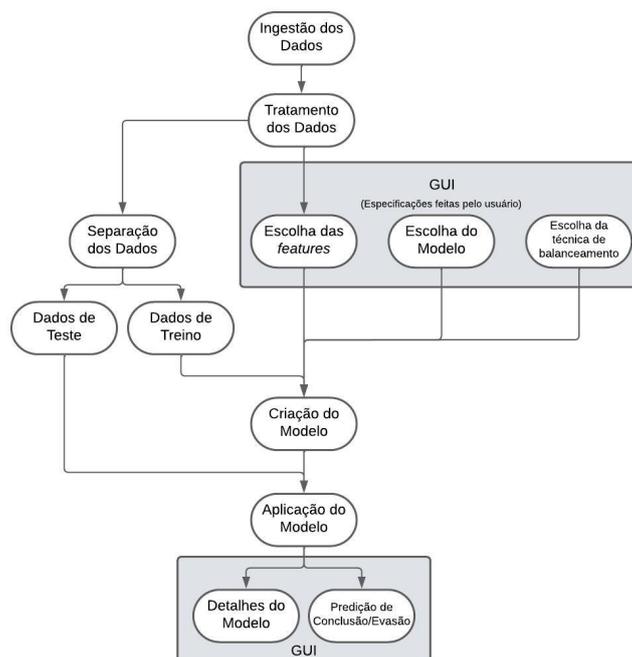


Figura 1. Fluxograma com as etapas da página até a exibição dos resultados.

Os dados são atualizados semestralmente, visto que a situação dos discentes são atualizados ao final de período, além dos dados do INEP demandarem um tempo para serem publicados. Portanto, não há necessidade de atualizar os *Data Marts* em tempo real. Contudo, atualizações intermediárias podem ser realizadas sob demanda, sempre que necessário.

Dentre as etapas realizadas no processo de tratamento dos dados, cita-se a remoção e filtragem de dados duplicados/inconsistentes da base de dados, a criação de campos como a duração do vínculo ou a quantidade de reprovações acumuladas por semestre e a modificação de tipos de dados.

3.2. Construção do modelo

O passo seguinte é construir o modelo, de acordo com o que o usuário especifica em abas presentes no painel. A primeira configuração é a escolha de atributos que estarão inclusos no modelo, baseadas em dados presentes nas colunas dos *Data marts* disponibilizados para a página de previsão. A segunda se trata de qual algoritmo de aprendizado de máquina será utilizado pelo modelo. Por fim, o usuário seleciona uma técnica de balanceamento de dados.

O painel foi projetado para ser escalável para modelos baseados em aprendizagem supervisionada. O usuário pode selecionar livremente o método de balanceamento, classificador e os atributos, que são baseados em colunas presentes nos *data marts* processados antes da criação do modelo. Para esse trabalho, foram utilizados uma quantidade limitada de modelos do *Scikit-Learn* [Pedregosa et al. 2011]: *Random Forest*, *SVM*, *Naive Bayes* e o *KNN*.

Como recorte, serão considerados para cálculo os estudantes que já encerraram o

vínculo com a IES, ou seja, as únicas classes de situação acadêmica final presentes serão *FORMADO* e *EVADIDO*. Para funcionamento dos modelo no *Scikit-Learn* utilizou-se a codificação das colunas da base de dados por meio de métodos de *encoder*.

A página de previsão utiliza diferentes classificadores de dados para realizar a previsão da situação acadêmica. Contudo, observa-se a importância de balancear os dados entre as classes no conjunto de treinamento [Barbosa et al. 2019], evitando que ocorram vieses nas classes minoritárias [Van Hulse et al. 2007]. Dentre as estratégias de balanceamento existentes, duas estratégias tradicionais são o *oversampling* e o *undersampling*. Algoritmos de *oversampling* lidam com dados desbalanceados aumentando o número de elementos na classe minoritária, através da criação de dados sintéticos baseados nos elementos existentes na amostra, enquanto os de *undersampling* cortam elementos da classe majoritária a fim de aproximar a quantidade de elementos entre as classes [Barbosa et al. 2019, Han et al. 2011]. Além dessas duas opções, foi considerado a aplicação de uma abordagem híbrida que considera simultaneamente as duas estratégias mencionadas.

Vale salientar, que além das opções diretamente relacionadas ao processo de construção do modelo, o SABIA inclui elementos que permitem a filtragem sobre os dados neste e nos demais painéis. Essa funcionalidade pode ser usada para criar filtros apenas para determinados cursos ou unidades acadêmicas, por exemplo. Com isso, é possível criar modelos para a classificação em cursos ou unidades acadêmicas específicas, ou mesmo um único modelo para toda a universidade.

3.3. Avaliação do modelo

Com o modelo treinado, é preparada a visualização dos resultados obtidos pelo modelo para o usuário através da biblioteca *Streamlit*, responsável pela criação de uma aplicação web com suporte a ferramentas de aprendizado de máquina e ciência de dados. Nas páginas montadas, os dados (devidamente processados) são inseridos em gráficos, tabelas e infográficos, criados por funções de bibliotecas como o *Matplotlib* para criação de *plots* estáticos simples e o *Plotly* para visualizações dinâmicas e interativas [Marques et al. 2023].

A interface do sistema possui uma seção dedicada para a análise do modelo criado pelo usuário. Esta seção possui um conjunto de métricas importantes para a compreensão dos resultados, sendo elas: *accuracy*, *precision*, *support*, *recall* e *f1-score*. A *accuracy*, ou acurácia, indica o quão próxima a análise está do objeto a ser observado; em outras palavras, o quanto os dados previstos condizem com os dados reais. A precisão (*precision*) se difere da acurácia sendo uma métrica que demonstra, intuitivamente, a habilidade do classificador de não rotular um elemento negativo como positivo. No caso do SABIA, os valores positivos são os formados, enquanto os negativos são os evadidos. O *support* se trata simplesmente do número de ocorrências daquela classe nos dados disponibilizados. Já a revocação (*recall*) se trata, especificamente, da capacidade do classificador de encontrar os elementos positivos, sem considerar os negativos. O *f-1 score*, por fim, é uma métrica de média harmônica ponderada entre precisão e *recall*, onde a função encontra seu melhor resultado [Pedregosa et al. 2011].

A plataforma oferece uma análise detalhada focada na explicabilidade do modelo, com ênfase na importância das características para a classificação do modelo. As-

sim, os gráficos mostram a influência global ou local de cada característica na previsão de evasão ou formação de um discente. Os gráficos de explicabilidade foram elaborados a partir da *Permutation Feature Importance* [Pedregosa et al. 2011] e dos valores SHAP [Lundberg and Lee 2017]. Com base na teoria dos jogos, a técnica SHAP (*SHapley Additive exPlanation*) apresenta a contribuição das *features* em cada instâncias [Lundberg and Lee 2017]. Este método é agnostico ao modelo, ou seja, pode ser aplicado a modelos treinados com quaisquer algoritmos de aprendizado de máquina. O SHAP ainda pode ser utilizado para realizar explicações globais e locais.

No contexto desse trabalho, a técnica SHAP permite visualizar quais variáveis o modelo considera mais relevantes para determinar se um aluno tem chances de evadir ou se formar. Essa perspectiva é essencial para que os gestores da instituição possam tomar medidas eficazes para evitar a evasão e incentivar a formação dos discentes. Além disso, permite que os pesquisadores ajustem seus modelos para torná-los mais justos. O painel elabora uma análise global dos modelos, destacando a relevância média de cada atributo, e uma análise local que detalha as probabilidades de evasão ou formação e a contribuição de cada *feature* na decisão de cada classe.

Ao treinar o modelo, é possível observar suas métricas de acurácia, *recall*, precisão e f1-score para os conjuntos de treino e de teste. Com isso é possível se ter indicativos de *overfitting* e *underfitting* que são alertados diretamente na plataforma. O alerta de *overfitting* é apresentado caso alguma das métricas esteja muito diferente nos conjuntos de treino e de teste. Além disso, a justiça do modelo também pode ser analisada na plataforma. Os resultados das métricas relativas às classes de evasão e formação também são apresentadas de forma estratificada por grupos de interesse como gênero e raça. Assim, se houver uma disparidade superior a um *threshold* pré-determinado, também é apresentado um alerta ao usuário.

Esse sistema, utiliza como base o método CRISP-DM [Wirth and Hipp 2000]. Assim uma vez treinado e selecionado o modelo, é realizado o seu *deploy* no sistema SABI a fim de realizar a classificação dos estudantes da UFRPE. Os resultados são então reavaliados periodicamente de forma iterativa, atualizando os modelos do sistema. Vale salientar que enquanto esse painel é utilizado pelos especialistas da área de ciência de dados, os modelos criados e seus resultados são utilizados pelos gestores dos cursos da universidade, a fim de acompanhar o risco de evasão dos estudantes.

4. Resultados e Discussões

Nesta seção, será descrito o funcionamento do painel, incluindo as visualizações e possíveis análises que podem ser realizadas com as informações obtidas de um Data Mart gerado a partir da base de dados da UFRPE e do INEP. O painel é organizado em cinco seções principais: modelagem, resultados, explicabilidade, justiça e previsão por perfil. A Figura 4 ilustra visão inicial com essas seções. Vale salientar que os dados da UFRPE utilizados neste trabalho são uma amostra parcial, uma vez que o objetivo deste é apresentar as possibilidades da ferramenta e não analisar o risco de evasão de um cenário específico.

4.1. Construção dos modelos

Inicialmente, é necessário configurar os parâmetros a serem utilizados na construção do modelo, conforme mostrado na Figura 3. Nesse exemplo, foram escolhidas 11 variáveis



Figura 2. Visualização inicial do *dashboard* de previsão.

relacionadas aos estudantes em um classificador *Naive Bayes* sem nenhum balanceador. O usuário pode filtrar as características a serem consideradas para o estudo, permitindo maior flexibilidade na investigação de diferentes cenários. Esse filtro, combinado com as *features* relevantes (seção 4.2), oferecem a possibilidade de criar cenários para analisar como o modelo lida com a presença de diferentes conjuntos de atributos.

Ademais, tanto o gestor quanto o pesquisador podem personalizar o algoritmo de classificação, o método de balanceamento e definir uma *seed* para a aplicação de variáveis aleatórias. Ao preencher esses campos, é possível gerar modelos com diferentes combinações, permitindo uma análise abrangente do desempenho de cada configuração. Essa flexibilidade facilita a criação de cenários diversos, possibilitando uma avaliação detalhada dos modelos treinados e seus resultados.

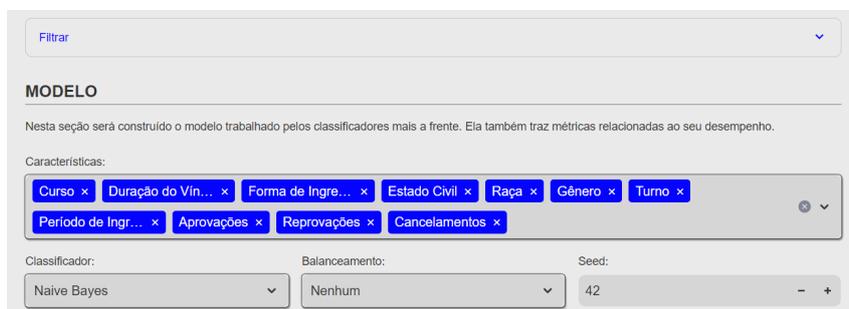


Figura 3. Seção de montagem do modelo para a página de previsão.

4.2. Avaliação dos modelos

Com o modelo ajustado às demandas do usuário, a página fornece gráficos e tabelas que descrevem a performance do classificador (Figura 4), permitindo a verificação de métricas

de desempenho, como precisão e acurácia. Essas informações disponibilizam uma visão inicial da confiabilidade do modelo, dando suporte ao usuário a determinar se ele está adequado para uso ou se necessita de melhorias.

Um problema comum que o pesquisador pode encontrar é o *overfitting* (Figura 4(a), que é expressado por uma queda considerável de desempenho do modelo entre o conjunto de treinamento e teste [Monard and Baranauskas 2003]. No exemplo apresentado na Figura 4(b), pode-se notar altas métricas para alunos evadidos, entretanto, apesar de semelhantes acurácias entre dados de treino e teste, há uma diferença considerável na performance do modelo ao identificar a classe minoritária (formados), indicando que o modelo pode ser melhor adaptado para classificação da mesma. Certas mudanças, como o aumento de elementos na classe minoritária através de um algoritmo de balanceamento por *oversampling*, podem proporcionar maior eficiência.



(a) Modelo com risco de *overfitting*.



(b) Modelo com melhor performance no teste.

Figura 4. Gráficos e Tabelas detalhando a performance de um modelo com dados para treino e teste.

Na seção seguinte, o foco está na explicabilidade. O painel fornece gráficos adi-

cionais a fim de auxiliar a compreensão da influência das características no modelo. Em um primeiro momento há possibilidade de investigar a contribuição das características ao classificador treinado por meio de *feature importance* (Figura 5) e gráficos que explicam a influência das *features* em cada instância, que são disponibilizados pela biblioteca SHAP (Figura 6). Essas análises não apenas facilitam a identificação de melhorias e ajustes no modelo, mas também proporcionam uma compreensão geral de quais atributos distinguem a propensão de um discente à evasão e à conclusão.

No exemplo da Figura 5, ambos os algoritmos indicam grande importância nas características referentes à jornada acadêmica do estudante como cancelamentos, aprovações e reprovações, além da duração do vínculo do estudante na instituição. A significativa disparidade na importância dessas *features* em comparação a outras sugere a necessidade de avaliar o impacto da remoção das características menos relevantes, que podem ser redundantes, podendo assim potencialmente melhorar a eficiência do modelo. Outro ponto que pode ser investigado é o conhecimento prévio da relevância de um atributo, onde discrepâncias significativas podem ser identificadas pelo pesquisador. Essa percepção permite ajustes no modelo para corrigir eventuais problemas.

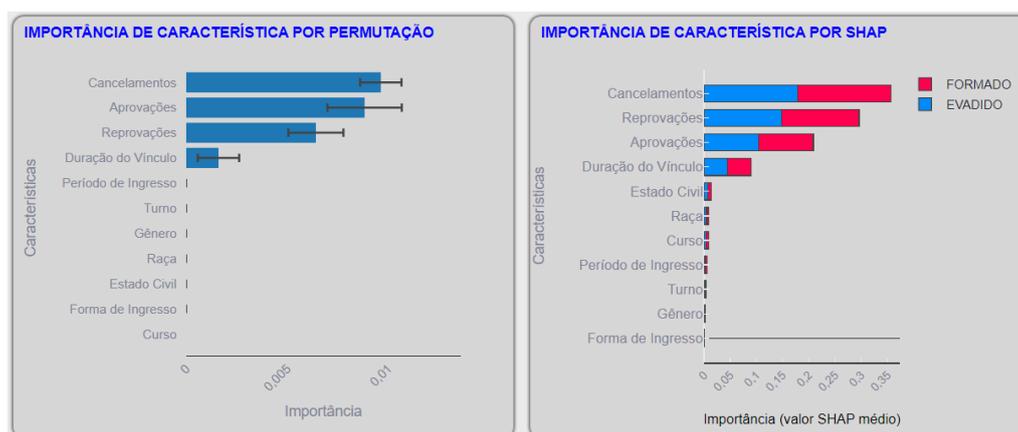


Figura 5. Gráficos de *feature importance* de um modelo criado na página, através de diferentes algoritmos.

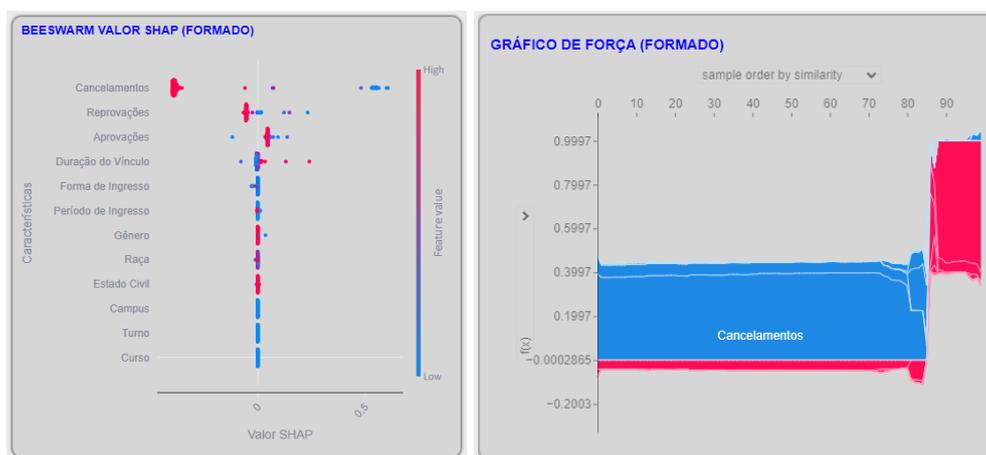
Na Figura 5, há uma distinção por cores. Cada cor representa uma das classes consideradas no contexto do trabalho, indicando se o discente foi evadido (em azul) ou formado (em vermelho). Na Figura em questão, observa-se uma distribuição uniforme de relevância entre as classes. No entanto, é possível que haja pesos de relevâncias diferentes para atributos distintos em cada classe. Por exemplo, um modelo pode atribuir alta relevância ao cancelamento para prever a evasão de alunos, enquanto para a formação essa característica tem pouca importância.

Em reforço às informações obtidas pela Figura 5, com o uso dos valores SHAP, são apresentados dois gráficos: o *Beeswarm* e de força. O primeiro, apresentado na Figura 6(a), ilustra a relação entre as instâncias de alunos em cada valor possível das *features*, evidenciando seu impacto na classificação. No eixo y, são apresentadas as variáveis consideradas no modelo, enquanto o eixo x representa os valores SHAP. Na perspectiva de probabilidade de formação, valores positivos indicam uma tendência do modelo em prever que o aluno pode se formar, enquanto valores negativos sugerem uma tendência à

evasão. As cores variam do azul (menor valor) ao vermelho (maior valor), representando os diferentes níveis dos atributos.

Ao observar o gráfico da Figura 6(a), pode-se observar uma tendência no modelo a prever uma propensão à evasão quando o discente apresenta altos valores de cancelamentos e reprovações. Por outro lado, a quantidade de aprovações tem considerável relevância para considerar o discente como provável para formação.

É possível observar diretamente, através do gráfico de força representado na Figura 6(b), o peso que cada característica possui nas instâncias para a classificação. As classes 'formado' e 'evadido' são representadas pelas cores vermelha e azul, respectivamente. No gráfico de força, é apresentada a contribuição de cada característica para o modelo. Uma funcionalidade relevante a ser citada é a capacidade de filtrar as informações por relevância de características (representada pela entrada no eixo x) e relevância de cada valor do atributo (representada pela entrada no eixo y).



(a) Gráfico *Beeswarm*.

(b) Gráfico de Força.

Figura 6. Exemplos de gráficos da biblioteca SHAP usados no painel.

Adicionalmente, no âmbito de justiça (*fairness*), se reconhece a possibilidade que modelos apresentem vieses obtidos durante diferentes etapas do processo de *machine learning*, sejam eles de fruto computacional (devido a particularidades nos dados em que o mesmo foi treinado) ou sociocultural (devido a reflexão de contextos históricos discriminatórios) [Ruback et al. 2022]. A fim de identificar problemas relacionados a viés anteriores ao pós-processamento, o sistema disponibiliza uma subseção dedicada à análise de justiça de *features*, indicando possíveis discrepâncias de comportamento do modelo para os valores existentes no seu domínio. Esse tipo de análise é especialmente útil para variáveis categóricas, que possuem uma quantidade limitada de valores possíveis.

Ao selecionar um atributo, como pode ser observado na Figura 7, que utiliza gênero como exemplo, pode-se avaliar as métricas de desempenho de *precision*, *recall* e *f1-score* do modelo em cada valor dessa variável. Isso permite identificar se o modelo está apresentando desempenho consistente para todos os valores do domínio ou se há um viés em relação a um perfil específico do atributo.

5. Considerações Finais

Este trabalho trata do processo de desenvolvimento de painéis e a aplicação de XAI em uma plataforma (SABIA) voltados à exibição de indicadores de desempenho acadêmico de estudantes para uso do corpo docente da instituição de ensino. Tais painéis são capazes de apontar os principais fatores influenciando a conclusão ou evasão de diferentes perfis estudantis, contendo uma subseção dedicada à análise de justiça do modelo a fim de diminuir a possibilidade de vieses prejudicarem o processo de tomada de decisão. Desta forma, oferece-se um sistema capaz de fornecer modelos mais explicáveis e justos para o tomador de decisão, facilitando a conexão modelo-usuário de forma semi-automatizada.

A estrutura do sistema elaborado permite a fácil inclusão de novos algoritmos, técnicas e características. Logo, prevê-se que a inclusão de novos elementos no processo de montagem e treino amplie o potencial de análise dos modelos, de acordo com as demandas dos usuários em próximas iterações do sistema. Como perspectivas futuras, identifica-se a possibilidade de trazer mais foco ao pré-processamento interativo na plataforma, além da incorporação de outras técnicas e funcionalidades relativas à explicabilidade e justiça dos modelos.

Referências

- Barbosa, G., de Miranda, P., Mello, R., and Silva, R. (2019). Sequenciamento de algoritmos de amostragem para aumentar o desempenho de classificadores em conjuntos de dados desequilibrados. In *Anais do XVI Encontro Nacional de Inteligência Artificial e Computacional*, pages 413–423. SBC.
- Carvalho, C. S., Mattos, J. C., and Aguiar, M. S. (2023). Avaliação da interpretabilidade de modelos por meio da clusterização de explicações no contexto da predição de evasão no ensino superior. In *Anais do XXXIV Simpósio Brasileiro de Informática na Educação*, pages 1191–1201. SBC.
- de Mesquita, J. L., de Sousa, R. R., Nascimento, S. M., and de Souza, T. F. (2021). Academic analytics como apoio ao sucesso na graduação: uma revisão sistemática da literatura academic analytics to support undergraduate success: a systematic review of the literature. *Brazilian Journal of Development*, 7(10):99882–99897.
- Filho, H., Brito, F. W., Vinuto, T. S., and Leal, B. C. (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. SBC.
- Gunning, D., Stefik, M., Choi, J., Miller, T., Stumpf, S., and Yang, G.-Z. (2019). Xai—explainable artificial intelligence. *Science robotics*, 4(37):eaay7120.
- Han, J., Kamber, M., and Pei, J. (2011). *Data Mining: Concepts and Techniques*. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, 3rd edition.
- Khosravi, H., Shum, S. B., Chen, G., Conati, C., Tsai, Y.-S., Kay, J., Knight, S., Martinez-Maldonado, R., Sadiq, S., and Gašević, D. (2022). Explainable artificial intelligence in education. *Computers and Education: Artificial Intelligence*, 3:100074.
- Lundberg, S. M. and Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in neural information processing systems*, 30.

- 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 *Anais do II Workshop de Aplicações Práticas de Learning Analytics em Instituições de Ensino no Brasil*, pages 71–80, Porto Alegre, RS, Brasil. SBC.
- MEC (2014). Documento orientador para a superação da evasão e retenção na rede federal de educação federal de educação profissional, científica e tecnológica.
- Monard, M. C. and Baranauskas, J. A. (2003). Conceitos sobre aprendizado de máquina. *Sistemas inteligentes-Fundamentos e aplicações*, 1(1):32.
- Neto, M. V. G., Vasconcelos, G. C., and Zanchettin, C. (2021). Mineração de dados aplicada à predição do desempenho de escolas e técnicas de interpretabilidade dos modelos. In *Anais do XXXII Simpósio Brasileiro de Informática na Educação*, pages 773–782. SBC.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., et al. (2011). Scikit-learn: Machine learning in python. *the Journal of machine Learning research*, 12:2825–2830.
- Ruback, L., Carvalho, D., and Avila, S. (2022). Mitigando vieses no aprendizado de máquina: Uma análise sociotécnica mitigating bias in machine learning: A socio-technical analysis.
- Silva, L. G. d. L. (2024). O impacto da nova matriz curricular da licenciatura em computação no desempenho dos discentes. B.S. thesis, Brasil.
- Van Hulse, J., Khoshgoftaar, T. M., and Napolitano, A. (2007). Experimental perspectives on learning from imbalanced data. In *Proceedings of the 24th international conference on Machine learning*, pages 935–942.
- Wirth, R. and Hipp, J. (2000). Crisp-dm: Towards a standard process model for data mining. In *Proceedings of the 4th international conference on the practical applications of knowledge discovery and data mining*, volume 1, pages 29–39. Manchester.
- Zapparolli, L., Stiubiener, I., Braga, J., and Pimentel, E. (2017). Aplicando técnicas de business intelligence e learning analytics em ambientes virtuais de aprendizagem. *Simpósio Brasileiro de Informática na Educação*, 28(1):536–545.