

***Machine Learning* para a identificação de barreiras cognitivas em estudantes de Engenharia de Software**

Denise Rísia Andrade Carvalho¹, Rossana M. de Castro Andrade¹

¹Universidade Federal do Ceará - (UFC)

deniserisia@alu.ufc.br, rossana@ufc.br

Resumo. *Esta pesquisa investiga como dados de interação e desempenho do aluno, coletados em uma plataforma gamificada, podem ser analisados por modelos de Machine Learning para identificar barreiras cognitivas e apoiar intervenções pedagógicas adaptadas. Vídeo: <https://youtu.be/JMK8fP5wwaQ>*

1. Introdução

A qualidade do software influencia diretamente na confiabilidade dos resultados obtidos com seu uso e está relacionada às práticas adotadas para desenvolvê-lo; portanto, formar engenheiros de software com base teórica e prática adequada é condição para produzir software de qualidade [Barcellos et al. 2024]. Nesse cenário, o ensino de Engenharia de Software (ES) ganha espaço como um campo de conhecimento autônomo e com desafios educacionais próprios [Ferreira et al. 2018]. A incorporação de tópicos emergentes ao currículo de ES, alinhada a diretrizes ACM/IEEE, tem sido apontada como estratégia para responder a desafios atuais da ES, como sustentabilidade e solidez no desenvolvimento de software [Mishra e Mishra 2021].

Para enfrentar tais desafios, estratégias inovadoras baseadas em tecnologias educacionais têm se mostrado promissoras, destacando-se plataformas web e formatos online/híbridos. Revisões sistemáticas recentes indicam que a efetividade do ensino online, ou com suporte de recursos online, no ensino superior depende de fatores como infraestrutura, desenho instrucional e qualidade das interações [Meng et al., 2024]. Nesse cenário, um dos métodos é a gamificação que pode promover maior engajamento ao incorporar elementos como pontos, rankings e *feedback* em tempo real [Lelli et al. 2024]. Além disso, mecanismos de monitoramento e análise de dados de interação permitem acompanhar desempenho, engajamento e padrões de uso, apoiando intervenções pedagógicas baseadas em evidências [Ferguson 2012].

Estudos recentes em *learning analytics* e mineração de dados educacionais mostram que modelos de *machine learning* (ML) podem oferecer um grau superior de personalização, aprendendo com o uso do aluno. Eles podem identificar, em escala, padrões e perfis de aprendizagem e prever desempenho e riscos acadêmicos, desde que o ambiente seja bem instrumentado e os indicadores estejam alinhados aos objetivos educacionais [Silva et al. 2022]. Contudo, ainda é desafiador converter essas predições

em intervenções pedagógicas úteis e válidas, especialmente no contexto de Educação em Computação e em disciplinas de Engenharia de Software [Moraes et al. 2022].

2. Proposta de Investigação

O ensino de ES exige integrar fundamentos técnicos e competências práticas, indo além do modelo expositivo tradicional. Apesar dos avanços metodológicos, a rápida evolução de tecnologias e abordagens dificulta o acompanhamento individual. Nesse sentido, [Pinheiro 2025] aponta que a tecnologia educacional deve apoiar o docente no monitoramento fino das dificuldades e necessidades de cada estudante.

Esta pesquisa investiga como dados de interação e desempenho em uma plataforma para disciplinas de ES podem ser analisados por modelos de ML para identificar barreiras cognitivas e subsidiar recomendações adaptativas. Revisões recentes indicam que ML ajuda a caracterizar perfis estudantis e atributos associados ao desempenho, apoiando análises preditivas e explicativas [Issah et al. 2023]. Diante desse cenário, fez-se a proposta do desenvolvimento de um protótipo de uma plataforma no qual: (i) o estudante acessa um simulador gamificado, seleciona a disciplina e responde inicialmente questões para estimar seu nível; (ii) a plataforma coleta métricas como padrões de erro, tempo de resolução, tentativas e navegação; (iii) modelos de ML identificam padrões, perfis e riscos, atualizando o perfil do estudante; e (iv) com base nesse perfil, o sistema recomenda intervenções, conforme a Figura 1.




Figura 1. Arquitetura do Fluxo do Protótipo

Dessa forma, a investigação busca responder: Como dados de interação e desempenho em uma plataforma digital para disciplinas de ES podem ser usados por modelos de ML para identificar barreiras cognitivas e recomendar intervenções? E qual o seu impacto sobre a adesão, experiência do usuário e o resultado acadêmico do aluno?

Como contribuição, pretende-se (i) definir indicadores para identificar barreiras cognitivas, (ii) implementar recomendações adaptativas com justificativas para estudantes e docentes e (iii) avaliar o impacto das intervenções em desempenho, engajamento e experiência do usuário. Como resultado, pretende-se gerar evidências sobre a efetividade do ML e produzir lições sobre validade, explicabilidade e limites de recomendações adaptativas em Educação em Computação.

Referências

- BARCELLOS, Monalessa P.; SOUZA, Vítor E. Silva; COSTA, Patrícia Dockhorn; AGUIAR, Camila Zacché de. Using Extension Projects to Improve Software Engineering Education and Software Quality: The Experience of the “Ricardo de Almeida Falbo” Software Engineering Practices Laboratory. In: Brazilian Symposium on Software Quality (SBQS 2024). DOI: 10.1145/3701625.3701680
- FERREIRA, Thaís; VIANA, Davi; FERNANDES, Juliana Costa; SANTOS, Rodrigo Pereira dos. Identifying emerging topics and difficulties in software engineering education in Brazil. In: (SBES), 32., 2018, São Carlos. ACM, 2018. p. 230–239.
- MISHRA, Alok; MISHRA, Deepti. Sustainable software engineering: curriculum development based on ACM/IEEE guidelines. In: CALERO, Coral; MORAGA, M^a Ángeles; PIATTINI, Mario (org.). *Software sustainability*. Cham: Springer, 2021. p. 269–285.
- MENG, Wentao; YU, Lei; LIU, Chen; PAN, Nengchao; PANG, Xiawen; ZHU, Yunyun. *A systematic review of the effectiveness of online learning in higher education during the COVID-19 pandemic period*. *Frontiers in Education*, v. 8, 2023. Publicado em: 17 jan. 2024. DOI: 10.3389/feduc.2023.1334153.
- LELLI, Valéria; SANTOS, Ismayle; BRANCO, Karina. Uso de Práticas Gamificadas no Ensino de Verificação e Validação de Software. In: SIMPÓSIO BRASILEIRO DE EDUCAÇÃO EM COMPUTAÇÃO (EDUCOMP), 4., 2024, São Paulo, SP. 2024. p. 184–192. DOI: 10.5753/educomp.2024.237525.
- FERGUSON, Rebecca. Learning analytics: drivers, developments and challenges. *International Journal of Technology Enhanced Learning*, v. 4, n. 5/6, p. 304–317, 2012. DOI: 10.1504/IJTEL.2012.051816.
- SILVA, Bruno João da; PIMENTEL, Edson Pinheiro; BOTELHO, Wagner Tanaka. Predição de Desempenho de Estudantes: Uma Revisão Sistemática de Literatura. In: SIMPÓSIO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO (SBIE), 33., 2022. Porto Alegre. DOI: 10.5753/sbie.2022.225093.
- MORAES, Laura O.; DELGADO, Carla A. D. M.; FREIRE, João Pedro; PEDREIRA, Carlos Eduardo. Machine Teaching: uma ferramenta didática e de análise de dados para suporte a cursos introdutórios de programação. In: SIMPÓSIO BRASILEIRO DE EDUCAÇÃO EM COMPUTAÇÃO (EDUCOMP), 2022. p. 213–223. DOI: 10.5753/educomp.2022.19216.
- PINHEIRO, Tânia Saraiva de Melo; PINHEIRO, Ana Cláudia Mendonça. Toda era é uma era tecnológica: um referencial de padrões evolutivos para a compreensão do continuum de inovações educacionais. *Et al – Education & Technology for Advancing Learning*, Rio de Janeiro, v. 1, n. 1, 2025. Disponível em: <https://www.et-al.com.br/index.php/etal/article/view/13>. Acesso em: 28 jan. 2026.
- ISSAH, Iddrisu; APPIAH, Obed; APPIAHENE, Peter; INUSAH, Fuseini. A systematic review of the literature on machine learning application of determining the attributes influencing academic performance. *Decision Analytics Journal*, v. 7, p. 100204, jun. 2023. DOI: 10.1016/j.dajour.2023.100204