

Association for Information Systems

AIS Electronic Library (AISeL)

ISLA 2023 Proceedings

Latin America (ISLA)

Fall 8-7-2023

Prever o desempenho do aluno com a aprendizagem de máquina e melhorar com GPT

Maurilio Aparecido Benevento

Fernando S. Meirelles

Follow this and additional works at: <https://aisel.aisnet.org/isla2023>

This material is brought to you by the Latin America (ISLA) at AIS Electronic Library (AISeL). It has been accepted for inclusion in ISLA 2023 Proceedings by an authorized administrator of AIS Electronic Library (AISeL). For more information, please contact elibrary@aisnet.org.



Prever o desempenho do aluno com a aprendizagem de máquina e melhorar com GPT

Artigo Completo

Maurilio Benevento

FGV EAESP

maurilio.benevento@gmail.com

Fernando Meirelles

FGV EAESP

fernando.meirelles@fgv.br

Abstract

Objective: This research aimed to use Machine Learning algorithms and the GPT natural language model to predict and improve students' performance. **Originality:** This study innovates in the educational field by employing advanced techniques of Machine Learning and GPT, enabling more personalized approaches that positively affect the quality of student learning. **Method:** The study adopted a quantitative, descriptive, and explanatory approach, based on applied research and experimental methods, processing 900 records using 21 algorithms. **Results:** The effectiveness of the algorithms in predicting students' performance stood out. The use of GPT proved particularly beneficial in enhancing student performance, surpassing other training approaches. These techniques find knowledge gaps and provide personalized feedback, allowing for individualized education. **Conclusion:** The combination of GPT with machine learning is a valuable tool for enhancing the quality of education and the learning experience, fostering significant advancements in the educational field.

Keywords

Algorithm, machine learning, GPT, student performance prediction.

Resumo

Objetivo: Esta pesquisa utilizou algoritmos de Aprendizagem de Máquina (AM) e o modelo de linguagem natural GPT para prever e melhorar o desempenho dos alunos. **Originalidade:** Esta pesquisa inova na área educacional ao empregar técnicas avançadas de AM e GPT, possibilitando abordagens mais personalizadas, impactando positivamente a qualidade do aprendizado dos alunos. **Método:** O estudo adotou uma abordagem quantitativa, descritiva e explicativa, com base em pesquisa aplicada e métodos experimentais, processando 900 registros com 21 algoritmos. **Resultados:** Destacaram-se a eficácia dos algoritmos na previsão do desempenho dos alunos. O uso do GPT mostrou-se particularmente benéfico na melhoria do desempenho de alunos, superando outras abordagens de formação. Essas técnicas identificam lacunas no conhecimento e fornecem feedback personalizado, permitindo uma educação individualizada. **Conclusão:** A combinação do GPT com aprendizagem de máquina é uma ferramenta valiosa para aprimorar a qualidade da educação e a experiência de aprendizado, promovendo avanços significativos na área educacional.

Palavras-chave

Algoritmo, aprendizado de máquina, GPT, predição de desempenho do aluno.



Introdução

A busca por uma educação de qualidade impulsiona o desenvolvimento de tecnologias inovadoras para aprimorar o desempenho dos estudantes, incluindo a aplicação de algoritmos de AM. Com o crescente volume de dados gerados no contexto educacional, surgem oportunidades para empregar técnicas avançadas de AM na previsão do desempenho dos alunos. Nesse cenário, destaca-se o *Generative Pre-trained Transformer* (GPT), um modelo de linguagem natural baseado em Processamento de Linguagem Natural (PLN), desenvolvido pela OpenAI em 2018, que se mostra promissor na melhoria do desempenho dos alunos.

O GPT é treinado em grandes volumes de texto provenientes de diversas fontes, utilizando pré-treinamento para prever a próxima palavra em uma frase ou completar uma frase de forma coerente. Ao combinar o GPT com algoritmos de AM, é possível prever e aprimorar o desempenho dos alunos em tarefas educacionais, permitindo uma educação mais personalizada. As técnicas de AM contribuem significativamente para elevar a qualidade da educação, possibilitando que os educadores desenvolvam estratégias pedagógicas mais eficazes.

Objetivo

Este estudo tem como objetivo investigar a previsão do desempenho do aluno por meio de algoritmos de AM combinado com o GPT, a fim de fornecer sugestões para a melhoria do desempenho dos estudantes. Além de explorar as questões de causalidade, dependência e influência, nosso delineamento metodológico abrange uma revisão abrangente do estado da arte na área, destacando a relevância do estudo para a comunidade acadêmica e educacional. Acreditamos que os resultados obtidos contribuirão para avançar o conhecimento nessa área emergente e beneficiarão os educadores na implementação de abordagens educacionais mais personalizadas.

Questões e hipóteses

As hipóteses para os questionamentos são doravante nomeadas com H de hipótese e se relacionam com Q de questão.

Q1. Existe uma relação entre os dados educacionais disponíveis e o desempenho acadêmico dos alunos?

H1: Há uma relação significativa entre os dados educacionais disponíveis e o desempenho acadêmico dos alunos.

Q2. Os algoritmos de Aprendizagem de Máquina podem ser eficazes na previsão do desempenho dos alunos?

H2: Os algoritmos de Aprendizagem de Máquina são capazes de prever de forma precisa o desempenho dos alunos.

Q3. O uso do GPT em conjunto com os algoritmos de Aprendizagem de Máquina melhora o desempenho do aluno?

H3: O uso do modelo GPT em conjunto com os algoritmos de Aprendizagem de Máquina melhora o desempenho do aluno.

Q4. Quais fatores ou características dos dados educacionais têm maior influência na previsão do desempenho do aluno?

H4: Certas características dos dados educacionais, como histórico acadêmico anterior e envolvimento em atividades extracurriculares, têm maior influência na previsão do desempenho do aluno.



Justificativa

Esta pesquisa justifica-se pelo interesse crescente das escolas em compreender e melhorar o desempenho dos alunos, bem como pelo uso frequente de tecnologias que geram dados educacionais. A análise desses dados usando algoritmos de AM pode fornecer insights valiosos sobre o processo de aprendizagem dos alunos. Além disso, o uso de técnicas de AM pode ajudar os professores a identificar alunos com dificuldades e oferecer intervenções personalizadas para melhorar seu desempenho.

Referencial teórico

O *Generative Pre-trained Transformer* (GPT) é um modelo de processamento de linguagem natural (PLN) desenvolvido pela OpenAI, uma organização de pesquisa em inteligência artificial. Introduzido em 2018 por um time de pesquisadores liderado por Alec Radford, segundo o próprio ChatGPT (2023). O GPT tem evoluído ao longo dos anos, com versões como o GPT-1, GPT-2, GPT-3 e a mais recente, GPT-3.5 a ser lançado ainda em 2023. Sua aplicação abrange uma ampla variedade de áreas.

Previsão do Desempenho dos Alunos (PDA)

A PDA é crucial para monitorar e adaptar o ensino às necessidades individuais dos alunos (Ofori et al., 2020). Identificar dificuldades de aprendizagem antecipadamente melhora os resultados acadêmicos e auxilia na adoção de políticas e práticas de ensino mais eficazes (Pojon, 2017). Estudos estão concentrados no desenvolvimento de ferramentas para processar os dados educacionais (Ofori et al., 2020).

A PDA é uma prática comum, avaliada por notas, frequências e trabalhos extras, buscando melhorias na jornada educacional dos alunos (Shovon & Haque, 2012). Estratégias pedagógicas e de gestão são empregadas para aprimorar o desempenho dos alunos. A PDA desperta interesse de pesquisadores e profissionais, alertando os alunos sobre sua jornada educacional e oferecendo oportunidades de melhoria (Alamri & Alharbi, 2021; Karthikeyan & Kavipriya, 2017). Técnicas de mineração de dados e análise do aprendizado dos alunos aplicam abordagens estatísticas e de AM (Al-Shabandar et al., 2017).

Ahmad et al. (2022) identificaram a falta de sincronização dos dados internos das escolas, levando à dependência de sistemas externos de previsão. Os algoritmos de AM são cada vez mais utilizados para a PDA, complementando os softwares acadêmicos existentes.

As escolas investem significativamente em TI e a PDA é um tema relevante, devido à geração de dados nesse ambiente (Cortex, 2022). Estudos destacam a importância da PDA na trajetória educacional e retenção dos estudantes (Kabakchieva, 2012; Obsie & Adem, 2018; Shovon & Haque, 2012). O uso de históricos de notas permite prever o sucesso acadêmico e melhorar a oferta de educação desde o início da jornada dos estudantes.

Algoritmos, Tipos de aprendizado e Ferramentas

Os algoritmos de AM têm sido úteis na PDA para prever desempenhos, aprimorar o ensino e identificar métodos instrucionais adequados aos alunos (Belachew & Gobena, 2017; Ofori et al., 2020; Soni et al., 2018). O AM processa notas para prever o desempenho dos alunos, utilizando grandes conjuntos de dados e técnicas específicas (Belachew & Gobena, 2017; Ofori et al., 2020; Soni et al., 2018).

Tipos de aprendizado

O aprendizado supervisionado é uma técnica que estima os parâmetros do modelo usando análise de dados, aplicada em diversas áreas (Karthikeyan & Kavipriya, 2017). Grandes organizações têm utilizado essa técnica em suas operações, como Google, OpenAI, Meta, FedEx, Amazon, Mercado Livre e Walmart. O aprendizado não supervisionado, por sua vez, é um processo mais demorado e caro, onde o algoritmo precisa aprender a combinar os dados para obter informações relevantes (Abdi, 2016). Já o aprendizado por reforço treina a máquina para tomar decisões específicas, baseado em recompensas cumulativas (Abdi, 2016).

Software para aprendizagem de máquina

A aplicação de AM requer softwares especializados ou bibliotecas para processar grandes quantidades de dados. Existem ferramentas proprietárias pagas e de acesso livre, incluindo produtos de grandes empresas de tecnologia, como ilustrado na Tabela 1.

Fabricante	Solução	Descritivo
Microsoft	Azure Machine Learning	É uma plataforma de nuvem que permite que os desenvolvedores criem, treinem e implantem modelos de IA.
IBM	Watson Machine Learning	O <i>Watson Machine Learning</i> é um serviço de nuvem da IBM que usa dados para colocar em produção modelos de <i>machine learning</i> e <i>deep learning</i> .
Amazon	Amazon Machine Learning	É um serviço gerenciado para construir modelos de <i>Machine Learning</i> e gerar previsões.
Linguagem de programação Python	Python Software Foundation	O Python Software Foundation é uma organização dedicada ao avanço da tecnologia de código aberto relacionada à linguagem de programação Python com centenas de bibliotecas para AM.

Tabela 1. Ambientes e ferramentas para AM

Este trabalho usou a linguagem de programação Python com a biblioteca *SciKit-learn*.

A escolha de técnicas e algoritmos

Atualmente, o campo de AM oferece uma ampla variedade de algoritmos. A Tabela 2 apresenta uma lista concisa dessas técnicas e algoritmos, com suas respectivas abreviações ou siglas. Neste estudo, foram considerados apenas algoritmos de aprendizado supervisionado.

Técnica	#	Algoritmo	Sigla
Linear Models	1	Ridge regression	LRR
	2	Logistic Regression	LLR
	3	Linear Regression	LiR
Linear and Quadratic Discriminant Analysis	4	Dimensionality Reduction using Linear Discriminant Analysis	LDA
Support Vector Machines	5	Classification	SVC
	6	Regression	SVR
Stochastic Gradient Descent	7	Classification	SGDC
	8	Regression	SGDR
Nearest Neighbors	9	Nearest Neighbors Classification	NNC
	10	Nearest Neighbors Regression	NNR
Naive Bayes	11	Gaussian Naive Bayes	NBG
	12	Bernoulli Naive Bayes	NBB
Decision Trees	13	Classification	DTC

Técnica	#	Algoritmo	Sigla
	14	Regression	DTR
Ensemble methods	15	Gradient Tree Boosting (Classification)	GBC
	16	Gradient Tree Boosting (Regression)	GBR
	17	Random Forest (Classification)	RFC
	18	Random Forest (Regression)	RFR
Neural network models	19	Multi-layer Perceptron	KNP
	20	Classification	KNC
	21	Regression	KNR

Tabela 2. Agrupamento dos algoritmos que serão utilizados nesta pesquisa

Algoritmos de classificação e regressão

Os algoritmos de classificação e regressão são técnicas fundamentais em Aprendizado de Máquina. A classificação é usada para prever a classe de uma entidade com base em seus atributos, enquanto a regressão busca modelar relações entre variáveis dependentes (y) e independentes (x). Esses algoritmos são aplicados em uma variedade de áreas, como previsão de desempenho de alunos. A compreensão desses algoritmos permite ao pesquisador determinar quais variáveis serão usadas no processamento, sendo a variável dependente (y) conhecida como meta ou *target*.

Os problemas de Regressão buscam prever um valor numérico, por exemplo prever o preço de uma casa com base no endereço, ou valor de ações no mercado, ou as notas de alunos em uma disciplina, como neste estudo, em que o atributo meta é um valor numérico. (KUBAT, 2017, p. 3)

Neste trabalho, a variável y é a nota média final das disciplinas que o aluno concluiu, e as demais variáveis x são aquelas que influenciam a predição do desempenho, tais como: gênero, idade, tempo de curso etc.

Metodologia

Foi elaborado um delineamento estruturado seguindo as melhores práticas de metodologia de pesquisa, com critérios de qualidade. O modelo conceitual desse delineamento é apresentado na Figura 1, seguindo a ordem descrita abaixo. O primeiro item, Hipótese, não será detalhado nesta seção, pois já foi mencionado junto com as questões. O segundo item, Teoria, será descrito de forma breve nesta seção, mas não será aprofundado, sugerindo seu uso em futuros trabalhos que desejem discutir como melhorar o desempenho do aluno com base nas hipóteses.



Figura 1. Delineamento da metodologia de pesquisa deste trabalho

Teoria

Foram identificadas duas teorias: a Teoria da Expectativa da Motivação (TEM) e a Teoria da Dependência do Aprendizado (TDA), utilizadas na fundamentação e incremento da melhoria individual do aluno.

A teoria das expectativas da motivação (TEM) de Victor Vroom (1964) propõe que as pessoas se comportam de maneira a maximizar o prazer e minimizar a dor, optando por ações que resultem em melhores resultados ou recompensas. Essa teoria é aplicada aos estudantes e possui três variáveis principais: expectativa, instrumentalidade e valência. A expectativa refere-se à crença de que o esforço leva a um melhor desempenho. A instrumentalidade está relacionada à percepção de que o desempenho traz recompensas. Já a valência diz respeito ao valor atribuído às recompensas. Para motivar os alunos, é necessário fortalecer essas três variáveis. Uma forma eficaz de fazer isso é por meio do uso de selos ou *badges*, que podem ser físicos ou virtuais e servem como reconhecimento e incentivo ao esforço e ao desempenho dos alunos. Os selos estimulam os alunos a alcançar metas, desenvolver habilidades e valorizar as recompensas obtidas. Portanto, a motivação dos alunos pode ser representada pela equação: Força motivacional (FM) = Expectativa (E) x Instrumentalidade (I) x Valência (V).

A teoria da dependência do aprendizado (TDA) de B.F. Skinner (1971) explica como as pessoas aprendem novas habilidades e comportamentos, afirmando que o comportamento é controlado por estímulos externos. A teoria enfatiza o uso de reforços positivos para promover mudanças comportamentais desejadas. O reforço pode ser na forma de elogios, satisfação ou realização, e deve ser aplicado de maneira razoável e criativa. O estabelecimento de metas comportamentais claras e a seleção adequada de técnicas de reforço são essenciais para promover a mudança de comportamento. É importante evitar a punição, pois ela tem efeitos negativos e não cria um impacto permanente. Para que os reforços sejam eficazes, eles devem ser pontuais, claros, específicos e contínuos.

Estrutura da metodologia de pesquisa

A pesquisa é quantitativa, com dados numéricos, e permite generalizar os resultados para a população em estudo. O estudo utiliza os níveis descritivo e explicativo, com análises de correlação e regressão. É uma pesquisa aplicada, com propósito prático. O método de pesquisa é experimental, com controle de variáveis, e foram utilizadas diversas técnicas de coleta e análise de dados ao longo do trabalho (Gil, 2017; Lakatos & Marcondes, 2021; Vergara, 2010)

População e período

Esta pesquisa utilizou uma população de 900 registros de alunos de uma escola online de desenvolvimento de software sediada no Brasil. Os registros foram divididos em 70% para treinamento e 30% para testes em 21 algoritmos de AM, com foco em métricas de acurácia, precisão, revocação e F1-score. A análise ocorreu entre abril e dezembro de 2022 e o objetivo final foi selecionar o melhor algoritmo para prever a nota final de 249 alunos testados.

Análises e resultados

Acurácia

A acurácia é uma medida utilizada para avaliar a precisão de um modelo de aprendizado de máquina. Ela mede a taxa de acertos do modelo, ou seja, a proporção de previsões corretas em relação ao total de previsões. Quanto maior a acurácia, melhor o desempenho do modelo. A Tabela 3 mostra a acurácia dos algoritmos com destaque para os melhores resultados.

#	Algoritmo	Sigla	Acurácia
1	Ridge regression	LRR	0.9521

#	Algoritmo	Sigla	Acurácia
2	Logistic regression	LLR	0.9777
3	Linear Regression	LiR	0.9538
4	Dimensionality Reduction using Linear Discriminant Analysis	LDA	0.9444
5	Classification	SVC	0.9629
6	Regression	SVR	0.9658
7	Classification	SGDC	0.9185
8	Regression	SGDR	0.9517
9	Nearest Neighbors Classification	NNC	0.9555
10	Nearest Neighbors Regression	NNR	0.9586
11	Gaussian Naive Bayes	NBG	0.9185
12	Bernoulli Naive Bayes	NBB	0.6074
13	Classification	DTC	1.0
14	Regression	DTR	1.0
15	Gradient Tree Boosting (Classification)	GBC	1.0
16	Gradient Tree Boosting (Regression)	GBR	0.9999
17	Random Forest (Classification)	RFC	0.9962
18	Random Forest (Regression)	RFR	0.9878
19	Multi-layer Perceptron	KNP	0.8703
20	Classification	KNC	0.9592
21	Regression	KNR	0.9640

Tabela 3. Resultado da métrica acurácia dos algoritmos

Precisão e Revocação

Precisão é a proporção de instâncias corretamente classificadas como positivas em relação ao total de instâncias classificadas como positivas. Indica confiabilidade nas previsões positivas, com alta precisão significando poucos falsos positivos. Revocação é a proporção de instâncias positivas corretamente identificadas em relação ao total de instâncias positivas. Indica a capacidade de encontrar corretamente os casos positivos, com alta revocação significando poucos falsos negativos. Na Tabela 4, são apresentadas informações sobre a precisão e a revocação dos 21 algoritmos testados. As células com o caractere hífen, indicam que o algoritmo de regressão não conseguiu processar a precisão e revocação.

#	Algoritmo	Sigla	Acurácia	Precisão	Revocação
1	Ridge regression	LRR	0.9521	-	-
2	Logistic Regression	LLR	0.9777	-	-
3	Linear Regression	LiR	1.0	-	-
4	Dimensionality Reduction using Linear	LDA	0.9444	0.7458	0.9444
5	Classification	SVC	0.9629	0.7182	0.9629
6	Regression	SVR	0.9658	-	-
7	Classification	SGDC	0.9185	0.6411	0.9333
8	Regression	SGDR	0.9999	-	-
9	Nearest Neighbors Classification	NNC	0.9555	0.9099	0.9407

#	Algoritmo	Sigla	Acurácia	Precisão	Revocação
10	Nearest Neighbors Regression	NNR	0.9861	-	-
11	Gaussian Naive Bayes	NBG	0.9185	0.8433	0.9185
12	Bernoulli Naive Bayes	NBB	0.6074	0.3535	0.6074
13	Classification	DTC	1.0	1.0	1.0
14	Regression	DTR	0.9997	-	-
15	Gradient Tree Boosting (Classification)	GBC	1.0	1.0	1.0
16	Gradient Tree Boosting (Regression)	GBR	0.9999	-	-
17	Random Forest (Classification)	RFC	0.9962	0.9923	0.9962
18	Random Forest (Regression)	RFR	0.9927	-	-
19	Multi-layer Perceptron	KNP	0.8703	0.5613	0.8703
20	Classification	KNC	0.9592	0.8898	0.9592
21	Regression	KNR	0.9918	-	-

Tabela 4. Resultado da previsão e revocação dos algoritmos finalistas

F1-Score

A Tabela 5, apresenta o resultado da métrica F1-score. F1-score é uma métrica que combina a precisão e a revocação de um algoritmo de classificação. Ela é calculada como a média harmônica entre essas duas métricas, atribuindo peso igual para ambas.

A F1-score varia entre 0 e 1, sendo que um valor maior indica um melhor desempenho do algoritmo.

#	Algoritmo	Sigla	Acurácia	Precisão	Revocação	F1-Score
1	Ridge regression	LRR	0.9521	-	-	-
2	Logistic regression	LLR	0.9777	-	-	-
3	Linear Regression	LiR	1.0	-	-	-
4	Dimensionality Reduction using Linear	LDA	0.9444	0.7458	0.9444	0.94
5	Classification	SVC	0.9629	0.7182	0.9629	0.96
6	Regression	SVR	0.9658	-	-	-
7	Classification	SGDC	0.9185	0.6411	0.9333	0.94
8	Regression	SGDR	0.9999	-	-	-
9	Nearest Neighbors Classification	NNC	0.9555	0.9099	0.9407	0.95
10	Nearest Neighbors Regression	NNR	0.9861	-	-	-
11	Gaussian Naive Bayes	NBG	0.9185	0.8433	0.9185	0.96
12	Bernoulli Naive Bayes	NBB	0.6074	0.3535	0.6074	0.62

#	Algoritmo	Sigla	Acurácia	Precisão	Revocação	F1-Score
13	Classification	DTC	1.0	1.0	1.0	1.0
14	Regression	DTR	0.9997	-	-	-
15	Gradient Tree Boosting (Classification)	GBC	1.0	1.0	1.0	1.0
16	Gradient Tree Boosting (Regression)	GBR	0.9999	-	-	-
17	Random Forest (Classification)	RFC	0.9962	0.9923	0.9962	0.99
18	Random Forest (Regression)	RFR	0.9927	-	-	-
19	Multi-layer Perceptron	KNP	0.8703	0.5613	0.8703	0.89
20	Classification	KNC	0.9592	0.8898	0.9592	0.95
21	Regression	KNR	0.9918	-	-	-

Tabela 5. Resultado da F1-score

Sobre o resultado da Tabela 5, ressalta-se para problemas de **classificação**: DTC e GBC como excelentes candidatos, pois apresentaram os melhores valores de F1-Score na tabela.

Para problemas de **regressão**: LiR e GBR são ótimos candidatos, pois tiveram altos valores de acurácia na tabela.

O melhor algoritmo

A escolha do melhor algoritmo de Aprendizado de Máquina (AM) para a predição do desempenho do aluno depende de vários fatores, incluindo o tamanho e qualidade dos dados disponíveis, a natureza do problema, as saídas desejadas e a capacidade computacional disponível.

Em relação às saídas desejadas, se o objetivo é prever a média do aluno, é necessário utilizar um algoritmo de regressão, que é capaz de produzir uma saída numérica contínua. Por outro lado, se o objetivo é prever a classe de um determinado objeto, como "Aprovado", "Reprovado" ou "Recuperação", os algoritmos de classificação, que produzem saídas discretas, são mais adequados.

Os algoritmos de regressão foram selecionados para a finalização deste artigo, pois o objetivo foi apresentar um resultado igual à média do aluno, ou seja, números contínuos (com casas decimais).

Assim, pode-se verificar na Tabela 5 (acima) que os finalistas são LiR e GBR, respectivamente nesta ordem de melhor resultado.

Linear Regression (LiR)

A regressão linear simples (LiR) é limitada para prever o desempenho do aluno devido às suposições de linearidade, sensibilidade a *outliers* e incapacidade de capturar relações complexas. A LiR pressupõe uma relação linear entre as variáveis, mas as relações no mundo real podem ser mais complexas e não lineares. Além disso, *outliers* podem distorcer os resultados da LiR e a técnica não é capaz de modelar relações complexas entre variáveis.

Gradient Tree Boosting (GBR)

O GBR (Gradient Boosting Regression) é uma abordagem que supera as limitações da regressão linear. Ele não assume linearidade nas relações entre as variáveis, capturando relações complexas e não lineares. Além

disso, o GBR é menos sensível a outliers e lida com interações entre as variáveis. Essas características o tornam mais adequado para prever o desempenho do aluno em comparação com a regressão linear.

Testando o melhor algoritmo

O processamento foi realizado novamente, focando nos algoritmos finalistas, para analisar as diferenças de predição e explicar a escolha do melhor algoritmo. As previsões do algoritmo LiR mostraram imprecisão e não capturaram as complexidades das linearidades, como evidenciado na Figura 6, que apresenta os resultados das previsões dos três algoritmos finalistas em relação à média final do aluno.

	Media Final	Previsão LiR	Previsão GBR
70	0.210526	2.105263e-01	0.210879
827	0.210526	2.105263e-01	0.210879
231	0.000000	-3.330669e-16	0.000160
588	-0.010526	-1.052632e-02	-0.009867
39	0.000000	-3.330669e-16	0.000160
...
506	0.000000	-3.330669e-16	0.000160
653	0.000000	-3.330669e-16	0.000160
638	2.805263	2.805263e+00	2.816504
752	0.714211	7.142105e-01	0.714418
281	2.170000	2.170000e+00	2.170063

Tabela 6. Resultado das previsões do algoritmo DTR (amostragem de alguns alunos)

Além da fundamentação anterior sobre a inadequação do LiR, na prática, observa-se uma alta distância entre as previsões, o que gera dúvidas no desempenho do aluno. Por outro lado, o GBR, que combina várias árvores de decisão para lidar com dados não lineares e complexos, é escolhido como o melhor algoritmo para a previsão do desempenho do aluno, de acordo com este artigo.

Usando o ChatGPT para apoiar na melhoria do desempenho dos alunos

O modelo de linguagem GPT pode ser utilizado para melhorar o aprendizado de alunos em risco, mesmo sem conhecimento prévio da ementa. Através de questionamentos específicos, é possível obter sugestões pontuais de melhoria para alunos com desempenho abaixo do esperado em disciplinas específicas. Na Tabela 7, são apresentados os resultados de um questionamento e as considerações sobre o uso do GPT. As cinco primeiras colunas da tabela foram submetidas ao GPT para análise e obtenção de sugestões de melhoria.

Aluno	Disciplina	Média Final	Média Esperada	Previsão AM	Recomendação do ChatGPT
638	Sistemas Operacionais	2.80	3.50	2.81	Para ajudar o aluno 638 a melhorar sua nota de 2,81 para a média esperada

					<p>de 3,50, aqui estão algumas recomendações:</p> <p>Identifique as áreas de dificuldade na disciplina de Sistemas Operacionais.</p> <p>Revise o material relacionado à disciplina, como livros didáticos e recursos online.</p> <p>Participe de atividades extras, como grupos de estudo ou aulas de reforço.</p> <p>Pratique exercícios para consolidar o conhecimento e desenvolver habilidades.</p> <p>Busque ajuda adicional com professores, colegas ou profissionais da área.</p> <p>Gerencie o tempo e estabeleça um cronograma de estudos.</p>
--	--	--	--	--	---

Tabela 7. Submissão de dados ao GPT e solicitação de recomendação de melhoria

Pelo fato de o GPT não ter acesso à ementa, a recomendação acima é coerente com o contexto da disciplina, porém, se tratando de conteúdos específicos de cada escola a resposta do GPT poderia ser diferente.

Dessa forma, questionou-se ao GPT como sua recomendação seria alterada caso tivesse acesso prévio à ementa com o conteúdo completo da disciplina.

“O GPT pode ser mais específico em suas recomendações se tiver acesso antecipado à ementa da disciplina. Com base nos tópicos abordados, o modelo poderia sugerir livros, materiais de estudo, tutoriais ou exercícios práticos específicos para ajudar o aluno a melhorar seu desempenho.”;

“Além disso, eu também poderia sugerir outras estratégias de estudo, como fazer anotações, resumos, revisões frequentes e formação de grupos de estudo.” ChatGPT (2023).

Perguntou-se ao ChatGPT se seria capaz de indicar melhorias para milhares de alunos caso houvesse uma integração do sistema escolar com o chat.openai.com, passando a ementa de cada disciplina e o resultado das previsões de desempenho de alunos.

“Com a integração ao sistema escolar, seria possível gerar recomendações personalizadas de estudo para cada aluno, identificando as habilidades específicas que precisam ser melhoradas com base nas previsões de desempenho e no conteúdo da disciplina. Recomendações de leituras, exercícios e atividades práticas seriam geradas para atender às necessidades individuais de cada aluno, aumentando suas chances de sucesso acadêmico.” ChatGPT (2023)

Essa etapa do resultado foi surpreendente e provocante, entretanto, aumentaria necessidade de maiores explicações de testes feitos, assim, deixa-se aqui uma avenida de possibilidades para outros pesquisadores.



Respostas às questões e hipóteses

A seguir, as respostas às hipóteses declaradas anteriormente, como se segue.

Q1. Existe uma relação entre os dados educacionais disponíveis e o desempenho acadêmico dos alunos?

H1.2: Existe uma forte relação entre os dados educacionais disponíveis e o desempenho acadêmico dos alunos.

Q2. Os algoritmos de Aprendizagem de Máquina podem ser eficazes na previsão do desempenho dos alunos?

H2: Os algoritmos finalistas de Aprendizagem de Máquina deste artigo são capazes de prever de forma precisa o desempenho dos alunos.

Q3. O uso do GPT em conjunto com os algoritmos de Aprendizagem de Máquina melhora o desempenho do aluno?

H3: O uso do modelo GPT em conjunto com os algoritmos de Aprendizagem de Máquina melhora o desempenho do aluno individual.

Q4. Quais fatores ou características dos dados educacionais têm maior influência na previsão do desempenho do aluno?

H4.2: Certas características dos dados educacionais, como histórico acadêmico anterior e envolvimento em atividades extracurriculares, têm maior influência na previsão do desempenho do aluno.

Conclusão

Pesquisas recentes exploraram o uso de algoritmos de Aprendizado de Máquina (AM) para prever o desempenho dos alunos, mas nenhuma aplicou o AM com o GPT ao longo de nove meses. Embora o GPT seja uma ferramenta poderosa, sua precisão e confiabilidade devem ser avaliadas. O GPT pode gerar textos fluentes, porém, seus vieses e problemas de desigualdade devem ser considerados. É importante utilizá-lo para gerar hipóteses e insights, além de superar a limitação de relacionar os dados do aluno com os resultados do algoritmo por meio de técnicas avançadas em futuros trabalhos.

Este artigo não abordou o uso das teorias como forma de melhorar o desempenho do aluno, o que poderia ser útil para criar um constructo prático em conjunto com o GPT. Embora seja evidente a possibilidade de aplicar teorias para esse fim, estudos futuros devem se concentrar na melhoria do aprendizado do aluno nesse contexto desafiador.

É importante destacar que o uso dessas tecnologias não é determinante por si só. A qualidade e precisão dos resultados dependem da qualidade dos dados coletados, como já demonstrado. O GPT e outras ferramentas de PLN podem auxiliar na identificação de lacunas de conhecimento e áreas em que os alunos precisam melhorar, permitindo que os professores ajustem o ensino de forma mais precisa e individualizada. No entanto, é essencial lembrar que essas tecnologias não substituem o papel fundamental dos professores no processo de aprendizagem, mas sim os complementam.

Referências

- Abdi, A. 2016. *Three Types of Machine Learning Algorithms*. (<https://doi.org/10.13140/RG.2.2.26209.10088>).
- Ahmad S., S., El-Affendi, M. A., Anwar, M. S., and Iqbal, R. 2022. "Potential Future Directions in Optimization of Students' Performance Prediction System," *Computational Intelligence and Neuroscience* (2022), (Z. Hu, ed.), pp. 1–26. (<https://www.hindawi.com/journals/cin/2022/6864955/>) Acesso em: 06 jun. 2023.
- Alamri, R., and Alharbi, B. 2021. "Explainable Student Performance Prediction Models: A Systematic Review," *IEEE Access* (9), pp. 33132–33143. (<https://ieeexplore.ieee.org/document/9360749/>) Acesso em: 06 jun. 2023.
- Al-Shabandar, R., Hussain, A., Laws, A., Keight, R., Lunn, J., and Radi, N. 2017. "Machine Learning Approaches to Predict Learning Outcomes in Massive Open Online Courses," in *2017 International Joint Conference on Neural Networks (IJCNN)*, May, pp. 713–720. (<https://ieeexplore.ieee.org/document/7965922>) Acesso em: 06 jun. 2023.
- Belachew, E. B., and Gobena, F. A. 2017. "Student Performance Prediction Model Using Machine Learning Approach: The Case of Wolkite University," *International Journal of Advanced Research in Computer Science and Software Engineering* (7:2), pp. 46–50. (https://www.researchgate.net/publication/335691409_Student_Performance_Prediction_Model_using_Machine_Learning_Approach_The_Case_of_Wolkite_University) Acesso em: 06 jun. 2023.
- ChatGPT. 2023. "ChatGPT." (<https://chat.openai.com>) Acesso em: 06 jun. 2023.
- Cortex. (n.d.). "Maturidade digital nas empresas brasileiras: conheça os setores que mais investem em tecnologia." (<https://pages.cortex-intelligence.com/pesquisa-maturidade-digital-nas-empresas-brasileiras>) Acesso em: 06 jun. 2023.
- Gil, A. C. 2019. *Métodos e técnicas de pesquisa social*, ATLAS EDITORA.
- Kabakchieva, D. 2012. "Student Performance Prediction by Using Data Mining Classification Algorithms," *International Journal of Computer Science and Management Research* (1:4), pp. 686–690. (<https://www.semanticscholar.org/paper/Student-Performance-Prediction-by-Using-Data-Mining-Kabakchieva/1f817e320e0fofe8225821ce923f85980c1bdc9>) Acesso em: 06 jun. 2023.
- Karthikeyan, K., and Kavipriya, P. 2017. "On Improving Student Performance Prediction in Education Systems Using Enhanced Data Mining Techniques," *International Journal of Advanced Research in Computer Science and Software Engineering* (7:5), pp. 935–941. (https://www.researchgate.net/publication/318930599_On_Improving_Student_Performance_Prediction_in_Education_Systems_using_Enhanced_Data_Mining_Techniques) Acesso em: 06 jun. 2023.
- Kubat, M. 2017. *An Introduction to Machine Learning*, Cham: Springer International Publishing. (<http://link.springer.com/10.1007/978-3-319-63913-0>) Acesso em: 06 jun. 2023.
- Lakatos, E. M., and Marconi, M. de A. 2021. *Fundamentos de metodologia científica*, (9th ed.), Atlas.
- Obsie, E. Y., and Adem, S. A. 2018. "Prediction of Student Academic Performance Using Neural Network, Linear Regression and Support Vector Regression: A Case Study," *International Journal of Computer Applications* (180:40), pp. 39–42. (<https://www.semanticscholar.org/paper/Prediction-of-Student-Academic-Performance-using-A-Obsie-Adem/1c7e1e9478cefd58283c9844bb13f7d5a00e6146>) Acesso em: 06 jun. 2023.
- Ofori, F., Maina, E., and Gitonga, R. 2020. "Using Machine Learning Algorithms to Predict Students' Performance and Improve Learning Outcome: A Literature Based Review," *Journal of Information*



- and Technology* (4:1), pp. 33–55. (<https://stratfordjournals.org/journals/index.php/Journal-of-Information-and-Techn/article/view/480>) Acesso em: 06 jun. 2023.
- Pojon, M. 2017. “Using Machine Learning to Predict Student Performance,” University of Tampere - Faculty of Natural Sciences. (<https://www.semanticscholar.org/paper/Using-Machine-Learning-to-Predict-Student-Pojon/4a50fo917142467b1b3ce48d126378a808c4abfc>). Acesso em: 22 jan. 2023.
- Shovon, H. I., and Haque, M. 2012. “An Approach of Improving Student’s Academic Performance by Using K-Means Clustering Algorithm and Decision Tree,” *International Journal of Advanced Computer Science and Applications* (3:8), pp. 146–149. (<https://doi.org/10.14569/IJACSA.2012.030824>).
- Soni, A., Kumar, V., Kaur, R., and Hemavathi, D. 2018. *Predicting Student Performance Using Data Mining Techniques*. *International Journal of Pure and Applied Mathematics*, in (Vol. 119(12)), pp. 221–227. (<https://www.acadpubl.eu/hub/2018-119-12/articles/7/1591.pdf>) Acesso em: 22 jan. 2023.
- Vergara, S. C. 2010. *Métodos de pesquisa em administração*, Atlas.