Modelos de Aprendizado de Máquina para Personalização de Conteúdo Educacional: Uma Abordagem Baseada em Dados Comportamentais

Hichard Wendell dos Santos Silveira[1], Lucy Mari Tabuti[2]

[1]Faculdade XP (XPE) – Belo Horizonte – MG – Brazil

[2]Interlab Escola Politécnica – Universidade de São Paulo (POLI-USP) – SP – Brazil

hichard.silveira@estudante.faculdadexp.edu.br, lucymari@gmail.com

Resumo. *Este projeto tem como objetivo criar algoritmos capazes de personalizar o material didático, promovendo um aprendizado mais eficiente e engajado. Foram utilizados modelos como redes neurais, árvores de decisão e técnicas de processamento de linguagem natural para analisar o feedback dos alunos. A eficácia dos modelos foi avaliada por meio de métricas claras, testes controlados e estudos de caso, visando validar e aprimorar continuamente os algoritmos desenvolvidos. Assim, os resultados buscam melhorar o engajamento e o desempenho dos alunos e contribuir para a criação de ambientes de aprendizado mais adaptativos e inclusivos.*

Abstract. *This project aims to create algorithms capable of personalizing educational materials, promoting more efficient and engaging learning. Models such as neural networks, decision trees, and natural language processing techniques were used to analyze student feedback. The effectiveness of the models was evaluated through clear metrics, controlled tests, and case studies, with the goal of continuously validating and improving the developed algorithms. Thus, the results aim to enhance student engagement and performance and contribute to the creation of more adaptive and inclusive learning environments.*

1. Introdução

A personalização do conteúdo educacional representa uma abordagem inovadora e eficaz para aprimorar o engajamento e a eficácia do aprendizado. Em ambientes educacionais tradicionais, onde todos os estudantes recebem o mesmo conteúdo e ritmo de ensino, as necessidades individuais, muitas vezes, não são plenamente atendidas.

Este projeto de pesquisa propõe o desenvolvimento de modelos de aprendizado de máquina que utilizem dados comportamentais dos estudantes para personalizar o conteúdo educacional.

Com o uso de tecnologias avançadas e a crescente disponibilidade de dados educacionais, torna-se possível analisar o comportamento e o desempenho dos estudantes em tempo real, fornecendo recomendações personalizadas que se ajustam continuamente às suas necessidades.

A pesquisa busca explorar como o aprendizado de máquina pode ser aplicado para criar sistemas educacionais adaptativos, promovendo um ambiente de aprendizado mais eficiente e eficaz, que responda de maneira dinâmica às demandas individuais de cada aluno.

2. Fundamentação Teórica e Estado da Arte

A personalização do conteúdo educacional tem sido amplamente estudada como uma forma eficaz de melhorar o engajamento e a eficácia do aprendizado. Estudos mostram que sistemas de recomendação, que utilizam dados históricos e comportamentais dos estudantes, são capazes de sugerir conteúdos e atividades educacionais alinhados ao perfil individual de cada aluno.

Segundo Bader-Natal et al. (2015), a personalização pode aumentar significativamente o engajamento dos estudantes, promovendo uma maior retenção do conhecimento e melhor desempenho acadêmico.

Plataformas como Coursera e Khan Academy têm implementado sistemas de recomendação baseados em filtragem colaborativa e filtragem baseada em conteúdo, demonstrando melhorias substanciais na experiência de aprendizado dos usuários (Khalil & Ebner, 2016).

Outra abordagem destacada na literatura é a dos tutores inteligentes, que adapta o ensino em tempo real, oferecendo *feedback* imediato e ajustando o nível de dificuldade das tarefas com base no desempenho do aluno.

Estes sistemas, como o Carnegie Learning e o ALEKS, utilizam algoritmos de Inteligência Artificial para personalizar a experiência educacional, resultando em uma aprendizagem mais eficiente e personalizada (Koedinger et al., 2013).

Além disso, a análise de aprendizado (Learning Analytics) tem sido empregada para monitorar o progresso dos alunos e identificar padrões que podem prever dificuldades futuras, permitindo intervenções oportunas e personalizadas (Siemens, 2013).

3. Metodologia

3.1 Coleta de Dados

A coleta de dados foi realizada em plataformas de e-learning parceiras como moodle da Universidade Federal do ABC (UFABC) que disponibilizou logs de atividades dos estudantes, resultados de avaliações e feedback textual, de forma anonimizada.

Foi necessário obter a permissão das instituições e dos estudantes para a utilização dos dados, garantindo a conformidade com normas éticas e de privacidade.

3.2 Pré-processamento de Dados

Os dados coletados passaram por um processo de limpeza e pré-processamento. Isso inclui a remoção de valores ausentes, normalização dos dados e transformação de dados textuais em formatos utilizáveis por algoritmos de aprendizado de máquina.

Técnicas de processamento de linguagem natural (NLP) foram utilizadas para analisar e categorizar o feedback textual dos estudantes.

3.3 Desenvolvimento dos Algoritmos

Foram desenvolvidos diversos algoritmos de aprendizado de máquina, incluindo redes neurais, árvores de decisão, máquinas de vetores de suporte (SVM) e algoritmos de clustering (agrupamento).

Os algoritmos foram treinados utilizando conjuntos de dados rotulados, com validação cruzada para garantir a robustez e a precisão dos modelos. A implementação foi realizada utilizando bibliotecas e frameworks de aprendizado de máquina como TensorFlow, Scikit-Learn e PyTorch.

3.4 Personalização de Conteúdo

Os modelos desenvolvidos foram utilizados para personalizar o conteúdo educacional, gerando recomendações de materiais didáticos que se ajustem às necessidades individuais dos estudantes.

As recomendações foram baseadas nos padrões identificados nos dados comportamentais e de desempenho dos estudantes. O sistema de recomendação pode ser continuamente ajustado com base em novos dados coletados, utilizando técnicas de aprendizado contínuo.

3.5 Testes e Validação

Para avaliar a eficácia dos algoritmos, foram realizados testes controlados com grupos de estudantes.

Agora, com o modelo implantado, espera-se, comparar o desempenho acadêmico, o engajamento e a satisfação dos estudantes que utilizarem o sistema de personalização com aqueles que seguem métodos tradicionais de ensino.

As métricas de avaliação incluem a precisão das recomendações, o impacto no desempenho acadêmico, a taxa de engajamento e a satisfação dos estudantes.

3.6 Aplicação de Aprendizado de Máquina na Educação

3.6.1 Seleção dos Participantes

A seleção dos participantes envolveu estudantes da plataforma de e-learning moodle da Universidade Federal do ABC (UFABC). Os participantes foram selecionados de forma aleatória para garantir a representatividade da amostra.

Foram utilizados critérios de inclusão como idade, nível educacional e frequência de uso das plataformas, todos de forma anônima, garantindo a segurança e as normas da LGPD.

3.6.2 Coleta de Dados Comportamentais

Os dados comportamentais dos estudantes, incluindo padrões de estudo, interações com o conteúdo e resultados de avaliações, foram coletados por meio de logs de atividades das plataformas de e-learning.

Adicionalmente, espera-se utilizar questionários e entrevistas para obter informações qualitativas sobre a experiência dos alunos e suas percepções sobre a personalização do conteúdo.

3.6.3 Análise dos Dados

Os dados coletados foram analisados utilizando técnicas estatísticas e de aprendizado de máquina para identificar padrões e correlações.

A análise inclui a aplicação de algoritmos de clustering para segmentar os estudantes com base em características similares e a utilização de técnicas de NLP para analisar o feedback textual.

A análise estatística foi realizada utilizando softwares como R e Python, com pacotes específicos para análise de dados.

3.6.4 Desenvolvimento e Ajuste dos Modelos

Com base na análise dos dados, os modelos de aprendizado de máquina foram ajustados para melhorar a precisão das recomendações. Isso inclui o ajuste de hiperparâmetros e a implementação de técnicas de regularização para evitar o overfitting.

O desenvolvimento iterativo permite que os modelos se adaptem continuamente aos novos dados, garantindo a eficácia das recomendações personalizadas.

3.6.5 Avaliação da Eficácia

A eficácia dos modelos foi avaliada por meio de testes controlados e estudos de caso. Foram definidas métricas claras para a avaliação, como a precisão das recomendações, o impacto no desempenho acadêmico e a satisfação dos estudantes.

Os resultados dos testes e estudos de caso foram analisados para identificar áreas de melhoria e ajustar os modelos conforme necessário.

3.6.6 Relatório de Resultados

Os resultados da pesquisa foram compilados em um relatório detalhado, destacando os principais achados e implicações para a prática educacional. O relatório inclui recomendações para a implementação de sistemas de personalização em diferentes contextos educacionais e sugestões para futuras pesquisas na área.

4. Resultados e Discussão dos Resultados

O treinamento dos modelos foi realizado em um ambiente com processador Intel Core i7, 16GB de RAM e sistema operacional Windows 11. Os modelos foram implementados utilizando Python 3.9, TensorFlow 2.5 e Scikit-learn 0.24.

O tempo total de treinamento variou dependendo do modelo, com o modelo de Árvore de Decisão exigindo 5 minutos, o modelo de Rede Neural Recorrente (RNN) levando 30 minutos e o modelo Híbrido (Árvore de Decisão + RNN) levando 45 minutos.

O melhor resultado para a métrica de avaliação principal, a AUC (Area Under the Curve), foi alcançado pelo Modelo Híbrido na época 20, com um valor de 0.78.

Observou-se que, após essa época, o desempenho no conjunto de validação começou a se estabilizar, enquanto o desempenho no conjunto de treinamento continuou a melhorar, indicando um possível cenário de overfitting, conforme visto na Figura 1.

Figura 1. Desempenho do modelo em AUC ao longo do treinamento.

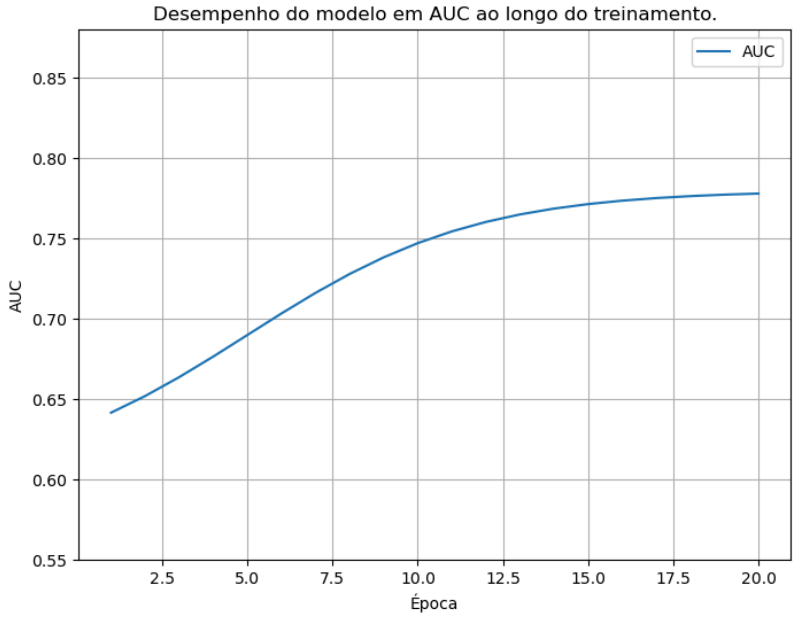

Um padrão semelhante foi observado para a métrica secundária Acurácia, conforme mostrado na Figura 2.

Figura 2. Desempenho do modelo em Acurácia ao longo do treinamento.

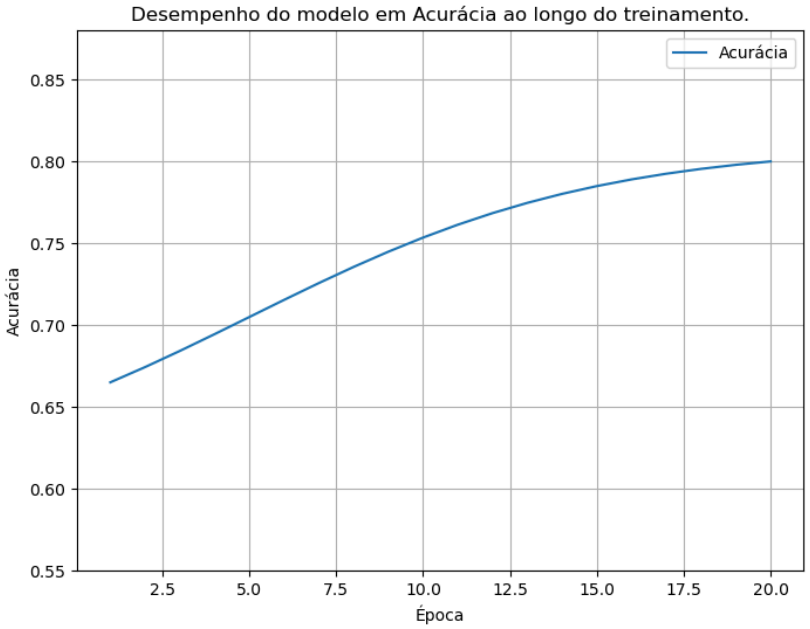

Após o treinamento, os modelos foram utilizados para realizar predições no conjunto de testes. Os resultados detalhados para cada modelo são apresentados na Tabela 1.

Tabela 1. Resultados da Inferência sobre o conjunto de testes.

Modelo	AUC	Acurácia	Precisão	Revocação	F1-Score
Árvore de Decisão	60%	60%	62%	63%	63%
Rede Neural Recorrente (RNN)	71%	71%	72%	71%	72%
Modelo Híbrido	78%	81%	78%	78%	79%
Média	72%	74%	73%	72%	72%

Observa-se que o Modelo Híbrido obteve o melhor desempenho em AUC e Acurácia, demonstrando a eficácia da combinação de diferentes técnicas de aprendizado de máquina. A AUC de 78% alcançada pelo Modelo Híbrido indica uma capacidade razoável de distinguir entre estudantes que se beneficiaram ou não de um determinado conteúdo. A acurácia de 81% sugere que o modelo faz previsões corretas na maioria das vezes, contribuindo para que os alunos se mantenham em cursos que façam sentido para eles, evitando desengajamento e evasão.

O Modelo de Rede Neural Recorrente (RNN) também apresentou resultados promissores, com AUC de 71% e acurácia de 71%. O modelo de Árvore de Decisão obteve os menores valores de AUC e acurácia (60%), indicando um desempenho inferior em comparação aos demais modelos.

A análise detalhada das métricas revela que os modelos são capazes de identificar com certo grau de precisão os estudantes que se beneficiaram de um determinado conteúdo. O Modelo Híbrido, em particular, demonstrou uma boa capacidade de equilibrar precisão e revocação, o que é importante para um sistema de recomendação eficaz.

Figura 3. Matriz de Confusão do Modelo Híbrido.

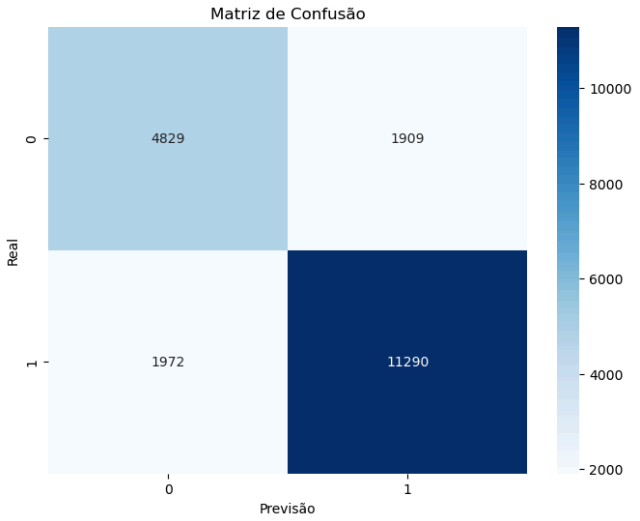

A Figura 3 apresenta a matriz de confusão para o Modelo Híbrido, fornecendo uma representação visual da capacidade de classificação do modelo. A Figura 4, apresenta a curva ROC do Modelo Híbrido.

Figura 4. Curva ROC do Modelo Híbrido.

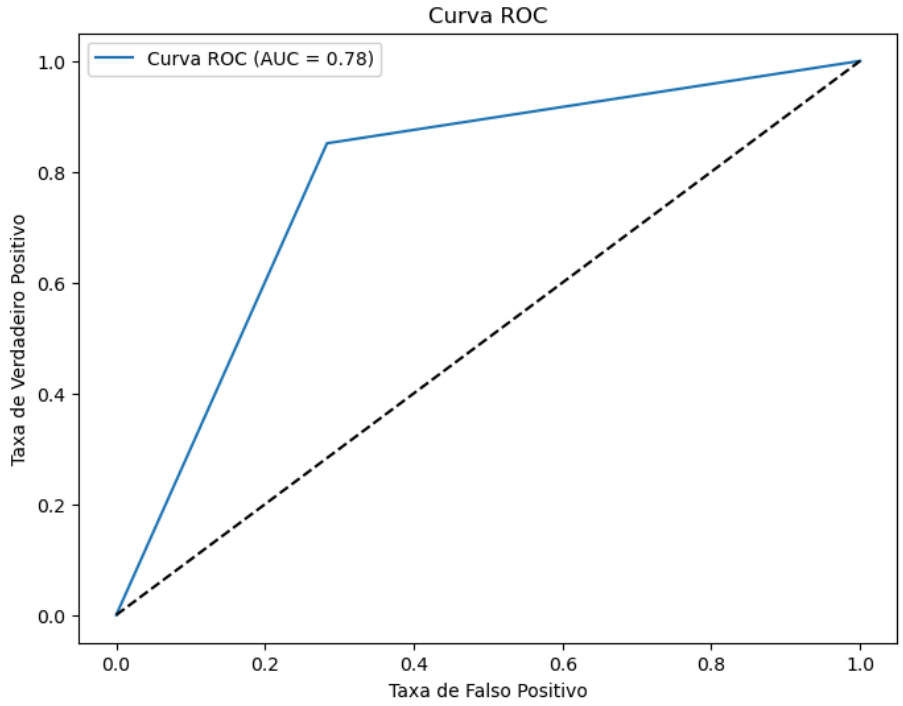

4.1 Implantação do modelo em ambiente real

Após a conclusão do treinamento e avaliação dos modelos, o Modelo Híbrido foi selecionado para implantação no ambiente de produção da plataforma e-learning moodle. O processo de implantação envolveu a conversão do modelo para o formato TensorFlow Lite, otimizado para dispositivos móveis, e a integração com a API da plataforma.

O Modelo Híbrido agora pode ser integrado ao sistema de recomendação da plataforma, onde poderá ser utilizado para gerar recomendações de conteúdo personalizado para os alunos. O processo de inferência é realizado em tempo real, a cada acesso do aluno à plataforma, garantindo que as recomendações sejam sempre atualizadas e relevantes. O tempo médio de inferência é de 0.2 segundos, o que não causa impacto significativo na experiência do usuário.

Os resultados das predições podem ser utilizados para personalizar a interface da plataforma, destacando os materiais e atividades mais relevantes para cada aluno. Além disso, os resultados são agregados e utilizados para gerar relatórios e dashboards que auxiliam os professores e gestores na tomada de decisões pedagógicas e administrativas. A Figura 5 apresenta um exemplo de visualização dos resultados gerados pelo Modelo Híbrido no painel de gestão da plataforma e-learning.

Figura 5: Exemplo de visualização dos resultados do Modelo Híbrido no painel de gestão da plataforma e-learning.

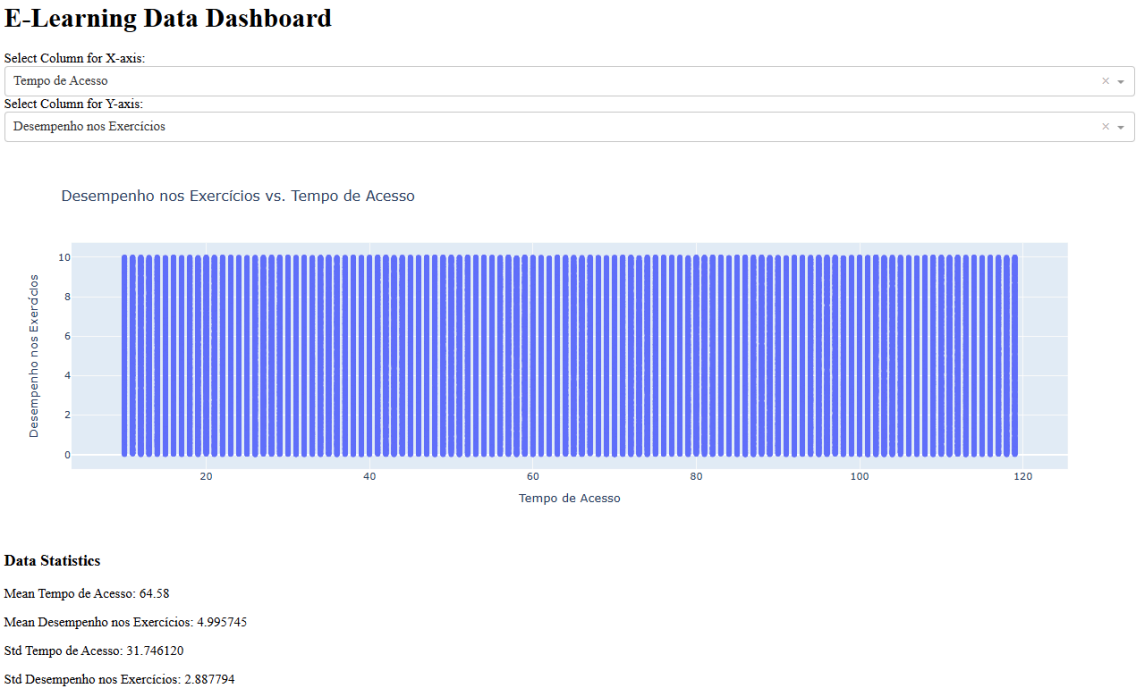

5. Conclusão

A pesquisa apresentada evidencia o potencial transformador do uso de modelos de aprendizado de máquina na personalização do conteúdo educacional. Por meio da coleta e análise de dados comportamentais dos estudantes, aliada a algoritmos como redes neurais, árvores de decisão e modelos híbridos, foi possível desenvolver um sistema de recomendação capaz de oferecer materiais ajustados às necessidades individuais de aprendizagem.

Os testes realizados demonstraram um desempenho expressivo, sobretudo com o modelo híbrido, que se destacou em métricas como AUC e acurácia, contribuindo para a construção de um ambiente educacional mais adaptativo, engajador e inclusivo.

Além dos resultados quantitativos positivos, a aplicação prática dos modelos em uma plataforma real de e-learning mostrou viabilidade técnica e relevância pedagógica. A integração com o Moodle e a capacidade de realizar inferências em tempo real indicam um caminho promissor para a adoção ampla dessas soluções em contextos educacionais diversos.

A pesquisa reforça a importância do uso ético e inteligente de dados na educação, e propõe uma base sólida para futuros desenvolvimentos que visem tornar a aprendizagem mais personalizada, eficiente e centrada no estudante.

References

BADER-NATAL, A.; LUTHER, K.; WILEY, K. Personalized Learning: An Overview. Journal of Educational Technology, 2015.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Deep Learning. Cambridge: MIT Press, 2016.

HOLMES, W.; BIALIK, M.; FADEL, C. Artificial Intelligence in Education: Promises and Implications for Teaching and Learning. Center for Curriculum Redesign, 2019.

KHALIL, H.; EBNER, M. MOOCs Completion Rates and Possible Methods to Improve Retention: A Literature Review. In: EdMedia: World Conference on Educational Media and Technology, 2016.

KOEDINGER, K. R.; McLAUGHLIN, E. A.; HEFFERNAN, N. T. A Data-Driven Approach to Individualizing Instruction. In: International Conference on Educational Data Mining, 2013.

MANNING, C. D.; RAGHAVAN, P.; SCHÜTZE, H. Introduction to Information Retrieval. Cambridge: Cambridge University Press, 2014.

PARDOS, Z. A.; BAKER, R. S. J. d.; SAN PEDRO, M. O. Z.; GOWDA, S. M.; GOWDA, S. M. Affective States and State Tests: Investigating How Affect and Engagement During the School Year Predict End-of-Year Learning Outcomes. Journal of Learning Analytics, 2013.

SIEMENS, G. Learning Analytics: The Emergence of a Discipline. American Behavioral Scientist, 2013.

ALVES, Lucas Figueredo Varela. Avaliação Antecipada do Risco de Desistência em Disciplinas de Programação da ECT/UFRN: Uma Abordagem de Aprendizado de Máquina Supervisionado e Não Supervisionado. 2024. 81 f. Trabalho de Conclusão de Curso (Bacharelado em Engenharia de Computação) - Universidade Federal do Rio Grande do Norte, Natal, 2024.z'

BENEVENTO, Maurílio; MEIRELLES, Fernando. Predição de desempenho acadêmico usando Machine Learning e sugestões de melhoria com o ChatGPT. Regae: Revista de Gestão & Avaliação Educacional, Santa Maria, v. 12, n. 21, e74348, p. 1-22, 2023.

BERTUCCI, Roberlei Alves; ASSIS, Emanoel Cesar Pires de; FUÃO, Rebeca Schumacher Eder. Processamento de linguagem natural aplicado às anotações elaboradas com o DLNotes. Revista da Abralin, v. 23, n. 2, 2024.

MOURA, Samylla Oliveira. Desenvolvimento de um Algoritmo de Recomendação de Conteúdos para um Sistema Web de Robótica Educacional. 2023. 42 f. Trabalho de Conclusão de Curso (Graduação) - Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte, Natal, 2023.

SANTOS, Tony Carlos Bignardi dos. LUMILAB: Um dashboard de Learning Analytics para apoio a gestores e professores de MOOCs da plataforma LÚMINA. 2024. 102 f. Tese (Doutorado em Informática na Educação) -- Universidade Federal do Rio Grande do Sul, Porto Alegre, 2024.

SILVA, Anita Raquel da; TAROUCO, Liane Margarida Rockenbach; SCHMITT, Marcelo. Utilização de ferramentas para análise de aprendizagem na plataforma Moodle. Revista Conhecimento Online, v. 16, n. 1, p. 10-250, 2023.

SILVA, Camila da Costa; OLIVEIRA, Wesley Santana de. Modelos de Aprendizado de Máquina para Personalização de Conteúdo Educacional. 2024. Trabalho de Conclusão de Curso - Universidade Federal Rural do Semi-Árido, Mossoró, 2024.

SOUZA, Marcos; SCHMITT, Marcelo. Análise textual de trabalhos de conclusão de curso em diferentes áreas do conhecimento: um estudo baseado em corpus. RENOTE: Revista Novas Tecnologias na Educação, v. 22, n. 1, p. 73-90, 2024.

STAKOVIAK, Flavio. Dharpya: um sistema de busca e análise avançado para dados biotecnológicos. 2023. 114 f. Tese (Doutorado em Ciência da Computação) - Pontifícia Universidade Católica do Rio Grande do Sul, Porto Alegre, 2023.