



Previsão da Evasão Escolar através da Análise de Dados e Aprendizagem de Máquina: Um estudo de caso

Dyego Barbosa¹, Luciano Cabral^{1,5}, Filipe Dwan^{2,5} Elyda Freitas^{4,5} e Rafael Ferreira Mello^{3,5}

¹ Campus Jaboatão dos Guararapes - Instituto Federal de Pernambuco (IFPE)
CEP: 54080-000 - Jaboatão dos Guararapes - PE - Brasil

² Campus Boa Vista - Universidade Federal de Roraima (UFRR)
CEP: 69310-000 - Boa Vista - RR - Brasil

³ Campus Recife - Universidade Federal Rural de Pernambuco (UFRPE)
CEP: 55.292-901 - Recife - PE - Brasil

⁴ Campus Caruaru - Universidade de Pernambuco (UPE)
CEP: 55014-908 - Caruaru- PE - Brasil

⁵ Centro de Estudos Avançados do Recife (CESAR)
CEP: 50030-390 - Recife - PE - Brasil

{dhbb@discente, luciano.cabral@jaboatao}.ifpe.edu.br,
filipedwan@gmail.com, elyda.freitas@upe.br, rafaelfilmello@gmail.com

Abstract. *School dropout is a global issue, and the use of automated methods to predict and monitor at-risk students can be effective. This study examines the prediction of dropout rates among students from Federal Institute of Pernambuco - Campus Jaboatão dos Guararapes using machine learning algorithms and academic data. The XG Boost algorithm demonstrated superior performance, outperforming other algorithms and achieving higher metrics in the conducted experiments.*

Keywords: *School dropout. Intelligent analysis. Machine learning.*

Resumo. *A evasão escolar é um problema global, e o uso de métodos automatizados para prever e acompanhar alunos em risco pode ser eficaz. Este estudo analisa a previsão da evasão de alunos do Instituto Federal de Pernambuco - Campus Jaboatão dos Guararapes por meio de algoritmos de aprendizado de máquina, utilizando dados acadêmicos. O XG Boost apresentou melhor desempenho, superando outros algoritmos e alcançando métricas superiores nos experimentos.*

Palavras-chave: *Evasão escolar. Análise inteligente. Aprendizado de máquina.*

1. Introdução

A evasão escolar é um problema que afeta o cenário educacional no Brasil e no mundo, na educação profissional e tecnológica não é diferente. Segundo o Ministério da Educação (BRASIL, 2019), a média nacional do índice de evasão da Rede Federal de Educação Profissional, Científica e Tecnológica (RFEPCT) em 2018 era de 17,2%. Em

consulta à Plataforma Nilo Peçanha, observa-se 19,11% ano base 2022.

No Instituto Federal de Pernambuco (IFPE), um dos integrantes da RFEPCT, a evasão escolar também se apresenta como um desafio a ser enfrentado. Por exemplo, um estudo de caso realizado no Campus Vitória de Santo Antão revelou que o curso de Agroindústria apresentou uma evasão de 43,41% entre 2013 e 2017 (COSTA, 2018).

Diante desse contexto, o presente artigo tem como objetivo realizar uma análise dos dados à luz do cenário de evasão de alunos do IFPE bem como criar e treinar diversos modelos de Aprendizagem de Máquina para prever tal evasão. O objetivo final é auxiliar professores e gestores na tomada de decisões e na elaboração de políticas públicas para reduzir a evasão escolar.

2. Trabalhos Relacionados

A Descoberta de Conhecimento em Banco Dados (do inglês *Knowledge Discovery in Databases*, KDD) é utilizada em processos predição, pois extrai informação em grandes conjuntos de dados identificando padrões explicáveis (Fayyad *et al.*, 1996).

Para Baker *et al.* (2011), o processo de KDD extrai conhecimento implícito a partir de conjuntos de dados volumosos ensejando a tomadas de decisões. No trabalho de Brito, Mello e Alves (2020), Técnicas de mineração de dados com auxílio de algoritmos podem auxiliar na identificação do possível aluno em evasão. Eles identificaram a relevância de características pessoais estudantis em associação com características demográficas no processo de evasão de uma universidade pública federal, usando *Random Forest*, entre os três experimentos e as análises entre as áreas de conhecimento realizados, chegando na melhor acurácia para Engenharias com 78.98%. Oliveira *et al.* (2022) também utilizou o mesmo modelo.

Já Colpo, Primo e Aguiar (2021) avaliaram diferentes formas de representar o comportamento de evasão no desenvolvimento de modelos destinados a prever tal risco com foco no nível de graduação. Efetuou-se tratamento dos dados e avaliaram diferentes modelos. Para eles analisar o comportamento dos alunos em todos os semestres, de forma acumulada e progressiva, beneficia a aprendizagem dos modelos, analisaram *Decision Tree* e *Random Forest*, este último provendo melhor acurácia com 80.1%.

Em outro trabalho, Lemos (2021) desenvolveu um comparativo de modelos de previsão de evasão escolar em um instituto federal utilizando algoritmos de aprendizado supervisionado. Ele utilizou dados históricos de estudantes de ensino técnico apenas, como informações sociodemográficas, notas do vestibular e respostas de questionários para treinar o modelo. Dentre os modelos do estudo, o que alcançou melhor acurácia (62,7%) foi o *RandomForest*. Já a proposta de Souza & Braga (2021) baseia-se em uma abordagem de aprendizado de máquina em conjunto de dados de alunos de cursos técnicos integrados, o que inclui as notas das disciplinas, auxiliando na melhoria do resultado, tendo o melhor modelo (LibSVM) atingido 94,5% de acurácia.

Silva (2019) utilizou um dataset com maior quantitativo de características e instâncias, fez uma análise exploratória, trabalhou com modelo *Decision Tree* por curso (TI e Redes) cujos resultados atingiram 76% e 70% de acurácia respectivamente, com dados do ensino técnico e superior, ele identificou características comuns entre os

estudantes evasores e sugeriu intervenções específicas para cada grupo.

Os estudos revisados demonstram que a aplicação de técnicas de Aprendizagem de Máquina (*Decision Tree* e *Random Forest* na maioria) é promissora para a análise e previsão da evasão escolar em institutos federais, permitindo identificar padrões e variáveis relevantes para o problema, facilitando a implementação de medidas preventivas e de intervenção direcionadas. As diferenças entre os trabalhos citados para este é o conjunto de dados, menor (cerca de 1400 registros) e sem utilizar dados de notas e faltas, os quais ajudam muito no processo de predição do problema em questão, uso do modelo *XG Boost*, bem como a análise dos múltiplos cursos, turnos e níveis de ensino.

3. Metodologia

A metodologia adotada neste estudo consiste em: (a) coletar os dados sócio demográficos e sua respectiva situação a cada período dos alunos provenientes do sistema acadêmico; (b) aplicar técnicas de pré-processamento e análise exploratória dos dados; (c) selecionar os algoritmos de aprendizagem de máquina mais adequados para o problema; (d) treinar e avaliar os modelos utilizando as métricas Acurácia, F1, Recall, Kappa e Precisão por serem medidas clássicas usadas em trabalhos similares; (e) comparar desempenho dos modelos e identificar fatores relevantes para prever a evasão.

Utilizou-se a base de dados do sistema de informações estudantis institucional. Foi efetuada a seleção de características, tratamento inicial dos dados, remoção de valores nulos, colunas duplicadas, dados pessoais, tratamento de atributos categóricos. As instâncias foram classificadas em dois grupos, estudantes regulares (0) e evadidos(1).

A partir dessas informações, foram desenvolvidos modelos de IA utilizando os algoritmos *Decision Tree Classifier*, *Random Forest* e *XGBoost*, com o objetivo de prever a probabilidade de evasão dos discentes. A escolha dos modelos foi baseada em critérios de desempenho, interpretabilidade e capacidade de lidar com diferentes tipos de dados.

3.1 Análise da base de dados

A base de dados foi fornecida pelo sistema Q-Acadêmico¹, que é o sistema de gestão e controle acadêmico oficial do Instituto Federal de Pernambuco (IFPE). A base de dados contém informações sobre os alunos matriculados nos cursos do *campus* em questão nos últimos cinco anos, abrangendo mais de 100 atributos diferentes.

Após uma análise dos campos disponíveis na base de dados, foram selecionadas 14 colunas relevantes para as análises e treinamento dos modelos, tratamento supracitado na seção anterior, e as colunas selecionadas foram nomeadas, conforme Tabela 1.

Tabela 1. Nomenclatura das colunas selecionadas.

Coluna	Descrição
Coeficiente_Rendimento	coeficiente de rendimento
Desc_Tipo_Escola_Origem	tipo de escola de origem
Percentual_Frequencia	percentual de frequência
Nivel_Ensino	nível de ensino

¹ Dataset não foi disponibilizado devido questões LGPD.

Coluna	Descrição
Desc_Cor	cor ou raça declarada
Desc_Modalidade_Curso	modalidade do curso (concomitante, subsequente ou outros)
Desc_Cota	tipo de cota que o aluno se beneficiou para ingressar
Desc_Estado_Civil	situação conjugal
Sexo	sexo biológico declarado
Desc_Renda_Per_Capita	renda familiar bruta per capita declarada
Desc_Naturalidade	naturalidade declarada
Desc_Turno	turno de matrícula do curso
Desc_Sit_Matricula	situação acadêmica (matriculado, concluído, evadido ou outras);

Fonte: Autoria própria.

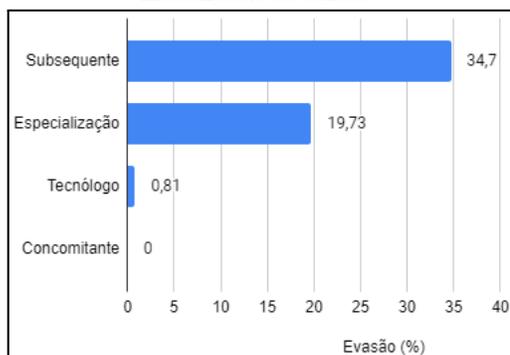
3.2 Análise exploratória dos dados de evasão

Nesta seção, é realizada uma análise exploratória dos dados de evasão com base em diferentes variáveis, como sexo, estado civil, cor, tipo de curso, curso, turno e tipo de cota. Por meio de gráficos, é possível visualizar o percentual de evasão em cada grupo, com objetivo de identificar quais fatores podem estar associados à evasão escolar.

3.2.1 Análise por modalidade e turno dos cursos

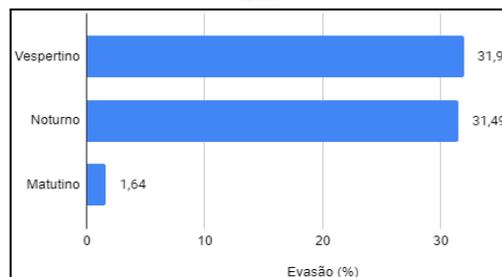
A Figura 1 exibe o percentual de evasão em cada modalidade de curso. Por outro lado, a Figura 2 apresenta o percentual de evasão em cada turno dos cursos oferecidos.

Figura 1. Percentual de evasão por modalidade de curso.



Fonte: Autoria própria.

Figura 2. Percentual de evasão por turno.



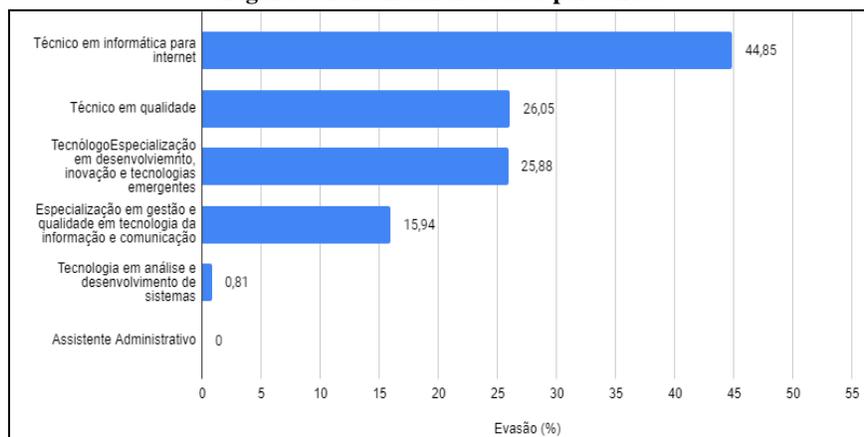
Fonte: Autoria própria.

Alguns tipos de cursos apresentam uma taxa de evasão mais alta, devido a idade do curso (ser mais antigo na instituição), cursos mais novos como Superior (Tecnólogo) e o Médio Técnico (concomitante) apresentam taxa menor ou zero (contêm alunos ainda no 1º ano). Da mesma forma, a Figura 2 indica que certos turnos têm uma taxa de evasão maior, o que pode ser atribuído a interferências na rotina pessoal ou profissional, como os turnos vespertino ou noturno. Aprofundar essas questões em estudos futuros ajudaria a compreender melhor as razões por trás da evasão escolar em diferentes turnos.

3.2.2 Análise por curso

A Figura 3 exibe o percentual de evasão em cada curso oferecido.

Figura 3. Percentual de evasão por curso.



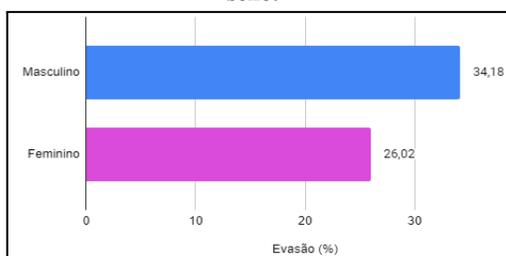
Fonte: Autoria própria.

A Figura 3 revela que alguns cursos têm uma taxa de evasão mais alta do que outros. Isso sugere que os alunos matriculados em cursos com maior carga horária, exigência acadêmica mais elevada ou menor afinidade com o perfil profissional podem enfrentar mais dificuldades ou desinteresse em continuar o curso, como é o caso dos cursos de Agroindústria ou Química. Investigar esses fatores em estudos futuros ajudaria a compreender melhor as causas da evasão escolar entre os alunos em diferentes cursos.

3.2.3 *Análise por sexo e estado civil*

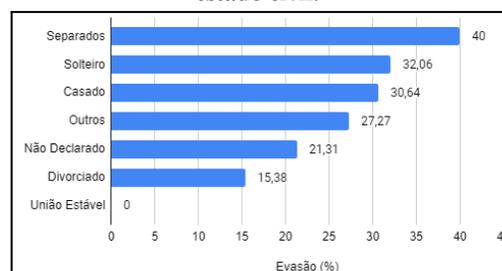
A Figura 4 apresenta a percentual de evasão por sexo nos cursos destacados. Por outro lado, a Figura 5 exibe o mesmo percentual por estado civil.

Figura 4. Percentual de evasão por sexo.



Fonte: Autoria própria.

Figura 5. Percentual de evasão por estado civil.



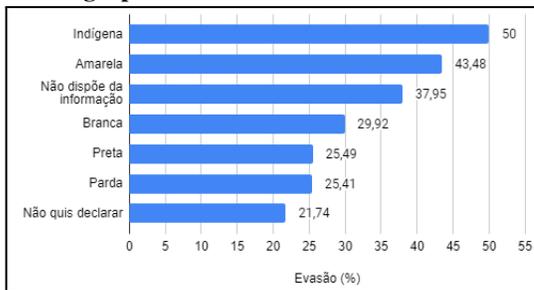
Fonte: Autoria própria.

Na Figura 4, pode-se observar que os alunos do sexo masculino apresentam uma taxa de evasão maior do que os do sexo feminino, sendo 34,18% contra 26,02%, respectivamente. No caso do estado civil (Fig. 5), o destaque está no estado civil separado, isso pode indicar que estudantes que passaram por uma ruptura afetiva recente podem ser afetados, até mesmo em relação aqueles que já oficializaram o divórcio.

3.2.4 *Análise por grupo étnico e sistema de reserva de vagas (cotas)*

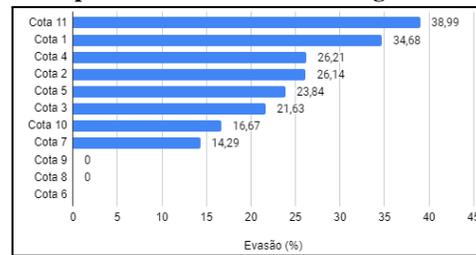
A Figura 6 ilustra o percentual de evasão de cada grupo étnico nos cursos. Por sua vez, a Figura 7 apresenta o percentual de evasão de cada tipo de cota nos cursos. A descrição de cada tipo de cota pode ser encontrada na Figura 8.

Figura 6. Percentual de evasão por grupo étnico nos cursos oferecidos.



Fonte: Autoria própria.

Figura 7. Percentual de evasão por sistema de reserva de vagas.



Fonte: Autoria própria.

A Figura 6 revela que algumas raças apresentam uma taxa de evasão mais alta do que outras. Isso pode indicar que os alunos pertencentes a grupos étnicos minoritários ou historicamente discriminados enfrentam mais obstáculos e desafios para permanecer na escola, como racismo, falta de representatividade, baixa autoestima ou exclusão social. Estudos futuros podem investigar esses fatores para compreender melhor as causas da evasão escolar entre os alunos com diferentes cores ou raças.

Figura 8. Descrição das cotas no sistema de reserva de vagas (cotas).

Cota	Descrição da cota
Cota 1	Não possui
Cota 2	Aluno de Escola Pública com renda \leq 1,5 SM por pessoa
Cota 3	Aluno de Escola Pública com renda \leq 1,5 SM por pessoa, autodeclarado preto, pardo ou indígena
Cota 4	Aluno de Escola Pública com renda $>$ 1,5 SM por pessoa
Cota 5	Aluno de Escola Pública com renda $>$ 1,5 SM por pessoa, autodeclarado preto, pardo ou indígena
Cota 6	Aluno de Escola Pública, com deficiência e com renda \leq 1,5 SM por pessoa
Cota 7	Aluno de Escola Pública, com deficiência e com renda \leq 1,5 SM por pessoa, autodeclarado preto, pardo ou indígena
Cota 8	Aluno de Escola Pública, com deficiência e com renda $>$ 1,5 SM por pessoa
Cota 9	Alunos de Escola Pública, sem comprovação renda
Cota 10	Alunos de Escola Pública, sem comprovação renda, autodeclarado preto, pardo ou indígena
Cota 11	Ampla Concorrência

Fonte: Autoria própria.

A Figura 7 mostra que os alunos que ingressaram por meio de ampla concorrência têm uma taxa de evasão maior em comparação aos que entraram por meio das cotas. Isso sugere que os alunos que não se beneficiaram de sistemas de reserva de vagas enfrentam mais dificuldades ou falta de interesse em permanecer no curso, como falta de motivação, identificação ou senso de pertencimento, necessidade de trabalhar, baixa autoestima ou falta de apoio institucional para alunos sem cotas. Investigar esses fatores em estudos futuros pode ajudar a compreender melhor as causas da evasão escolar entre alunos com diferentes tipos de cota vide Fig. 8.

3.3. Preparação dos dados para o treinamento dos modelos

Nesta seção, descrevem-se os passos realizados para preparar os dados de evasão dos alunos para serem usados nos modelos de inteligência artificial. Primeiramente, efetuou-se a categorização de colunas com valores string por valores em inteiros, i.e., utilizou-se regras simples para atribuir valores inteiros aos valores em string, seguindo uma ordem lógica ou alfabética. As colunas que foram transformadas dessa forma foram: Sexo, Estado civil, Cor, Tipo de curso, Curso, Turno e Tipo de cota. Por exemplo, na coluna sexo, “masculino” foi substituído por 1, “feminino” por 0.

Em seguida, removeu-se as colunas de situação da matrícula, pois elas se tornaram o nosso target (variável dependente). Nesse caso, 0 significa situação regular e 1 significa evadido. Depois, separa-se o X de Y, sendo X as variáveis independentes (todas as colunas restantes) e Y o target. Por fim, definem-se os conjuntos de treino e teste em uma proporção de 0.3, ou seja, 70% dos dados foram usados para treinar os modelos e 30% para testar o seu desempenho.

4. Treinamento e avaliação dos modelos de aprendizagem de máquina

Nesta seção, são apresentados os resultados do treinamento e avaliação de três modelos de inteligência artificial selecionados: *XGBoost*, *RandomForest* e *DecisionTreeClassifier*. Para cada modelo, são utilizadas as métricas oriundas do classification report + Cohen Kappa devido a serem as métricas mais utilizadas no meio.

4.1. XGBoost

O *XGBoost* é um algoritmo baseado em árvores de decisão que utiliza o método de boosting para combinar vários modelos fracos em um modelo forte. O *boosting* é uma técnica que consiste em treinar modelos sequencialmente, dando mais peso aos exemplos que foram classificados incorretamente pelo modelo anterior (CHEN & GUESTRIN, 2016).

Tabela 2. Resultados do processamento do XGBoost.

Precision	Recall	F-measure (F1)	Accuracy	Cohen-kappa
0.72	0.82	0.82	0.82	0.57

Fonte: Autoria própria.

4.2. RandomForest

O *RandomForest* é um algoritmo baseado em árvores de decisão que utiliza o método de *bagging* para combinar vários modelos fracos em um modelo forte. O *bagging* é uma técnica que consiste em treinar modelos paralelamente, usando amostras aleatórias dos dados com reposição e combinando as suas predições por meio de votação ou média (BREIMAN, 2001).

Tabela 4. Resultados do processamento do Random Forest.

Precision	Recall	F-measure (F1)	Accuracy	Cohen-kappa
0.83	0.83	0.83	0.83	0.61

Fonte: Autoria própria.

4.3. DecisionTreeClassifier

O *DecisionTreeClassifier* é um algoritmo baseado em árvores de decisão que utiliza o método de divisão e conquista para classificar os exemplos. O algoritmo cria uma árvore que representa as regras de decisão baseadas nos atributos dos dados.

Tabela 5. Resultados do processamento do DecisionTreeClassifier.

Precision	Recall	F-measure (F1)	Accuracy	Cohen-kappa
0.65	0.80	0.80	0.80	0.53

Fonte: Autoria própria.

5. Discussão

Os resultados obtidos a partir das métricas pós *tuning* como acurácia em 85%, precisão 86%, Kappa quase 0.10 superior aos concorrentes, indicam o *XGBoost* o algoritmo que obteve melhor performance neste pipeline de experimentos e com o dataset utilizado. Para uma análise comparativa, tem-se a tabela consolidada a seguir:

Tabela 7. Comparativo consolidado entre os modelos experimentados.

Modelo	Precision	Recall	F1	Accuracy	Kappa
<i>XG Boost</i>	0.72	0.82	0.82	0.82	0.57
<i>RandomForest</i>	0.83	0.83	0.83	0.83	0.61
<i>Decision Tree</i>	0.65	0.80	0.80	0.80	0.53

Fonte: Autoria própria.

A escolha de um número ímpar de métricas foi para caso houvesse muita similaridade entre os resultados, poder-se-ia estabelecer um desempate de forma justa e objetiva. Diante dos resultados apresentados acima, é possível concluir que o *Random Forest* foi capaz de prever a evasão de alunos um pouco melhor que os concorrentes, em todas as métricas utilizadas. Os resultados ainda indicam que o *Random Forest*, sem *tuning*, consegue ser melhor que o *XG Boost* e *Decision Tree*, algo relativamente previsto, visto a robustez de um modelo ensemble frente a um clássico.

6. Considerações Finais, Limitações e Trabalhos Futuros

Neste trabalho, apresentou-se uma aplicação de inteligência artificial para prever a evasão escolar de alunos de cursos técnicos e superiores de um Instituto Federal. Utiliza-se técnicas de aprendizado de máquina para treinar e avaliar três modelos: *XGBoost*, *RandomForest* e *DecisionTreeClassifier*. Os modelos foram alimentados com 1.429 registros extraídos do Q-Acadêmico, variáveis sociodemográficas e acadêmicas.

O melhor modelo diante dos resultados foi o *Random Forest*, vencedor em todas as métricas sem usar *fine-tuning*. Esses resultados indicam que os modelos foram capazes de prever a evasão dos alunos com uma boa acurácia e precisão, além de terem um bom equilíbrio entre *recall* e *F1-score*, apoiando ações contra a evasão escolar.

Em termos de limitações, uma base restrita dificulta o processo de treinamento. A falta de tempo para realizar o *grid search* também foi uma limitação. Para trabalhos futuros, explorar-se-ão outras técnicas de aprendizado de máquina, i.e. redes neurais artificiais e *deep learning*, ampliar o conjunto de dados com características e instancias, e aplicar os modelos em outras instituições para verificar a sua generalização e validade.

Este trabalho contribui para o avanço do conhecimento na área de inteligência artificial aplicada à educação, auxiliando gestores educacionais e professores na elaboração de políticas e estratégias para reduzir a evasão escolar e melhorar a qualidade do ensino. No entanto, é importante ressaltar que o uso exclusivo de técnicas de *Machine Learning* não é suficiente para resolver o problema da evasão escolar em institutos federais. Essas técnicas podem fornecer insights valiosos e previsões precisas, mas a implementação de medidas efetivas requer uma abordagem abrangente, que envolva também fatores socioeconômicos, psicológicos e pedagógicos.

Agradecimentos

Gratidão a: Ustore, IFPE, UFRR, UPE, UFRPE, e CESAR pelo incentivo à pesquisa.

Referências

- Baker, R.; Isotani, S.; Carvalho, A. Mineração de dados educacionais: Oportunidades para o Brasil. *Revista Brasileira de Informática na Educação*, v.19, n.02, p.03, 2011.
- Brasil. (2019). O Ministério da Educação divulga dados da educação profissional. *Ministério da Educação*. Disponível: <https://encurtador.com.br/gjCIS> Acesso em: 17 junho 2023.
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32.
- Brito, B., Mello, R., & Alves, G. (2020). Identificação de Atributos Relevantes na Evasão no Ensino Superior Público Brasileiro. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação*, (pp. 1032-1041). Porto Alegre: SBC. doi:10.5753/cbie.sbie.2020.1032
- Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *arXiv preprint arXiv:1603.02754*. Disponível: <https://arxiv.org/abs/1603.02754> Acesso em: 17 junho 2023.
- Colpo, M., Primo, T., & Aguiar, M. (2021). Predição da evasão estudantil: uma análise comparativa de diferentes representações de treino na aprendizagem de modelos genéricos. In *Anais do XXXII Simpósio Brasileiro de Informática na Educação*, (pp. 873-884). Porto Alegre: SBC. doi:10.5753/sbie.2021.218517
- Costa, E. F. da. (2018). “Descortinando a evasão escolar: o caso do Instituto Federal de Pernambuco - Campus Vitória de Santo Antão”. 91 f. Dissertação (Mestrado em Políticas Públicas) - Universidade Federal de Pernambuco, Recife, 2018. Disponível: <https://repositorio.ufpe.br/handle/123456789/32323> Acesso em: 10 maio 2023.
- Fayyad, Usama; Piatetsky-Shapiro, Gregorye Smyth, Padhraic. From data mining toknowledgediscovery in databases. *AI magazine* 17, no. 3, 37-54. 1996.
- Lemos, Í. V. do R. (2021). Prevendo a evasão escolar em uma instituição de ensino técnico utilizando mineração de dados educacionais. 43 f. *Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação)* – Departamento de Computação, Universidade Federal Rural de Pernambuco, Recife, 2021.
- Oliveira, I., Medeiros, F., & Andrade, F. (2022). Seleção de Atributos para Classificadores de Evasão Escolar com Dados da Plataforma Nilo Peçanha. In *Anais do I Workshop de Aplicações Práticas de Learning Analytics em Instituições de Ensino no Brasil*, (pp. 30-39). Porto Alegre: SBC. doi:10.5753/wapla.2022.226769
- Silva, E. M. C. (2019). Um modelo descritivo para auxiliar no acompanhamento da evasão escolar nos cursos técnicos e superiores no Instituto Federal do Rio Grande do Norte - Campus do São Gonçalo do Amarante. 165f. *Dissertação (Mestrado Profissional em Inovação em Tecnologias Educacionais)* - Instituto Metrópole Digital, Universidade Federal do Rio Grande do Norte, Natal, 2019.
- Souza, A. L. G. de; Braga, A. H. (2021). Uma análise dos algoritmos de classificação com base na evasão dos estudantes dos cursos técnicos integrados ao Ensino Médio do Campus Ceres do IF Goiano. In: *Simpósio Brasileiro De Informática Na Educação*, 32. Online. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação. p. 1276-1285.