

Aspectos relevantes dos modelos preditivos de inteligência artificial no combate à evasão escolar em cursos de graduação: uma revisão sistemática

Aline F. Alves, Clarice B. Venâncio Inácio, Eliane Pozzebon, Juarez Bento da Silva

Programa de Pós-Graduação Tecnologia da Informação e Comunicação
Universidade Federal de Santa Catarina - UFSC
Araranguá – Brasil

{aline.alves@ifsc.edu.br, clavenancio@gmail.com, eliane.pozzebon@ufsc.br, juarez.silva@ufsc.br}

Abstract. *The study addresses the relevant aspects of the application of Artificial Intelligence (AI) in combating school dropout in higher education, a challenging, constant and persistent phenomenon. The research investigates the application of Artificial Intelligence as a tool in preventing school dropout in higher education courses with the aim of elucidating the relevant aspects, effectiveness and contribution of AI to reducing school dropout. The methodology adopted is a systematic review of the literature, including the collection and analysis of relevant studies on the use of AI as a predictive model in school dropout.*

Keywords: *School Dropout; Artificial intelligence; Prevention.*

Resumo. O estudo aborda os aspectos relevantes da aplicação da Inteligência Artificial (IA) no combate à evasão escolar no ensino superior, um fenômeno desafiador, constante e persistente. A pesquisa investiga a aplicação da Inteligência Artificial como ferramenta na prevenção à evasão escolar nos cursos superiores com o objetivo de elucidar os aspectos relevantes, eficácia e contribuição da IA para a redução da evasão escolar. A metodologia adotada é a revisão sistemática da literatura, incluindo a coleta e análise de estudos relevantes acerca do uso da IA como modelo preditivo na evasão escolar.

Palavras chaves: Evasão Escolar; Inteligência artificial; Prevenção.

1.Introdução

A evasão escolar ou abandono dos estudos acarreta consequências nos âmbitos sociais, econômicos e acadêmicos, sendo um fenômeno que traz um desafio constante e persistente e, que compromete a qualidade e a igualdade de acesso à educação.

Em busca do equilíbrio deste problema, faz-se necessário oportunidades de acesso iguais para que todos os acadêmicos permaneçam e concluam sua formação superior. (BITENCOURT; SILVA; XAVIER, 2021).

A evasão escolar ocorre em todos os níveis de ensino, desde o fundamental até o superior, e sofre influência de fatores diretos como: pobreza, falta de acesso a serviços básicos, violência urbana, trabalho infantil, gravidez precoce, falta de qualidade no ensino, desinteresse dos alunos entre tantos outros problemas. (SIHARE,2024).

Em 2023, o panorama da educação superior brasileiro revelou dados alarmantes: 70,6% dos jovens negros e pardos abandonaram o ensino superior sem completá-lo. A taxa de escolarização de pessoas entre 18 e 24 anos foi de apenas 30,5%, com 21,6% frequentando cursos de nível superior. Apenas 4,3% haviam obtido um diploma universitário, enquanto 65,2% não estavam matriculados em nenhum curso e não concluíram o ensino superior. (IBGE, 2023).

Entre os jovens negros e pardos da mesma faixa etária, apenas 16,4% estavam matriculados em cursos de graduação superior. Em contraste, 6,5% dos jovens brancos já haviam concluído uma graduação. Enquanto 57,0% dos jovens brancos abandonaram os estudos sem concluir o ensino superior, essa taxa subiu para 70,6% entre os jovens negros e pardos. (IBGE, 2023). Ainda, do total de jovens brancos dessa faixa etária, 36,5% estavam matriculados em alguma instituição educacional, e 29,5% estavam cursando o ensino superior. (IBGE, 2023). Além disso, verificou-se que 16,4% dos jovens negros ou pardos estavam matriculados em cursos de graduação superior, em contraste com os 6,5% dos jovens brancos que já haviam obtido um diploma universitário. Isso representa mais que o dobro da proporção de graduados entre os jovens negros e pardos, que foi de somente 2,9%. (IBGE, 2023).

A realidade do ensino superior no Brasil contraria diretamente a necessidade de garantir o acesso aos maiores níveis de educação e qualificação, pois somente através desse acesso irrestrito é possível impulsionar o desenvolvimento humano, social e econômico do país. (SILVA; SANTOS, 2017). Desta forma, esta pesquisa investiga a aplicação da inteligência artificial (IA) como ferramenta na prevenção e enfrentamento à evasão escolar nos cursos superiores e pretende elucidar os aspectos relevantes e a eficácia da IA neste contexto, analisando suas capacidades e suas limitações, trazendo compreensão sobre de que forma a inteligência artificial pode contribuir para a redução da evasão escolar nos cursos superiores de forma mais eficaz.

Quanto a metodologia, a forma adotada é uma revisão sistemática da literatura, que inclui a coleta e análise de estudos relevantes acerca do uso da inteligência artificial como modelo preditivo na evasão escolar.

A escolha do tema justifica-se pela crescente relevância da inteligência artificial (IA) no contexto educacional. Sendo a sua utilização uma oportunidade de inovação nas práticas pedagógicas, além de uma ferramenta importante para enfrentar desafios complexos, como a evasão escolar no ensino superior. Sendo assim, a inteligência artificial pode contribuir com a prevenção e o enfrentamento da evasão escolar por meio de soluções avançadas e personalizadas, auxiliando na identificação precoce de fatores de risco, permitindo a implementação de estratégias de intervenção.

O problema da pesquisa busca responder: quais os aspectos relevantes dos modelos preditivos de IA no combate à evasão escolar na graduação? O trabalho pretende identificar os benefícios que a aplicação da IA pode oferecer na prevenção e combate à evasão escolar no ensino superior.

2. Fundamentação teórica

2.1 Evasão Escolar no Ensino Superior

“A evasão é definida como a exclusão decretada por fatores e variáveis, tanto internos quanto externos às instituições de educação, e é considerado um fenômeno complexo que aflige as universidades do mundo contemporâneo”. (VELOSO; ALMEIDA, 2000).

Ainda, a evasão é a situação em que um aluno não consegue concluir a sua educação ou se afasta dela de forma temporária ou definitiva. (VILLARREAL, HENRY ET AL, 2024).

A educação é condição fundamental para o desenvolvimento e bem-estar de uma sociedade e, os estudantes são a razão de ser de qualquer instituição de ensino e o desenvolvimento social e econômico de um país está diretamente relacionado com o desempenho acadêmico de seus estudantes. (VILLARREAL, HENRY ET AL (2024). Nessa perspectiva:

Para as instituições públicas, os recursos possivelmente não atingirão as metas sociais e econômicas as quais foram destinadas, e nas instituições privadas as desistências geram perda de receita. Em ambos os casos, as vagas desocupadas acarretam na ociosidade de funcionários, professores e equipamentos. (RODRIGUES; MORAES; E SANTOS, 2021, n.p).

Desta forma, é urgente um planejamento educacional flexível e renovado, que aproveite todas as novas técnicas para um planejamento mais rigoroso e eficaz a fim de evitar a evasão escolar. (SKITTOU; MERROUCHI; GADI, 2023).

2.2 Inteligência Artificial

De acordo com o dicionário *Michaelis*, a palavra inteligência e artificial tem origem no latim; *intelligentia* significa a faculdade de entender, pensar, raciocinar e interpretar e a palavra *artificialis*, produzido por arte ou indústria do homem e não por causas naturais. Assim, a “inteligência artificial é um produto produzido pelo homem com a intenção de criar e capacitar máquinas a pensarem de maneira similar ao ser humano”. (MATIAS CAETANO, 2019).

A inteligência artificial (IA) busca induzir computadores a pensar e comportar-se de forma inteligente e, seu uso está em áreas diversas do conhecimento evoluindo em várias linhas de pesquisa como: sistemas baseados em conhecimento, robótica, redes neurais, aprendizado de máquina, planejamento, processamento e interpretação de linguagem natural, reconhecimento de padrões e pretende “fornecer ao computador as habilidades para efetuar funções antes desempenhadas apenas através inteligência humana”. (MONARD; BARANAUSKAS, 2000).

Ao ensinarmos (programarmos) um único computador para resolver um determinado problema, todos os demais computadores podem “aprender” como resolver o mesmo problema bastando apenas copiar o programa para cada um deles [...] entretanto ainda é necessário um ser humano que seja capaz de produzir um programa (ensinar) para os computadores. (MONARD; BARANAUSKAS, 2000, n.p).

A definição de inteligência artificial pode mudar, mas a condição fundamental para determinar a inteligência de um sistema é a capacidade de aprendizado.

2.3 A Inteligência Artificial como Ferramenta de Prevenção à Evasão

A inteligência artificial (IA) vem sendo reconhecida por seu potencial transformador na luta contra a evasão escolar no ensino superior, pois tem como característica processar e analisar grandes quantidades de dados e reconhecer padrões, sendo fundamental para o desenvolvimento de estratégias preditivas à evasão.

No Brasil, a evasão universitária é um problema persistente, que ultrapassa a questão educacional e atinge os segmentos econômico e social, necessitando de soluções eficientes para o seu enfrentamento. A utilização da IA no combate à evasão escolar representa uma abordagem capaz de analisar, por exemplo, o desempenho acadêmico e engajamento estudantil, permitindo a detecção antecipada de estudantes em situação de risco, possibilitando a personalização da educação tornando a aprendizagem mais eficaz. (OLIVEIRA JÚNIOR, 2022).

3. Metodologia

Este trabalho é uma revisão sistemática da literatura e busca identificar, avaliar e interpretar as pesquisas disponíveis relevantes para uma questão de pesquisa específica. Sendo a revisão sistemática uma forma de estudo secundário e os estudos individuais que contribuem para uma revisão sistemática são estudos primários. (KITCHENHAM, 2004).

Esta revisão tem o objetivo de analisar artigos científicos de estudos primários que utilizaram métodos de inteligência artificial como intervenção para prevenir a evasão escolar de estudantes universitários. A escolha dos estudos foi estabelecida com o uso do protocolo de inclusão e exclusão de artigos, como podemos ver na tabela 1.

Tabela1- Protocolo.

	INCLUSÃO	EXCLUSÃO
ESCOPO	O estudo investigou o uso de modelos preditivos de IA para prevenção e enfrentamento à evasão escolar. O estudo foi realizado sobre evasão na graduação formato presencial.	Estudos que não utilizaram IA. Estudos realizados com públicos que não eram da graduação. Estudos realizados com alunos de cursos EAD (Ensino à Distância).
IDIOMAS	Português / inglês	Outros idiomas não dominados pelas autoras.
ARTIGOS	Artigos revisados por pares. Artigos publicados entre 2019 à 2024	Teses e artigos de conferência. Artigos publicados com data anterior à 2019.

Fonte: autores (2024).

Os artigos foram selecionados utilizando os critérios do protocolo, onde primeiramente foram lidos os títulos e resumos, excluindo ou incluindo conforme o estabelecido. Após a filtragem os artigos foram lidos por completo e submetidos a análise.

Figura 1 – Filtragem dos Artigos

FILTRO 1 <ul style="list-style-type: none">• Base de dados Artigos encontrados a partir de “string” em base de dados.
FILTRO 2 <ul style="list-style-type: none">• Leitura parcial Aplicação do protocolo de pesquisa e leitura do título e resumo dos artigos selecionados.
FILTRO 3 <ul style="list-style-type: none">• Leitura completa Leitura completa dos artigos selecionados no filtro 2.

Fonte: autoras (2024)

4. Resultados e Discussão

Após algumas tentativas de pesquisa foi definido a *string* de busca na língua inglesa e portuguesa. Mas a maioria dos estudos foram encontrados na língua inglesa. A *string* de busca definida foram: inglês: “*student dropout*” AND “*artificial intelligence*”. Português: “evasão escolar” AND “inteligência artificial”.

As bases de dados foram acessadas via portal Periódicos Capes, pela função CAFE disponibilizada pela Universidade Federal de Santa Catarina – UFSC. As bases selecionadas foram *Scopus*, *IEEE*, além de buscas diretas no portal Capes. A opção foi por artigos de livre acesso, revisados por pares, nos idiomas inglês e português, publicados entre 2019 e 2024. Na primeira busca foram encontrados 91 artigos, a partir desses foram selecionados 25 artigos, excluindo-se os duplicados e seguindo os critérios do protocolo de pesquisa, o resultado foram 09 artigos em inglês e 1 em português para leitura completa.

Figura 2 – Resultado da filtragem de artigos

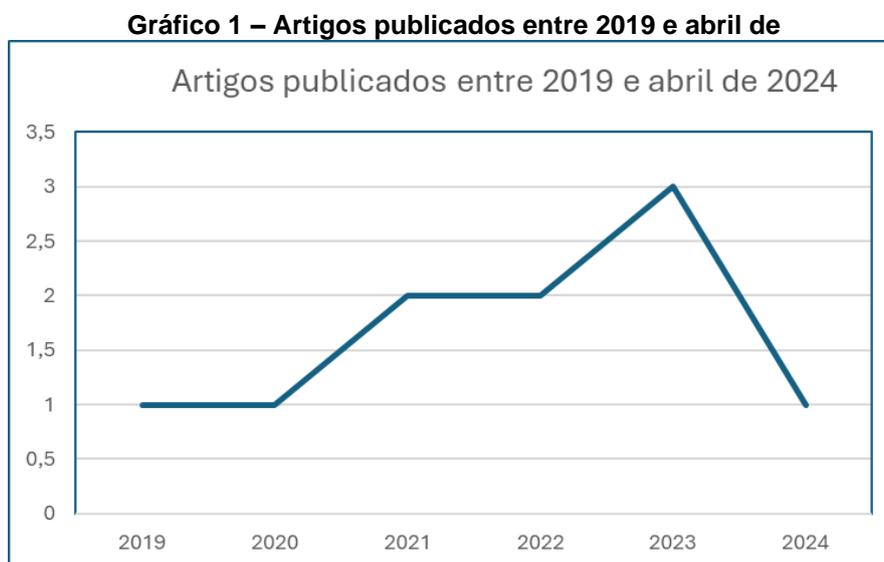
FILTRO 1	FILTRO 2	FILTRO 3
91	25	10
<ul style="list-style-type: none">• Base de Dados• Periódico Capes, scopus, IEE• String: “student dropout” AND “artificial intelligence” “evasão escolar” AND “inteligência artificial”	<ul style="list-style-type: none">• Leitura parcial• Periódico Capes: 4 artigos• Scopus: 11 artigos• IEE: 10 artigos	<ul style="list-style-type: none">• Leitura completa• Periódico Capes: 1 artigo• Scopus: 5 artigos• IEE: 4 artigos

Fonte: autoras (2024)

4.1 Análise bibliométrica

Foram selecionadas para este estudo as publicações dos anos 2019 a 2024. Podemos perceber pelo gráfico 1, que houve um aumento de publicações nos últimos anos, e o aparente decréscimo em 2024, se deve ao fato da pesquisa ter ocorrido até o início do

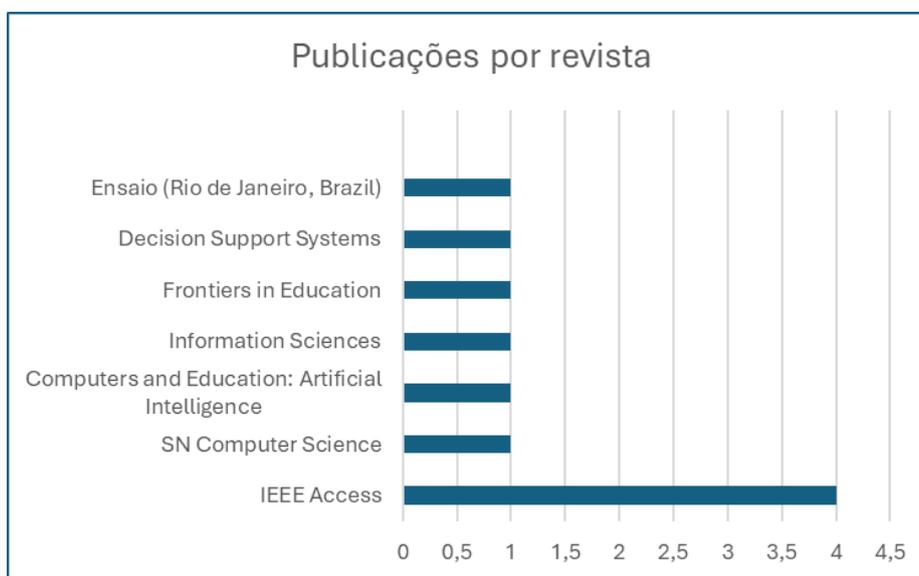
mês de maio deste ano, a tendência é que ocorra um crescimento no número de publicações até dezembro de 2024, com base na linha de crescimento dos últimos anos.



Fonte: autoras (2024)

As publicações são de revistas com área de concentração multi e interdisciplinar, em áreas de tecnologia e educação. No Gráfico 2, é possível observar que o maior número de publicações foi na *IEEE Access*.

Gráfico 2 – Publicações por revista



Fonte: autores (2024)

4.2 Análise de conteúdo

Esta seção reúne os resultados dos 10 artigos primários analisados, e demonstram que há um interesse a nível mundial pelo tema, com estudos em diversos países, sendo quatro deles em países da América Latina. A tabela 2 lista as bases de dados, ano e

autores dos artigos selecionados e a tabela 3 os países, número de artigos e as referências.

Tabela 2 – Artigos selecionados

Base de dados	Ano	Autores
IEEE	2020	Fernández-García et al. (2020)
	2021	Fernández-García et al. (2021)
	2023	Cañete-Sifuentes et al. (2023)
	2023	Uliyan et al. (2023)
Scopus	2019	Costa et al. (2019)
	2022	Niyogisubizo et al. (2022)
	2023	Gonzalez-Nucamendi et al. (2023)
	2023	Phan et al. (2023)
	2024	Sihare, Shyam R. (2024)
Capes	2022	Bitencourt et al. (2022)

Fonte: organizado pelas autoras (2024) com base nos artigos selecionados

Tabela 3 – Relação de artigos por país

País	Quantidade	Referências
Arabia Saudita	1	Uliyan <i>et al.</i> (2023)
Brasil	2	Costa et al. (2019); Bitencourt <i>et al.</i> (2022)
China	1	Niyogisubizo <i>et al.</i> (2022)
Espanha	2	Fernández-García <i>et al.</i> (2020); Fernández-García <i>et al.</i> (2021);
França	1	Phan <i>et al.</i> (2023)
Índia	1	Sihare, Shyam R. (2024)
México	2	Cañete-Sifuentes <i>et al.</i> (2023); Gonzalez-Nucamendi <i>et al.</i> (2023)

Fonte: organizado pelas autoras (2024) com base nos artigos selecionados

Os artigos selecionados são estudos sobre o uso de inteligência artificial e aprendizado de máquina para abordar o problema da evasão escolar, com o objetivo de identificação precoce de alunos em risco de evasão. Para isso utilizam dados educacionais, como registros acadêmicos, desempenho de alunos, padrões de frequência, entre outros, como entrada para seus modelos de IA/ML. Abaixo estão os algoritmos, redes neurais e técnicas citadas nos trabalhos.

Tabela 4 – Algoritmos, redes neurais, técnicas e conceitos de mineração de dados

	Algoritmo	Quantidade	Referência
1	<i>Random Forest (RF)</i>	5	Niyogisubizo, Jovial <i>et al.</i> (2022) (China); Bitencourt, W. A. <i>et al.</i> (2022) (Brasil); Cañete-Sifuentes <i>et al.</i> (2023) (México); Fernández-García <i>et al.</i> (2021) (Espanha); Gonzalez-Nucamendi <i>et al.</i> (2023) (México)

2	Máquina de vetores de suporte (<i>support vector machine- SVM</i>)	5	Bitencourt, W. A. <i>et al</i> (2022) (Brasil); Fernández-García <i>et al.</i> (2020) (Espanha); Fernández-García (2021) (Espanha); Gonzalez-Nucamendi <i>et al.</i> (2023) (México); Sihare, S.R. (2024) (Índia)
3	<i>Extreme Gradient Boosting (XGBoost)</i>	3	Niyogisubizo, Jovial <i>et al.</i> (2022) (China); Cañete-Sifuentes <i>et al.</i> (2023) (espanha); Gonzalez-Nucamendi <i>et al.</i> (2023) (México)
4	<i>K-nearest neighbors (KNN)</i>	3	Fernández-García <i>et al.</i> (2020) (Espanha); Gonzalez-Nucamendi <i>et al.</i> (2023) (México); Sihare, S.R. (2024) (Índia)
5	<i>Gradient Boosting (GB)</i>	2	Niyogisubizo, Jovial <i>et al.</i> (2022) (China); Fernández-García (2021) (Espanha)
6	<i>Logistic regression</i>	2	Fernández-García <i>et al.</i> (2020) (Espanha); Phan, Minh (2023) (França)
7	<i>Decision tree</i>	2	Fernández-García <i>et al.</i> (2020) (Espanha); Gonzalez-Nucamendi <i>et al.</i> (2023) (México)
8	<i>Gradient Boosting Machine (GBM)</i>	1	Bitencourt, W. A. <i>et al</i> 2022 (Brasil);
9	<i>Multilayer perceptron</i>	1	Fernández-García <i>et al.</i> (2020) (Espanha)
10	<i>Gradiente Boosting Classifier</i>	1	Fernández-García <i>et al.</i> (2020) (Espanha)
11	<i>LightGBM</i>	1	Cañete-Sifuentes <i>et al.</i> (2023) (Espanha);
12	<i>ExtremeRandomTrees</i>	1	Cañete-Sifuentes <i>et al.</i> (2023) (Espanha);
13	Ada Boosting	1	Gonzalez-Nucamendi <i>et al.</i> (2023) (México)
14	Naive Bayer	1	Gonzalez-Nucamendi <i>et al.</i> (2023) (México)
	Redes Neurais e modelos específicos	Quantidade	Referência
1	Redes neurais <i>Feedforward Neural Network (FNN)</i>	1	Niyogisubizo, Jovial <i>et al.</i> 2022 (China)
2	BLSTM (abreviação de <i>Bidirectional Long Short-Term Memory</i>)	1	D. Uliyan, A. S. (Arabia Saudita)
3	CRF (abreviação de <i>Conditional Random Field</i>)	1	D. Uliyan, A. S. (Arabia Saudita)

	Técnicas e conceitos de mineração de dados	Quantidade	Referência
1	comitê de máquina (conjunto de algoritmos)	1	Bitencourt, W. A. <i>et al</i> 2022 (Brasil)
2	mineração de DAGs	1	Costa, Jefferson de J. (Brasil)
3	análise estatística	1	Costa, Jefferson de J. (Brasil)
4	Apriori	1	Costa, Jefferson J. (Brasil)
5	Espaço vetorial	1	Phan, Minh (2023) (França)
6	Doc2vec	1	Phan, Minh (2023) (França)
7	<i>Bert</i>	1	Phan, Minh (2023) (França)
8	<i>K-mens</i>	1	Phan, Minh (2023) (França)
9	Algoritmos de agrupamento hierárquico	1	Phan, Minh (2023) (França)
10	LRA (<i>Linear Regression Analysis</i>)	1	Sihare (2024)
11	CART (<i>Classification and Regression Trees</i>)	1	Sihare (2024)
12	LDA (<i>Linear Discriminant Analysis</i>)	1	Sihare (2024)
13	Método de Probabilidade de Limiar (TPM)	1	Gonzalez-Nucamendi et al. (2023) (México)

Fonte: organizado pelas autoras (2024) com base nos artigos selecionados

Os algoritmos mais citados nos estudos apresentados foram o *Random Forest* (RF), *Support Vector Machine* (SVM), *Extreme Gradient Boosting* (XGBoost) e o *k-nearest neighbors* (KNN). Sendo que na aplicação a maioria dos estudos utilizou um combinado de algoritmos para prever a evasão dos estudantes.

O estudo realizado na China, propôs um novo conjunto de empilhamento baseado em um híbrido de *Random Forest* (RF), *Extreme Gradient Boosting* (XGBoost), *Gradient Boosting* (GB) e *Feed-forward Neural Networks* (FNN), permitindo estimar o risco de abandono de um curso acadêmico e a redução dos resultados dos alunos. (NYOGISUBIZO, 2022).

No Brasil, Bitencourt (2022), propôs a implantação de um processo de detecção e acompanhamento do risco de evasão utilizando um comitê de máquina (*Ensemble*) composto por três algoritmos: Máquina de Vetores de Suporte (SVM, do inglês: *Support Vector Machine*), Floresta Aleatória (RF, do inglês: *Random Forest*), *Gradient Boosting Machines* (GBM). O modelo preditivo proposto demonstrou adequação e resultou em um produto educacional de detecção e acompanhamento de risco de evasão disponível em: <https://bit.ly/2VVVmWH>. A implantação, de acordo com Bitencourt (2022), tem baixo ou nenhum custo adicional, com foco em dados já usualmente registrados em sistemas de informação institucionais das escolas.

Os algoritmos *Random Forest* e *XGBoost* também aparecem no estudo de Canete (2023), onde o melhor modelo preditivo foi um *Voting Ensemble* formado por: *XGBoost*, *LightGBM*, *Random Forest* e *Extreme Random Trees*.

Na Espanha, o *Ensemble* proposto pega as saídas dos modelos *Gradient Boosting*, *Random Forest* e *Support Vector Machine* e calcula sua própria saída, de acordo com Fernandez (2021), os resultados são promissores, conseguindo detectar mais de 72% dos alunos que irão desistir, sendo que os dados foram limitados, baseado apenas em dados acadêmicos.

Uma análise de oito classificadores, Gonzalez (2023), verificou que o *Random Forest* tem uma alta precisão, destacando-se como uma opção promissora e que requer menos sintonia para atingir um bom desempenho, permitindo visualizar a importância de variáveis preditoras.

A utilização do algoritmo *Random Forest* para implementar a metodologia *Thershold Probability*, de acordo com Gonzalez (2023), resultou na abordagem mais adequada, os resultados do estudo de caso demonstraram que a melhor estratégia é a que prevê a maior precisão no percentual de desistência.

Os estudos citados acima trabalharam apenas com dados numéricos e informações constantes nas bases de dados das instituições. Já o estudo realizado na França inova e propõe a inclusão de informações textuais dos alunos, de forma estruturada e não estruturada.

O *feedback* textual dos alunos, segundo Phan (2023), pode ser relevante, e sua proposta é uma estrutura híbrida de suporte à decisão que combina modelagem preditiva e esforços de segmentação de alunos. Neste estudo, de acordo com Phan (2023), observou-se que o método *doc2vec* apresenta melhor desempenho do que os métodos de espaço vetorial e *BERT*, e descobriram que o modelo usando o método de segmentação *K-means* tem melhor desempenho do que o agrupamento hierárquico em termo de AUC e TDL, a abordagem proposta supera os métodos existentes de desempenho preditivo.

4. Considerações finais

Com base nos estudos apresentados identificamos que a evasão escolar no ensino superior é um tema de interesse nos países em desenvolvimento, onde fatores socioeconômicos podem interferir na permanência dos estudantes. Os resultados das pesquisas demonstraram que o uso de modelos preditivos de IA são relevantes no combate a evasão em nível de graduação e se bem utilizados pelas instituições e governos podem servir de base para implantação de políticas de permanência estudantil em faculdades e universidades.

Uma previsão eficiente, como cita Nygisubizo (2022), pode alertar professores para intervenção precoce em comportamentos que podem levar ao abandono estudantil. Embora os estudos revelem que os métodos preditivos têm um potencial significativo para influenciar positivamente as políticas de prevenção à evasão escolar, ainda não se estabeleceu uma correlação direta entre os resultados dessas pesquisas e o impacto concreto nas políticas educacionais.

Todos os estudos demonstraram eficácia em seus modelos e podem ser adaptados para a realidade de outras instituições. Novos modelos de predição com dados numéricos e textuais também estão surgindo e demonstrando que a IA é um tema que está em constante avanço nos últimos anos e se bem utilizada pode contribuir de forma eficiente no combate a evasão no ensino superior.

Referências

- Bitencourt, W. A., Silva, D. M., & Do Carmo Xavier, G. (2022). May artificial intelligence support actions against school dropout? *Ensaio*, 30(116), 669–694. <https://doi.org/10.1590/S0104-403620220003002854>
- Caetano, M. M. (2019). O uso de inteligência artificial para detecção de evasão escolar em instituições de ensino: Um estudo de caso em uma instituição de ensino superior [Trabalho de conclusão de curso, Instituto Ensinar Brasil, Faculdade Doctum de Caratinga]. <https://dspace.doctum.edu.br/bitstream/123456789/3371/1/TCC%202020.pdf>
- Canete-Sifuentes, L., et al. (2023). Comparing automated machine learning against an off-the-shelf pattern-based classifier in a class imbalance problem: Predicting university dropout. *IEEE Access*, 11, 139147–139156. <https://doi.org.ez130.periodicos.capes.gov.br/10.1109/ACCESS.2023.3336596>
- Costa, J. de J., et al. (2019). Mining direct acyclic graphs to find frequent substructures — An experimental analysis on educational data. *Information Sciences*, 482, 266–278. <https://doi.org/10.1016/j.ins.2019.01.032>
- Fernández-García, A. J., et al. (2020). Creating a recommender system to support higher education students in the subject enrollment decision. *IEEE Access*, 8, 189069–189088. <https://doi.org.ez130.periodicos.capes.gov.br/10.1109/ACCESS.2020.3031572>
- Fernandez-Garcia, A. J., et al. (2021). A real-life machine learning experience for predicting university dropout at different stages using academic data. *IEEE Access*, 9, 133076–133090. <https://doi.org.ez130.periodicos.capes.gov.br/10.1109/ACCESS.2021.3115851>
- Gonzalez-Nucamendi, A., et al. (2023). Predictive analytics study to determine undergraduate students at risk of dropout. *Frontiers in Education*, 8. <https://doi.org/10.3389/feduc.2023.1244686>
- IBGE. (2023). Uma em cada quatro mulheres de 15 a 29 anos não estudava e nem estava ocupada em 2023. Agência IBGE de Notícias. <https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-de-noticias/noticias/39531-uma-em-cada-quatro-mulheres-de-15-a-29-anos-nao-estudava-e-nem-estava-ocupada-em-2023#:~:text=Em%202023%2C%20a%20taxa%20de,atrasados%2C%20frequentand o%20a%20educa%C3%A7%C3%A3o%20b%C3%A1sica>

- Kitchenham, B. (s.d.). Procedures for performing systematic reviews. <https://www.inf.ufsc.br/~aldo.vw/kitchenham.pdf>
- Monard, M. C., & Baranauskas, J. A. (2000). Aplicações de inteligência artificial: Uma visão geral. *Anais*. <https://dcm.ffclrp.usp.br/~augusto/publications/2000-laptec.pdf>
- Niyogisubizo, J., et al. (2022). Predicting student's dropout in university classes using two-layer ensemble machine learning approach: A novel stacked generalization. *Computers and Education: Artificial Intelligence*, 3. <https://doi.org/10.1016/j.caeai.2022.100066>
- Oliveira Júnior, J. O. (2022). A SBED e a Declaração de Lima de 2022: Garantia de atenção a crianças e adolescentes com dor e às suas famílias. *Brazilian Journal of Pain*, 5(3). <https://doi.org/10.5935/2595-0118.20220050-pt>
- Phan, M., De Caigny, A., & Coussement, K. (2023). A decision support framework to incorporate textual data for early student dropout prediction in higher education. *Decision Support Systems*, 168. <https://doi.org/10.1016/j.dss.2023.113940>
- Rodrigues, L. M., Moraes, E. A. P., & Santos, R. C. P. (2021). Análise preditiva para identificação de alunos suscetíveis à evasão escolar. *Brazilian Journal of Development*, 7(7), 71631-71643. <https://doi.org/10.34117/bjdv7n7-371>
- Santos Junior, J. da S., & Real, G. C. M. (2017). O acesso à educação superior na Universidade Federal da Grande Dourados: Trajetória de estudantes ingressantes entre 2006-2009. *Revista Brasileira de Política e Administração da Educação*, 33(2), 467. <https://doi.org/10.21573/vol33n22017.71081>
- Sihare, S. R. (2024). Student dropout analysis in higher education and retention by artificial intelligence and machine learning. *SN Computer Science*, 5(2). <https://rdcu.be/dluCU>
- Skittou, M., Merrouchi, M., & Gadi, T. (2023). Development of an early warning system to support educational planning process by identifying at-risk students. *IEEE Access*. <https://doi.org/10.1109/access.2023.3348091>
- Uliyan, D., et al. (2021). Deep learning model to predict students retention using BLSTM and CRF. *IEEE Access*, 9, 135550–135558. <https://ieeexplore-ieee.org.ez130.periodicos.capes.gov.br/document/9555608>
- Veloso, T. C. M. A., & De Almeida, E. P. (2002). Evasão nos cursos de graduação da Universidade Federal de Mato Grosso, campus universitário de Cuiabá—Um processo de exclusão. *Série-Estudos, Periódico do Programa de Pós-Graduação em Educação da UCDB*. <https://www.serie-estudos.ucdb.br/serie-estudos/article/view/564>
- Villarreal-Torres, H., et al. (2024). Modelo de clasificación para la deserción estudiantil en las universidades públicas del Perú. *Revista de Ciencias Sociales*, 30(1). <https://doi.org/10.31876/rcs.v30i1.41667>