



## TRANSFORMANDO A EDUCAÇÃO COM A INTELIGÊNCIA ARTIFICIAL: ESTRATÉGIAS INOVADORAS NO COMBATE À EVASÃO ESCOLAR

Raphael Antonio de Souza <sup>1</sup>  
Carlos Vital Giordano <sup>2</sup>

### RESUMO

A evasão escolar é uma preocupação global que não apenas afeta o acesso à educação, mas também influencia diretamente o desenvolvimento social e econômico. Neste estudo, conduziu-se uma revisão sistemática da literatura para analisar o uso da Inteligência Artificial (IA) como uma ferramenta inovadora para abordar esse desafio. A revisão sistemática permitiu examinar uma ampla gama de artigos científicos e projetos de pesquisa, com o objetivo de compreender a extensão do uso da IA na prevenção da evasão. A IA é aplicada por meio de algoritmos de aprendizado de máquina para analisar dados educacionais, identificando padrões e indicadores de evasão. A IA também ajuda os educadores a criar estratégias de ensino individualizadas por meio de sistemas de recomendação. No entanto, o uso da IA na prevenção da evasão escolar também apresenta desafios significativos em termos éticos e de privacidade. A proteção dos dados dos alunos e a garantia de que as decisões tomadas pelos algoritmos sejam justas e imparciais são questões cruciais que requerem atenção cuidadosa. Consequentemente, é fundamental que as intervenções baseadas em IA sejam desenvolvidas e implementadas de forma ética e em colaboração com profissionais da educação para abordar a evasão de forma humanizada. A IA tem um potencial significativo na prevenção da evasão escolar, proporcionando melhorias na identificação, intervenções personalizadas e apoio emocional aos estudantes. A revisão sistemática realizada neste estudo fornece uma base sólida de evidências que contribui para um entendimento aprofundado das abordagens da IA no contexto da evasão escolar.

**Palavras-chave:** Abandono. Algoritmos. Decisão. Egressos.

---

<sup>1</sup> Mestrando do Curso de Mestrado Profissional em Gestão e Desenvolvimento da Educação Profissional do Centro Paula Souza, [raphael299@gmail.com](mailto:raphael299@gmail.com).

<sup>2</sup> Doutor em Ciências Sociais, pela PUC-SP, professor do Curso de Mestrado Profissional em Gestão e Desenvolvimento da Educação Profissional do Centro Paula Souza, [giordanopaulasouza@yahoo.com.br](mailto:giordanopaulasouza@yahoo.com.br).



## 1 INTRODUÇÃO

A evasão escolar é um fenômeno global que representa desafio persistente para os sistemas educacionais em todo o mundo. Esse problema impacta não apenas na vida individual dos estudantes, mas também na sociedade como um todo, limitando o acesso a oportunidades econômicas e sociais e perpetuando desigualdades (Barros et al., 2021). A evasão escolar ocorre em todos os níveis de ensino, desde a educação básica até o ensino superior, e é influenciada por complexa interação de fatores socioeconômicos, familiares, psicológicos e educacionais conforme apontam os estudos de Filho e Araújo (2017), Gilioli (2016), Neri (2009) e Silva Filho et al. (2007). Nesse contexto, a aplicação da Inteligência Artificial (IA) emerge como estratégia inovadora e promissora a fim de identificar, prevenir e mitigar a evasão escolar (Giordano e Souza, 2023).

O artigo apresenta investigação particularizada sobre o uso da IA no combate à evasão escolar. A pesquisa envolveu cuidadosa análise sistemática da literatura, examinando ampla gama artigos científicos encontrados em cinco bases de dados. O foco principal da pesquisa se pautou em identificar como se emprega a IA ao abordar a evasão escolar em diferentes contextos educacionais e países.

A justificativa implícita da pesquisa reside na necessidade de abordar o problema de expressiva relevância social e educacional por meio de aproximações inovadoras. A evasão escolar compromete o desenvolvimento da sociedade, limitando o potencial dos seus cidadãos e a construção de futuro sustentável. Portanto, a pesquisa busca explorar como a IA se estabelece como ferramenta eficaz no intuito de enfrentar essa adversidade complexa.

Os objetivos se apresentam múltiplos: identificar as principais estratégias de IA usadas no combate à evasão escolar; avaliar sua eficácia da aplicação da IA; destacar os desafios éticos e práticos associados à implementação da IA na educação; e, fornecer *insights* à futuras pesquisas e práticas educacionais.

Metodologicamente, a pesquisa adotou abordagem de revisão sistemática da literatura. Consideraram-se os estudos de diversos contextos educacionais e países, incluindo análises de algoritmos de aprendizado de máquina na identificação de padrões de evasão e predição de desempenho acadêmico a fim de fornecer suporte aos estudantes e sistemas de recomendação baseados em IA buscando mitigar o problema da evasão.

As discussões e resultados apontam a competência significativa da IA no combate a evasão escolar, com evidências de melhorias na identificação precoce de indicadores de evasão, intervenções personalizadas e apoio emocional aos estudantes. No entanto, também destacam a importância de abordar questões éticas e de privacidade na aplicação da IA na educação.



## 2 REFERENCIAL TEÓRICO

A evasão escolar é um fenômeno persistente que afeta todos os níveis de ensino no Brasil. O abandono, que envolve a interrupção prematura dos estudos antes da conclusão de determinado ciclo educacional, inclui implicações profundas e duradouras aos indivíduos e à sociedade como um todo, com evidentes prejuízos sociais, acadêmicos e econômicos (Silva Filho et al., 2007). No contexto brasileiro, a evasão escolar abarca desde a educação infantil até o ensino superior, e suas causas são complexas, muitas vezes relacionadas a fatores sociais, econômicos e culturais (Neri, 2009).

Desde os primeiros anos de educação, até a conclusão da educação básica, atribui-se a evasão escolar a uma série de fatores, incluindo a dificuldade de acesso à escola, necessidade de trabalho, falta de interesse, entre outras, de acordo com os estudos conduzidos pelo movimento Todos pela Educação relata Neri (2009). Ademais, a evasão dos jovens dos bancos escolares, afeta, além da formação, as perspectivas profissionais futuras dos jovens, limitando suas oportunidades no mercado de trabalho e perpetuando um ciclo de desigualdade social (Barros et al., 2021 e Branco et al., 2020).

Mas o problema não é exclusividade da educação básica. No ensino superior brasileiro, em que os desafios incluem a falta de preparo acadêmico dos ingressantes, problemas financeiros que levam à desistência e a incompatibilidade entre as demandas do mercado de trabalho e a formação oferecida pelas instituições de ensino superior, a evasão é ainda mais presente. Isso resulta em altas taxas de abandono durante os cursos de graduação, impactando negativamente a qualidade da educação superior e limitando a capacidade do Brasil de formar profissionais qualificados (Gilioli, 2016).

Portanto, em todos os níveis de ensino, a evasão escolar é problema que demanda atenção urgente. A evasão perpetua a desigualdade social, prejudica o desenvolvimento educacional do país e compromete a capacidade de formar cidadãos preparados a enfrentar os desafios do século 21. Abordar a questão requer abordagem multidimensional que envolve a melhoria da qualidade da educação, o fortalecimento do apoio socioeconômico aos estudantes e a implementação de políticas educacionais eficazes que promovam a permanência e a conclusão dos estudos em todos os níveis educacionais.

## 3 METODOLOGIA

A pesquisa objetiva compreender o uso da IA na laboriosa tarefa de mitigar os números da evasão estudantil. A IA é um campo de pesquisa que ganha crescente relevância devido ao seu potencial em identificar padrões e fornecer *insights* valiosos no propósito de melhorar a



retenção dos estudantes nas instituições de ensino. A revisão sistemática da literatura é método rigoroso e essencial para investigar o uso das novas tecnologias na prevenção da evasão. Segundo Kitchenham (2004, p. 1) a revisão sistemática da literatura é “um meio de identificar, avaliar e interpretar todas as pesquisas disponíveis relevantes para uma determinada questão de pesquisa”. Neste contexto, a revisão sistemática da literatura desempenha papel crucial ao sintetizar e analisar de maneira abrangente as descobertas de estudos anteriores, fornecendo visão panorâmica das abordagens de IA adotadas, os resultados obtidos e as lacunas de pesquisa que ainda precisam ser preenchidas

Ainda de acordo com Kitchenham (2004) a revisão sistemática se divide em três fases principais:

1. **Planejamento:** Nesta fase, identifica-se a necessidade da pesquisa e determina-se o protocolo de pesquisa;
2. **Condução:** Nesta fase, o protocolo de pesquisa é aplicado, realiza-se a seleção primária dos estudos, realiza a extração, monitoramento e síntese dos dados;
3. **Relatório:** Nesta fase apresentam-se os resultados e análises estatísticas dos documentos selecionados.

### 3.1 PLANEJAMENTO

Objetiva-se com a investigação recolher as pesquisas que abordam o uso de IA na prevenção da evasão de estudantes, em todos os níveis de ensino, publicadas em artigos sobre evasão escolar em todos os níveis de ensino, em artigos entre os anos de 2012 a 2022, com o intuito de identificar as tendências de estudos sobre a temática. A necessidade da pesquisa se justifica por: identificar e sintetizar as principais pesquisas, abrangendo todos os contextos educacionais, avaliando os métodos e a eficácias das abordagens de IA em constatar precocemente os discentes com possibilidade de evasão.

Assim, propõem-se três questões de pesquisa com a finalidade de determinar os aspectos que veem sendo desenvolvidos para a prevenção da evasão por meio de IA:

**Questão 1:** Quais técnicas são utilizadas para criar modelos de predição da evasão?

**Questão 2:** Quais são as técnicas mais eficazes?

**Questão 3:** Qual o maior foco de pesquisas de prevenção da evasão por meio de IA?

Como protocolo de pesquisa, estabeleceu-se cinco bases de dados: ACM, DOAJ, ERIC, IEEE, Science Direct e Springer. Para a seleção dos documentos, no Quadro 1 se mostram os critérios de inclusão e exclusão.

Quadro 1 - Critérios de inclusão e exclusão

INCLUSÃO	EXCLUSÃO
Modelos que promovem solução para a evasão em qualquer nível educacional, por meio de IA	Documentos que não respondem às questões da pesquisa
Modelos que respondem às questões da pesquisa	Documentos que não respondem às questões da pesquisa
Publicações realizadas somente em periódicos	Publicações em Conferências e Livros, teses e dissertações
Publicações entre 2012 e 2022	Documentos fora do Período
Publicações somente em inglês	Publicações em quaisquer outras línguas

Fonte: Autores, 2023

Definiu-se a seguinte *string* de busca: “artificial intelligence” AND “School dropout” OR “dropout PREDICTION” OR “STUDENT DROPOUT”, aplicadas ao título, resumo e palavras chave, no período de busca correspondente entre Janeiro de 2012 e Dezembro de 2022.

### 3.2 CONDUÇÃO

Realizou-se a pesquisa de acordo com o protocolo proposto na seção 3.1. Uma vez selecionado, revisou-se cada documento, o que incluiu a leitura do título e resumo, a fim de verificar se ele se enquadrava nos critérios de seleção estabelecidos.

## 4 RESULTADOS

A Tabela 1 apresenta o total de artigos identificados e selecionados, por fonte de acesso. Evidencia-se, dentre os artigos selecionados, a distribuição das fontes, na coluna % / Total (46).

Tabela 1 - Artigos Selecionados

Fonte	Artigos identificados	Artigos selecionados	% / Total
SCIENCE DIRECT	431	10	21,7%
ERIC	18	9	19,6%
IEEE	175	9	19,6%
SPRINGER	121	8	17,4%
ACM	59	6	13,0%
DOAJ	8	4	8,7%
<b>Total</b>	<b>812</b>	<b>46</b>	<b>100,0%</b>

Fonte: Autores, 2023

Dentre os trabalhos selecionados, observa-se crescimento das publicações ao longo dos últimos 10 anos, conforme apresentado na Figura 1. Destaca-se maior crescimento nos últimos seis anos e que, nos anos de 2012, 2014 e 2016 não se encontraram artigos dentro dos critérios



estabelecidos para esta revisão. Listam-se os trabalhos selecionados no Quadro 2, com número de identificação e autor, que será usado posteriormente para indicá-los.

Considerando as perguntas norteadoras deste trabalho, pretende-se responder às questões de forma individualizada, por meio de tabelas e gráficos apresentados a seguir.

#### 4.1 Questão 1: Quais técnicas são utilizadas para criar modelos de predição da evasão?

Identificaram-se 65 técnicas de IA na criação de modelos de predição da evasão. A Tabela 2 apresenta as 12 técnicas que mais se repetiram nos trabalhos analisados. Para cada modelo apresentado, estão indicados o ID do estudo conforme Quadro 2. Observa-se que 17,3% dos trabalhos escolheram a Regressão Logística como técnica para o desenvolvimento de um classificador capaz de prever a possibilidade de conclusão ou não de um aluno. Esta escolha está atrelada ao fato da regressão logística ser especialmente projetada para lidar com variáveis dependentes binárias ou categóricas além de ser simples de operar, fácil de entender e amplamente utilizada (Qiu et al., 2018).

Quadro 2 - Artigos selecionados após aplicar critérios de inclusão e exclusão

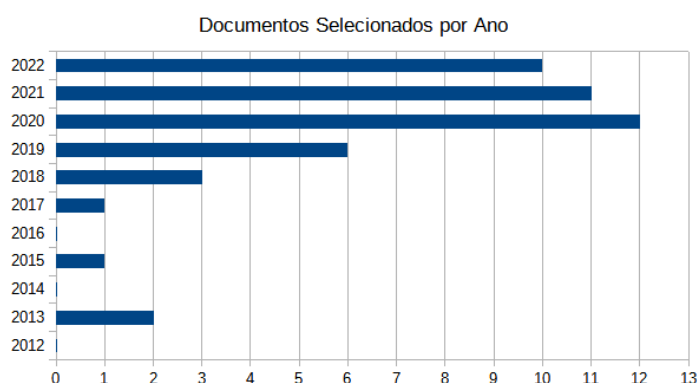
ID	ESTUDO	ID	ESTUDO	ID	ESTUDO
1	(Şahin, 2021)	17	(Deeva et al., 2022)	33	(Yin et al., 2020)
2	(Nicoletti; Oliveira, 2020)	18	(Costa et al., 2017)	34	(Huo et al., 2023)
3	(Lee; Lee, 2020)	19	(Albreiki et al., 2022)	35	(Hannaford et al., 2021)
4	(Fernandez-Garcia et al., 2021)	20	(Ortigosa et al., 2019)	36	(Marquez-Vera et al., 2013)
5	(Qiu et al., 2018)	21	(Li et al., 2020)	37	(Kemper et al., 2020)
6	(Berka; Marek, 2021)	22	(Oreshin et al., 2020)	38	(Niyogisubizo et al., 2022)
7	(Fu et al., 2021)	23	(Iam-On; Boongoen, 2017)	39	(Imran et al., 2019)
8	(Wen et al., 2020)	24	(Livieris et al., 2019)	40	(Barros et al., 2019)
9	(Fernandez-Garcia et al., 2020)	25	(Baranyi et al., 2020)	41	(Qiu et al., 2019)
10	(Burgos et al., 2018)	26	(Pallathadka et al., 2022)	42	(Pek et al., 2023)
11	(Mubarak et al., 2021)	27	(Christie et al., 2019)	43	(Hu; Rangwala, 2020)
12	(Chung; Lee, 2019)	28	(Wang et al., 2021)	44	(Plagge, 2013)
13	(Basnet et al., 2022)	29	(Zheng et al., 2022)	45	(Cruz-Jesus et al., 2020)
14	(Jin, 2021)	30	(Zheng et al., 2020)	46	(Cohausz, 2022)



15	(Figueroa-Canas; Sancho-Vinuesa, 2020)	31	(Melo et al., 2022)		
16	(Xu et al., 2022)	32	(Furini et al., 2021)		

Fonte: Autores, 2023

Figura 1 - Publicações por Ano



Fonte: Autores, 2023

Tabela 2 - Técnicas de IA e número de trabalhos correspondentes

Algoritmos identificados	Número de trabalhos	%
Logistic Regression (LR) <sup>1, 6, 9, 10, 13, 17, 26, 28, 34, 35, 37, 43, 45</sup>	13	17,3%
Random Forest (RF) <sup>4, 6, 9, 12, 13, 17, 26, 32, 35, 45</sup>	10	13,3%
Support Vector Machine (SVM) <sup>4, 9, 13, 17, 26, 35, 42, 45, 46</sup>	9	12,0%
Decision Tree (DT) <sup>6, 9, 22, 32, 35, 37, 45</sup>	7	9,3%
kNN <sup>9, 13, 24, 32, 35, 45</sup>	6	8,0%
Naive Bayes (NB) <sup>17, 18, 19, 24, 35, 46</sup>	6	8,0%
Convolutional Neural Network (CNN) <sup>7, 8, 16, 29, 30</sup>	5	6,7%
Ensemble <sup>3, 4, 23, 38</sup>	4	5,3%
Neural Network (NN) <sup>18, 33, 35, 45</sup>	4	5,3%
xgBoost <sup>13, 19, 27, 34</sup>	4	5,3%
Multi Layer Perceptron (MLP) <sup>9, 19, 24, 40</sup>	4	5,3%
Deep Neural Network (DNN) <sup>25, 39, 46</sup>	3	4,0%

Fonte: Autores, 2023

RF(13,3%), SVM (12,0%) e DT (9,3%) ocupam as posições seguintes, uma vez que se considera essas técnicas ferramentas poderosas na resolução de problemas de classificação e frequentemente utilizadas por sua simplicidade e facilidade de entendimento (Furini et al., 2021; Oreshin et al., 2020; Pek et al., 2023).

#### 4.2 Questão 2: Quais são as técnicas mais eficazes?

Em relação à efetividade das técnicas, os estudos consideraram como métricas de desempenho: Acurácia, Medida F1, Sensibilidade, Precisão e AUC. Em todos os estudos,



empregaram-se um total de 323 métricas de desempenho, sendo a Acurácia a métrica utilizada para avaliar 38,0% das técnicas de IA empregadas. A medida F1 foi empregada em 20,0% das técnicas, seguido de sensibilidade (18,0%), precisão (16,0%) e AUC (8,0%).

Considerando apenas a Acurácia das técnicas mais utilizadas, demonstradas na Tabela 2, a média aritmética das acurácias se estabelece em 0,8629. A Acurácia indica, de forma geral, a taxa de acerto do modelo preditivo. Ou seja, informa quanto o modelo acertou em classificar corretamente o objeto de estudo. O valor 0,8629, portanto, indica que na média, os algoritmos acertaram 86,3% dos casos em prever a evasão.

A Tabela 3 apresenta os trabalhos com Acurácia superior a 90,0%. Observa-se que dos 12 modelos de IA mais utilizados, 10 apresentam acurácias superiores a 90,0%. Os resultados indicam ainda como as técnicas mais precisas DT, DNN, LR, RF e SVM. Considerando ainda os 10 trabalhos que apresentaram modelos com Acurácia superior a 80,0%, os quatro trabalhos que utilizaram a medida F1, acima de 80,0% e um trabalho que apresentou a métrica AUC também acima de 80,0%, têm-se ainda 30 trabalhos com um total de 35 modelos de IA testados, com métricas de desempenho superior a 80,0%. Ou seja, 65,0% dos trabalhos apresentaram métricas de desempenho consideradas ótimas para os casos de prevenção da evasão. Ainda, apenas quatro trabalhos apresentaram modelos com métricas de desempenho inferiores a 70,0%. Contudo, é preciso cautela, uma vez que os resultados dependem do conjunto de dados e das variáveis analisadas.

Tabela 3 - Modelos com acurácia superior a 90%

TÉCNICA DE IA	ACURÁCIA
MLP <sup>24</sup> , SVM <sup>4</sup> , Ensemble <sup>3, 38</sup> , NN <sup>35</sup> , CNN <sup>16</sup> , LR <sup>1</sup> , DT <sup>6, 22</sup> , RF <sup>6</sup>	De 90% a 94%
LR <sup>6, 10, 37</sup> , SVM <sup>42</sup> , RF <sup>12</sup> , DT <sup>37</sup> , kNN <sup>35</sup>	De 94,01% a 98%
SVM <sup>35</sup> , RF <sup>35</sup> , LR <sup>35</sup> , DT <sup>35</sup> , DNN <sup>39, 46</sup>	De 98,01% a 99,80%

Fonte: Autores, 2023

#### 4.3 Questão 3: Qual o maior foco de pesquisas de prevenção da evasão por meio de IA?

Dos 46 trabalhos selecionados, vê-se clara preferência das pesquisas para tratar a evasão em cursos superiores, com 50,0% dos trabalhos, seguido pelos cursos MOOC, com 36,0% dos trabalhos. Somados os trabalhos realizados com ensino médio, fundamental, técnico e médio técnico, estes representam 14,0% dos trabalhos encontrados, ver Quadro 3.

Quadro 3 – Tipos de cursos

TIPO DE CURSO	TRABALHOS
---------------	-----------





MOOC	1, 5, 7, 8, 10, 11, 13, 14, 16, 17, 21, 28, 29, 30, 33, 39 e 41
Ensino Superior	2, 3, 4, 6, 9, 15, 18, 19, 20, 22, 23, 24, 25, 26, 27, 32, 34, 35, 37, 38, 43, 45, 46,
Ensino Médio	12, 36, 42 e 44
Ensino Fundamental	12
Ensino Técnico	31
Ensino Médio Técnico	40

Fonte: Autores, 2023

## 5 DISCUSSÃO

Dos 46 trabalhos identificados sobre a previsão de evasão, 73,0% contemplaram a fase do pré-processamento dos dados. Isso ressalta a importância desta fase na obtenção de variáveis adequadas, solução de dados ausentes e anomalias, resultando em um aumento das taxas de acertos. Observou-se ainda em 21% dos trabalhos, a preocupação com o desbalanceamento dos dados. Essas observações puderam ser feitas em trabalhos que utilizaram dados da unidade escolar ou da universidade. Das pesquisas sobre evasão em cursos do tipo MOOC, apenas dois não utilizaram dados públicos e portanto não houve observações nessas pesquisas em relação ao desbalanceamento de dados. O desbalanceamento portanto, deve ser considerado para evitar vieses do modelo e baixo desempenho na classe minoritária.

As pesquisas apontam destacada preferência em trabalhar a evasão em cursos superiores e do tipo MOOC. Portanto, identifica-se lacuna a ser explorada com maior enfoque, buscando soluções alternativas para o problema da evasão na educação básica e profissional.

## 6 CONSIDERAÇÕES FINAIS

O estudo abordou o uso da IA na prevenção da evasão escolar, um problema global que afeta o acesso à educação e o desenvolvimento socioeconômico. A revisão sistemática da literatura revelou a aplicação de diversas técnicas de IA, com foco na identificação de padrões de evasão e previsão de desempenho acadêmico. Os resultados demonstraram que as técnicas mais utilizadas, como: Regressão Logística, Random Forest, e Support Vector Machine, apresentam em média uma acurácia de 86,3%.

Além disso, observou-se tendência nas pesquisas em direção a cursos superiores e MOOC, deixando importante lacuna a explorar na prevenção da evasão em níveis de ensino



mais básicos. A análise também destacou a importância do pré-processamento de dados e a consideração do desbalanceamento de dados para evitar viés nos modelos.

No entanto, é crucial lembrar que o sucesso da IA na prevenção da evasão escolar depende do contexto e das variáveis específicas, e que os resultados devem ser interpretados com cautela. Além disso, desafios éticos e de privacidade surgem com o uso da IA, que deve ser abordado com cuidado.

Por fim, a investigação destaca a promissora capacidade da IA em combater a evasão escolar, fornecendo *insights* valiosos, intervenções personalizadas e suporte emocional aos alunos. No entanto, pesquisas futuras devem se concentrar em abordagens aos níveis de ensino mais básicos e abordar questões éticas e de privacidade de forma abrangente.

## REFERÊNCIAS

ALBREIKI, B.; HABUZA, T.; ZAKI, N. Framework for automatically suggesting remedial actions to help students at risk based on explainable ML and rule-based models. **International Journal of Educational Technology in Higher Education**, v. 19, n. 1, p. 49, 19 set. 2022.

BARANYI, M.; NAGY, M.; MOLONTAY, R. **Interpretable Deep Learning for University Dropout Prediction**. Proceedings of the 21st Annual Conference on Information Technology Education. **Anais...** Em: SIGITE '20: THE 21ST ANNUAL CONFERENCE ON INFORMATION TECHNOLOGY EDUCATION. Virtual Event USA: ACM, 7 out. 2020. Disponível em: <<https://dl.acm.org/doi/10.1145/3368308.3415382>>. Acesso em: 26 set. 2023

BARROS, R. P. DE et al. **Consequências da Violação do Direito à Educação**. 1º ed. Rio de Janeiro: Autografia, 2021.

BARROS, T. M. et al. Predictive Models for Imbalanced Data: A School Dropout Perspective. **Education Sciences**, v. 9, n. 4, p. 275, 15 nov. 2019.

BASNET, R. B.; JOHNSON, C.; DOLECK, T. Dropout prediction in Moocs using deep learning and machine learning. **Education and Information Technologies**, v. 27, n. 8, p. 11499–11513, set. 2022.

BERKA, P.; MAREK, L. Bachelor's degree student dropouts: Who tend to stay and who tend to leave? **Studies in Educational Evaluation**, v. 70, p. 100999, set. 2021.

BRANCO, E. P. et al. Evasão Escolar: desafios para permanência dos estudantes na educação básica. **Revista Contemporânea de Educação**, v. 15, n. 34, p. 133–155, 2020.

BURGOS, C. et al. Data mining for modeling students' performance: A tutoring action plan to prevent academic dropout. **Computers & Electrical Engineering**, v. 66, p. 541–556, fev. 2018.

CHRISTIE, S. T.; JARRATT, D. C.; OLSON, L. A. Machine-Learned School Dropout Early Warning at Scale. 2019.

CHUNG, J. Y.; LEE, S. Dropout early warning systems for high school students using machine learning. **Children and Youth Services Review**, v. 96, p. 346–353, 1 jan. 2019.



COHAUSZ, L. When Probabilities Are Not Enough — A Framework for Causal Explanations of Student Success Models. v. 14, n. 3, 2022.

COSTA, E. B. et al. Evaluating the effectiveness of educational data mining techniques for early prediction of students' academic failure in introductory programming courses. **Computers in Human Behavior**, v. 73, p. 247–256, ago. 2017.

CRUZ-JESUS, F. et al. Using artificial intelligence methods to assess academic achievement in public high schools of a European Union country. **Heliyon**, v. 6, n. 6, p. e04081, jun. 2020.

DEEVA, G.; DE SMEDT, J.; DE WEERDT, J. Educational Sequence Mining for Dropout Prediction in MOOCs: Model Building, Evaluation, and Benchmarking. **IEEE Transactions on Learning Technologies**, v. 15, n. 6, p. 720–735, 1 dez. 2022.

FERNANDEZ-GARCIA, A. J. et al. Creating a Recommender System to Support Higher Education Students in the Subject Enrollment Decision. **IEEE Access**, v. 8, p. 189069–189088, 2020.

FERNANDEZ-GARCIA, A. J. et al. A Real-Life Machine Learning Experience for Predicting University Dropout at Different Stages Using Academic Data. **IEEE Access**, v. 9, p. 133076–133090, 2021.

FIGUEROA-CANAS, J.; SANCHO-VINUESA, T. Early Prediction of Dropout and Final Exam Performance in an Online Statistics Course. **IEEE Revista Iberoamericana de Tecnologías del Aprendizaje**, v. 15, n. 2, p. 86–94, maio 2020.

FILHO, R. B. S.; ARAÚJO, R. M. DE L. Evasão e abandono escolar na educação básica no Brasil: fatores, causas e possíveis consequências. **Educação Por Escrito**, v. 8, n. 1, p. 35–48, 29 jun. 2017.

FU, Q. et al. CLSA: A novel deep learning model for MOOC dropout prediction. **Computers & Electrical Engineering**, v. 94, p. 107315, set. 2021.

FURINI, M.; GALLI, G.; MARTINI, M. C. **On Using Video Lectures Data Usage to Predict University Students Dropout**. Proceedings of the Conference on Information Technology for Social Good. **Anais... Em: GOODIT '21: CONFERENCE ON INFORMATION TECHNOLOGY FOR SOCIAL GOOD**. Roma Italy: ACM, 9 set. 2021. Disponível em: <<https://dl.acm.org/doi/10.1145/3462203.3475890>>. Acesso em: 26 set. 2023

GILIOLI, R. DE SOUSA P. **Evasão em instituições federais de ensino superior no Brasil: expansão da rede, SISU e desafios**. Brasília: Câmara dos Deputados: [s.n.]. Disponível em: <[https://nupe.blumenau.ufsc.br/files/2017/05/evasao\\_institui%C3%A7%C3%B5es.pdf](https://nupe.blumenau.ufsc.br/files/2017/05/evasao_institui%C3%A7%C3%B5es.pdf)>. Acesso em: 6 out. 2023.

GIORDANO, C. V.; SOUZA, R. A. DE. Prognóstico da Evasão Escolar em Instituição de Educação Profissional e Tecnológica por meio da Inteligência Artificial. **Revista Interações**, v. 19, n. 66, p. 1–20, 28 ago. 2023.

HANNAFORD, L.; CHENG, X.; KUNES-CONNELL, M. Predicting nursing baccalaureate program graduates using machine learning models: A quantitative research study. **Nurse Education Today**, v. 99, p. 104784, abr. 2021.



HU, Q.; RANGWALA, H. Towards Fair Educational Data Mining: A Case Study on Detecting At-risk Students. 2020.

HUO, H. et al. Predicting Dropout for Nontraditional Undergraduate Students: A Machine Learning Approach. **Journal of College Student Retention: Research, Theory & Practice**, v. 24, n. 4, p. 1054–1077, fev. 2023.

IAM-ON, N.; BOONGOEN, T. Improved student dropout prediction in Thai University using ensemble of mixed-type data clusterings. **International Journal of Machine Learning and Cybernetics**, v. 8, n. 2, p. 497–510, abr. 2017.

IMRAN, A. S.; DALIPI, F.; KASTRATI, Z. **Predicting Student Dropout in a MOOC: An Evaluation of a Deep Neural Network Model**. Proceedings of the 2019 5th International Conference on Computing and Artificial Intelligence. **Anais... Em: ICCAI '19: 2019 5TH INTERNATIONAL CONFERENCE ON COMPUTING AND ARTIFICIAL INTELLIGENCE**. Bali Indonesia: ACM, 19 abr. 2019. Disponível em: <<https://dl.acm.org/doi/10.1145/3330482.3330514>>. Acesso em: 26 set. 2023

JIN, C. Dropout prediction model in MOOC based on clickstream data and student sample weight. **Soft Computing**, v. 25, n. 14, p. 8971–8988, jul. 2021.

KEMPER, L.; VORHOFF, G.; WIGGER, B. U. Predicting student dropout: A machine learning approach. **European Journal of Higher Education**, v. 10, n. 1, p. 28–47, 2 jan. 2020.

KITCHENHAM, B. Procedures for Performing Systematic Reviews. **Keele, UK, Keele University**, v. 33, n. 2004, p. 1–26, 2004.

LEE, Z.-J.; LEE, C.-Y. A parallel intelligent algorithm applied to predict students dropping out of university. **The Journal of Supercomputing**, v. 76, n. 2, p. 1049–1062, fev. 2020.

LI, H.; DING, W.; LIU, Z. Identifying At-Risk K-12 Students in Multimodal Online Environments: A Machine Learning Approach. 2020.

LIVIERIS, I. E. et al. Improving the evaluation process of students' performance utilizing a decision support software. **Neural Computing and Applications**, v. 31, n. 6, p. 1683–1694, jun. 2019.

MARQUEZ-VERA, C.; MORALES, C. R.; SOTO, S. V. Predicting School Failure and Dropout by Using Data Mining Techniques. **IEEE Revista Iberoamericana de Tecnologías del Aprendizaje**, v. 8, n. 1, p. 7–14, fev. 2013.

MELO, E. et al. On the Use of eXplainable Artificial Intelligence to Evaluate School Dropout. **Education Sciences**, v. 12, n. 12, p. 845, 22 nov. 2022.

MUBARAK, A. A.; CAO, H.; HEZAM, I. M. Deep analytic model for student dropout prediction in massive open online courses. **Computers & Electrical Engineering**, v. 93, p. 107271, jul. 2021.

NERI, M. **Motivos da Evasão Escolar**. Disponível em: <<https://bibliotecadigital.fgv.br/dspace/handle/10438/21964>>. Acesso em: 30 maio. 2022.



NICOLETTI, M. D. C.; OLIVEIRA, O. L. D. A Machine Learning-Based Computational System Proposal Aiming at Higher Education Dropout Prediction. **Higher Education Studies**, v. 10, n. 4, p. 12, 10 set. 2020.

NIYOGISUBIZO, J. et al. Predicting student's dropout in university classes using two-layer ensemble machine learning approach: A novel stacked generalization. **Computers and Education: Artificial Intelligence**, v. 3, p. 100066, 2022.

ORESHIN, S. et al. **Implementing a Machine Learning Approach to Predicting Students' Academic Outcomes**. 2020 International Conference on Control, Robotics and Intelligent System. **Anais...** Em: CCRIS 2020: 2020 INTERNATIONAL CONFERENCE ON CONTROL, ROBOTICS AND INTELLIGENT SYSTEM. Xiamen China: ACM, 27 out. 2020. Disponível em: <<https://dl.acm.org/doi/10.1145/3437802.3437816>>. Acesso em: 26 set. 2023

ORTIGOSA, A. et al. From Lab to Production: Lessons Learnt and Real-Life Challenges of an Early Student-Dropout Prevention System. **IEEE Transactions on Learning Technologies**, v. 12, n. 2, p. 264–277, 1 abr. 2019.

PALLATHADKA, H. et al. Investigating the impact of artificial intelligence in education sector by predicting student performance. **Materials Today: Proceedings**, v. 51, p. 2264–2267, 2022.

PEK, R. Z. et al. The Role of Machine Learning in Identifying Students At-Risk and Minimizing Failure. **IEEE Access**, v. 11, p. 1224–1243, 2023.

PLAGGE, M. **Using artificial neural networks to predict first-year traditional students second year retention rates**. Proceedings of the 51st ACM Southeast Conference. **Anais...** Em: ACM SE'13: ACM SOUTHEAST REGIONAL 2013. Savannah Georgia: ACM, 4 abr. 2013. Disponível em: <<https://dl.acm.org/doi/10.1145/2498328.2500061>>. Acesso em: 26 set. 2023

QIU, L. et al. Student dropout prediction in massive open online courses by convolutional neural networks. **Soft Computing**, v. 23, n. 20, p. 10287–10301, out. 2019.

QIU, L.; LIU, Y.; LIU, Y. An Integrated Framework With Feature Selection for Dropout Prediction in Massive Open Online Courses. **IEEE Access**, v. 6, p. 71474–71484, 2018.

ŞAHIN, M. A Comparative Analysis of Dropout Prediction in Massive Open Online Courses. **Arabian Journal for Science and Engineering**, v. 46, n. 2, p. 1845–1861, fev. 2021.

SILVA FILHO, R. L. L. E et al. A evasão no ensino superior brasileiro. **Cadernos de Pesquisa**, v. 37, n. 132, p. 641–659, dez. 2007.

WANG, L. et al. **MOOC Dropout Prediction Based on Dynamic Embedding Representation Learning**. Proceedings of the 5th International Conference on Computer Science and Application Engineering. **Anais...** Em: CSAE 2021: THE 5TH INTERNATIONAL CONFERENCE ON COMPUTER SCIENCE AND APPLICATION ENGINEERING. Sanya China: ACM, 19 out. 2021. Disponível em: <<https://dl.acm.org/doi/10.1145/3487075.3487141>>. Acesso em: 26 set. 2023

WEN, Y. et al. Consideration of the local correlation of learning behaviors to predict dropouts from MOOCs. **Tsinghua Science and Technology**, v. 25, n. 3, p. 336–347, jun. 2020.



XU, C. et al. Educational Data Mining: Dropout Prediction in XuetangX MOOCs. **Neural Processing Letters**, v. 54, n. 4, p. 2885–2900, ago. 2022.

YIN, S. et al. Power of Attention in MOOC Dropout Prediction. **IEEE Access**, v. 8, p. 202993–203002, 2020.

ZHENG, Y. et al. MOOC Dropout Prediction Using FWTS-CNN Model Based on Fused Feature Weighting and Time Series. **IEEE Access**, v. 8, p. 225324–225335, 2020.

ZHENG, Y. et al. MOOC dropout prediction using a fusion deep model based on behaviour features. **Computers and Electrical Engineering**, v. 104, p. 108409, dez. 2022.