

DO TRADICIONAL AO ADAPTATIVO: A METODOLOGIA FAR-M NO ENSINO SUPERIOR DE TECNOLOGIA

FROM TRADITIONAL TO ADAPTIVE: THE FAR-M METHODOLOGY IN HIGHER TECHNOLOGY EDUCATION

Tiago Augusto Orcajo Demay Cordeiro ^{1, i}
Hebert de Oliveira Silva^{2, ii}
Jessica Franzon Cruz do Espírito Santo ^{3, iii}
Caique Zaneti Kirilo^{4, iv}
Arthur Gustavo de Araujo Ferreira ^{5, v}
Vivian de Oliveira Preto ^{6, vi}
Emerson Costa Santos^{7, vii}

RESUMO

O ensino superior em tecnologia exige metodologias que superem os limites das práticas tradicionais, pouco eficazes para turmas numerosas e para o desenvolvimento equilibrado de competências técnicas e socioemocionais. Este artigo apresenta a metodologia FAR-M (Feedback, Auto-grader, Randomização – MSeP), concebida como evolução da MSeP para o ensino superior. A proposta combina feedback imediato, avaliação automatizada e randomização de atividades como estratégias para promover aprendizagem ativa, personalizada e escalável. A implementação inicial ocorre em duas turmas de graduação em Segurança Cibernética e Ciência de Dados (cerca de 50 alunos cada), configurando o campo de aplicação da metodologia. As contribuições esperadas incluem maior engajamento discente, retenção de conhecimento e redução da evasão, além de apoiar o docente no papel de mediador do processo formativo.

Palavras-chave: Ensino Superior; Metodologias Ativas; Avaliação Automatizada, MSeP.

ABSTRACT

Higher education in technology requires methodologies that overcome the limitations of traditional practices, which are often ineffective in large classes and insufficient for the balanced development of technical and socioemotional competencies. This article presents the FAR-M methodology (Feedback, Auto-grader, Randomization – MSeP), conceived as an evolution of the MSeP for higher education. The proposal combines immediate feedback, automated assessment, and randomized activities as strategies to foster active, personalized, and scalable learning. The initial implementation takes place in two undergraduate cohorts in Cybersecurity and Data Science (around 50

¹ Mestre e Docente de Segurança Cibernética na Faculdade SENAI-SP, e-mail: tiago.demay@sp.senai.br.

² Doutorando e Docente de Segurança Cibernética na Faculdade SENAI-SP, e-mail: hebert.oliveira@sp.senai.br.

³ Mestranda e Docente de Ciência de Dados na Faculdade SENAI-SP, e-mail: jessica.santo@sp.senai.br.

⁴ Doutorando e Docente de Ciência de Dados na Faculdade SENAI-SP, e-mail: caique.zaneti@sp.senai.br.

⁵ Doutor e Docente de Ciência de Dados na Faculdade SENAI-SP, e-mail: arthur.ferreira@sp.senai.br.

⁶ Mestre e Coordenadora dos cursos superiores de Tecnologia em Ciência de Dados e Segurança Cibernética da Faculdade SENAI-SP, e-mail: vpreto@sp.senai.br.

⁷ Doutorando e Diretor do Campus Paulo Antônio Skaf, e-mail: emerson@sp.senai.br.

students each), serving as the pilot context for the methodology. The expected contributions include greater student engagement, improved knowledge retention, and reduced dropout rates, while supporting instructors in their role as learning mediators.

Keywords: Higher Education; Active Methodologies; Automated Assessment; MSeP.

1 INTRODUÇÃO

O ensino superior em cursos de tecnologia enfrenta o desafio de equilibrar o desenvolvimento de competências técnicas e socioemocionais em um cenário de rápidas transformações tecnológicas e alta demanda por profissionais adaptativos. Modelos tradicionais de ensino, baseados em aulas expositivas, avaliações pontuais e correções manuais, revelam-se insuficientes para atender às necessidades de acompanhamento individualizado e para garantir escalabilidade em turmas numerosas. Esse descompasso compromete tanto a qualidade da formação quanto a permanência e o engajamento dos estudantes.

No contexto brasileiro, o Projeto Pedagógico de Curso (PPC) da área de Segurança Cibernética, por exemplo, estabelece como princípio norteador a formação por competências, integrando capacidades básicas, técnicas e socioemocionais. Para operacionalizar esse princípio, o SENAI adota a Metodologia de Educação Profissional -MSeP (SENAI, 2019). Essa metodologia valoriza a aprendizagem ativa, a integração entre teoria e prática e a utilização de situações de ensino contextualizadas.

Apesar dos avanços, observa-se que a prática docente ainda carece de mecanismos tecnológicos que ofereçam e promovam uma avaliação contínua, individualizada e motivadora. Paralelamente, experiências internacionais recentes demonstram os benefícios de plataformas de avaliação automatizada, que incorporam feedback instantâneo e questões randomizadas. Tais práticas reforçam que a combinação de tecnologia e metodologias ativas pode reduzir desigualdades de desempenho, melhorar a retenção do conhecimento e apoiar o desenvolvimento socioemocional dos estudantes. Diante desse cenário, este artigo apresenta a metodologia FAR-M (Feedback, Auto-grader, Randomização – MSeP), concebida como uma evolução da MSeP ao integrar recursos digitais de avaliação automatizada. A proposta é demonstrar como a aplicação do FAR-M contribui para potencializar a aprendizagem ativa.

Problema de pesquisa

Apesar da consolidação de metodologias ativas no ensino superior e dos avanços alcançados pela MSeP no ensino técnico, ainda são limitadas as iniciativas que exploram sua adaptação para turmas de graduação em tecnologia. Surge, portanto, a seguinte questão: como a integração de feedback imediato, autoavaliação por meio de auto-graders e randomização de atividades pode fortalecer a aprendizagem ativa, reduzir a evasão e promover o desenvolvimento de competências em cursos superiores de tecnologia?

Objetivo

O objetivo deste trabalho é apresentar a metodologia FAR-M e discutir suas contribuições esperadas no ensino superior em Computação e áreas afins. Para isso, busca-se descrever a evolução da MSeP para o modelo FAR-M, contextualizar sua aplicação piloto em cursos de Segurança Cibernética e Ciência de Dados, projetar os

impactos esperados em termos de engajamento, personalização da aprendizagem e retenção discente, além de discutir o potencial de replicação da proposta em diferentes cursos de tecnologia.

Justificativa

A proposta da metodologia FAR-M responde à necessidade urgente de superar os limites das avaliações tradicionais no ensino superior, que muitas vezes desestimulam os estudantes e dificultam o acompanhamento contínuo de competências. Ao incorporar feedback imediato, atividades randomizadas e avaliação automatizada, o FAR-M amplia as possibilidades de engajamento e de personalização da experiência de aprendizagem, sem perder de vista a escalabilidade necessária em turmas numerosas. Espera-se que essa abordagem contribua para a formação de profissionais mais autônomos, resilientes e preparados para lidar com cenários complexos. Além disso, a metodologia oferece um modelo pedagógico inovador e replicável, alinhado aos PPCs e às demandas contemporâneas da formação tecnológica no Brasil.

2 REVISÃO DE LITERATURA

A integração de tecnologias digitais em metodologias ativas mostra-se promissora para enfrentar os desafios do ensino tecnológico. Esta revisão sintetiza evidências internacionais que fundamentam a proposta FAR-M. Hare et al. (2024) demonstraram que a combinação de sistemas tutores inteligentes com gamificação no projeto Gridlock resultou em maior engajamento e melhoria significativa no desempenho de estudantes de engenharia, utilizando aprendizado por reforço para adaptar conteúdo e suporte considerando desempenho e estado emocional dos estudantes. Jaison et al. (2024) investigaram os impactos do software inteligente no ensino de desenho técnico e, embora não tenham encontrado diferenças significativas na motivação, os estudantes relataram preferir o feedback imediato para desenvolvimento de habilidades técnicas complexas. Edwards et al. (2024) implementaram *specifications grading* em cursos de computação, substituindo pontos por sistema EMRN (Excelente, Atende Expectativas, Precisa de Revisão, Não Avaliável) com retentativas ilimitadas, e os resultados mostraram redução no estresse e eliminação de negociações por pontos, apesar da resistência inicial dos estudantes à ausência do tradicional "efeito de média". Combefis (2024) propôs avaliação contínua por competências como serviço de apoio ao sucesso e, em curso para adultos trabalhadores, 16 dos 18 estudantes obtiveram êxito, com pesquisas qualitativas indicando que o sistema forneceu clareza sobre o progresso e motivação para aprendizagem. Gao et al. (2024) investigaram modelos de linguagem para correção automática em engenharia mecânica e abordagens como PromCSE atingiram escores F1 superiores a 0,94 em avaliações binárias, porém com taxas significativas de falsos positivos, indicando necessidade de refinamento para contextos técnicos específicos. A eficácia do feedback imediato depende de plataformas que o viabilizem tecnicamente e, nesse contexto, laboratórios remotos surgem como ambientes privilegiados para implementar essa correção rápida. Ferrao et al. (2023) demonstraram que a identificação e correção imediata de erros comuns em um curso intensivo de linguagem C permitiu que os estudantes aplicassem estruturas avançadas competentemente em projetos subsequentes, reforçando a

necessidade de ambientes acessíveis e flexíveis. Assim, as evidências revisadas sustentam que a integração de personalização, avaliação contínua, feedback imediato e ambientes flexíveis potencializa a aprendizagem em disciplinas técnicas, sendo a proposta FAR-M uma síntese desses elementos comprovados, integrados ao framework MSeP e adaptados ao contexto da formação profissional tecnológica brasileira e ao princípio da formação por competências estabelecido nos PPCs de Segurança Cibernética (SENAI, 2019).

3 METODOLOGIA

A metodologia FAR-M (Feedback, Auto-grader, Randomização – MSeP) foi concebida como evolução da MSeP, integrando recursos digitais para avaliação contínua, feedback imediato e escalabilidade em turmas grandes. O modelo combina três eixos principais: i) feedback imediato, que permite ciclos rápidos de aprendizagem e correção; ii) auto-graders, que automatizam a avaliação e liberam o docente para mediação pedagógica; e iii) randomização de atividades, que fortalece a autonomia discente e garante integridade acadêmica.

A aplicação piloto ocorre em duas turmas de aproximadamente 50 estudantes, nos cursos de Segurança Cibernética e Ciência de Dados, em disciplinas práticas com uma plataforma que fornece a dinâmica de questões randomizadas, laboratórios e correções automáticas, a análise concentra-se nas contribuições esperadas, considerando tanto o impacto na aprendizagem quanto a viabilidade de replicação em outros cursos de tecnologia.




Figura 1 – Fluxograma da metodologia FAR-M aplicada ao ensino superior em tecnologia. Fonte: Próprio autor.

A Figura 1 apresenta o fluxograma da metodologia FAR-M, concebida como evolução da MSeP para o ensino superior. O diagrama evidencia a sequência de etapas que estruturam o ciclo de aprendizagem ativa. A partir da base metodológica da MSeP e sua adaptação ao ensino superior, estabelece-se o Ciclo FAR-M, composto por atividades práticas, randomização de itens, submissão de respostas, correção automatizada e feedback imediato. Esse ciclo é contínuo, permitindo ao estudante revisar e aprimorar seu desempenho por meio de múltiplas tentativas orientadas por feedback.

4 RESULTADOS E DISCUSSÕES

Com a aplicação do FAR-M, espera-se ampliar o engajamento discente, favorecer a retenção do conhecimento e reduzir disparidades de desempenho entre estudantes. Do ponto de vista docente, a metodologia deve otimizar o acompanhamento individualizado, permitindo foco na análise qualitativa e na mediação pedagógica. Além disso, a abordagem busca desenvolver competências socioemocionais, como resiliência e autorregulação, ao apoiar ciclos de tentativa e correção

com menor estresse. Em nível institucional, projeta-se contribuição para a redução da evasão e oferta de um modelo replicável e escalável, alinhado às demandas contemporâneas da formação em tecnologia.

5 CONCLUSÃO

A metodologia FAR-M (Feedback, Auto-grader, Randomização – MSeP) representa um esforço de adaptação da experiência acumulada no ensino técnico, por meio da MSeP, às demandas complexas do ensino superior em tecnologia. Ao integrar recursos digitais de avaliação contínua, feedback imediato e randomização de atividades, o modelo busca superar as limitações de práticas tradicionais ainda predominantes em cursos de Computação, Segurança Cibernética e Ciência de Dados, especialmente no que diz respeito à escalabilidade, à personalização da aprendizagem e ao desenvolvimento de competências socioemocionais. A proposta encontra-se em fase de implementação piloto, mas fundamenta-se em evidências científicas e em experiências pedagógicas anteriores que sustentam seu potencial. As contribuições esperadas incluem maior engajamento discente, retenção do conhecimento, redução da evasão e fortalecimento do papel docente como mediador. Além disso, o FAR-M apresenta-se como um modelo inovador e replicável, capaz de alinhar a formação acadêmica às exigências contemporâneas do setor tecnológico. Trabalhos futuros deverão incluir análises quantitativas e qualitativas dos resultados obtidos nas turmas piloto, bem como a expansão da metodologia para diferentes áreas do ensino superior, de modo a validar sua eficácia e ampliar seu impacto institucional.

REFERÊNCIAS

AMIN, Rashed Al; WIESE, Veit; JACOBS, Sven; HARDEBUSCH, Timo; JASCHKE, Steffen; OBERMAISSER, Roman. Requirement Analysis and Didactic Evaluation of a Collaborative Remote Laboratory for FPGAs. In: IEEE GLOBAL ENGINEERING EDUCATION CONFERENCE (EDUCON), 2024. Anais [...]. IEEE, 2024. p. 1–6. DOI: <https://doi.org/10.1109/EDUCON60636.2024.10643219>.

COMBÉFIS, Sébastien. Using Continuous Competency-Based Assessment as a Success Support Service in Higher Education. In: IEEE FRONTIERS IN EDUCATION CONFERENCE (FIE), 2023. Anais [...]. IEEE, 2023. p. 1–4. DOI: <https://doi.org/10.1109/FIE58773.2023.10343034>.

EDWARDS, Stephen H.; PÉREZ-QUIÑONES, Manuel A.; DECKER, Adrienne; EDMISON, Bob; RORRER, Audrey; SHUKLA, Anmol. Early Experiences with Specifications Grading in Introductory CS Courses. In: IEEE FRONTIERS IN EDUCATION CONFERENCE (FIE), 2024. Anais [...]. IEEE, 2024. p. 1–9. DOI: <https://doi.org/10.1109/FIE61694.2024.10893554>.

FERRAO, Rafael Corsi; MONTAGNER, Igor Dos Santos; CACEFFO, Ricardo; AZEVEDO, Rodolfo. How much C students can learn in one week? Experiences teaching C in advanced CS courses. In: IEEE FRONTIERS IN EDUCATION CONFERENCE (FIE), 2023. Anais [...]. IEEE, 2023. p. 1–8. DOI: <https://doi.org/10.1109/FIE58773.2023.10343145>.

GAO, Rujun; THOMAS, Naveen; SRINIVASA, Arun. Work in Progress: Large Language Model Based Automatic Grading Study. In: IEEE FRONTIERS IN EDUCATION CONFERENCE (FIE), 2023. Anais [...]. IEEE, 2023. p. 1–4. DOI: <https://doi.org/10.1109/FIE58773.2023.10343006>.

HARE, Ryan; TANG, Ying; ZHU, Chengzhang. Combining Gamification and Intelligent Tutoring Systems for Engineering Education. In: IEEE FRONTIERS IN EDUCATION CONFERENCE (FIE), 2023. Anais [...]. IEEE, 2023. p. 1–5. DOI: <https://doi.org/10.1109/FIE58773.2023.10343378>.

JAISON, Donna; WEAVER, Morgan B.; RAY, Samantha; MERZDORF, Hillary E.; DOUGLAS, Kerrie A.; KRISHNAMURTHY, Vinayak; LINSEY, Julie; WATSON, Karan; HAMMOND, Tracy. WIP Teaching Engineers to Sketch: Impacts of Feedback from an Intelligent Tutoring Software on Engineers' Sketching Skill Development. In: IEEE FRONTIERS IN EDUCATION CONFERENCE (FIE), 2022. Anais [...]. IEEE, 2022. p. 1–5. DOI: <https://doi.org/10.1109/FIE56618.2022.9962419>. Livro_Msep_2019.pdf>.

Serviço Nacional de Aprendizagem Industrial (SENAI). Metodologia SENAI de Educação Profissional. Brasília: SENAI Departamento Nacional, 2019. Acesso em: today. Disponível em: <<https://senaiweb.fieb.org.br/areadocente/assets/Midia/2019/>

AGRADECIMENTOS

À Faculdade SENAI, Direção da Escola SENAI “Antonio Skaf”, coordenação, equipe técnica, docentes, estudantes e parceiros institucionais, pelo apoio essencial à realização deste trabalho.

SOBRE O(S)AUTOR(ES)

ⁱ Tiago Augusto Orcajo Demay Cordeiro (Autor 1)



Mestre em Engenharia de Computação (Poli-USP), pós-graduado em Computação em Nuvem e graduado em Engenharia Eletrônica (IMT). Atua no Insper (Laboratório de Redes e Supercomputação) e como professor de Computação em Nuvem. Pesquisa em redes, segurança com IA e HPC.

<https://orcid.org/0000-0002-4991-478>

ⁱⁱ Hebert de Oliveira Silva (Autor 2)



Mestre e Doutorando em Tecnologia da Informação pela UNICAMP; Coordenador de Cibersegurança no Grupo Hapvida e professor (IBMEC, Impacta, UNIP e SENAI Informática). Atuação em Blue/Red Team, governança e resposta a incidentes, com foco em aprendizado federado, IA e segurança em CPS/IoT. Autor de livros e artigos IEEE, ACM e Elsevier.

<https://orcid.org/0000-0002-0186-5925>

iii Jéssica Franzon Cruz do Espírito Santo (Autor 3)



Possui graduação (Bacharelado) em Ciência da Computação (2018-2021) pela Universidade Paulista (UNIP); Pós-graduada em Gestão Educacional na Perspectiva Inclusiva (2022) pela Universidade Federal de Pelotas (UFPEL) e Pós-graduada em Psicopedagogia (2024) pela Faculdade das Américas (FAM); É Mestranda em Engenharia da Informação pela Universidade Federal do ABC. Atua como Professora na Faculdade Senai no campus Paulo Antônio Skaf no curso de Ciência de Dados.

<https://orcid.org/0000-0002-2812-3673>

iv Caique Zaneti Kirilo (Autor 4)



Possui bacharelado em Ciência da Computação (2012-2015); Mestrado em Engenharia de Produção com ênfase em Inteligência Artificial e Seis Sigma na linha de pesquisa de Métodos Quantitativos em Engenharia de Produção focada em Processos decisórios baseados em lógicas não clássicas (2016-2017); É Doutorando em Engenharia da Informação pela Universidade Federal do ABC. Atua como Professor Universitário e Pesquisador integrante do Grupo de Pesquisa de Engenharia de Software aplicada à criação de Sistemas Críticos, atuando também como orientador em programas de iniciação científica de alunos da graduação. <https://orcid.org/0000-0001-5667-0861>

v Arthur Gustavo de Araujo Ferreira (Autor 5)



Bacharel em Física com ênfase computacional, mestre e doutor em Ciências pela USP. Professor na Escola SENAI de Informática, atua em ciência de dados, inteligência artificial e computação quântica. Tem ampla experiência em Ressonância Magnética Nuclear aplicada ao estudo de meios porosos, computação quântica, petrofísica e materiais cimentícios, com foco em análises de RMN, modelagem estatística e machine learning para caracterização de materiais. Sua carreira integra pesquisa científica, aplicações industriais e ensino.

<https://orcid.org/0000-0002-6676-384X>

vi **Vivian de Oliveira Preto (Autor 6)**



Graduada em Tecnologia Gráfica (Faculdade SENAI Theobaldo de Nigris) e Mestre em Educação (UNESP/Marília). Coordenadora dos cursos superiores de Tecnologia em Ciência de Dados e Segurança Cibernética da Faculdade SENAI Mecatrônica (Campus Paulo Antônio Skaf).

<https://orcid.org/0009-0006-0193-5571>

vii **Emerson Costa Santos (Autor 7)**



Supervisor de Operações do SENAI-SP, com atuação em planejamento, gestão e avaliação de Escolas e Faculdades. Professor Convidado na Sheridan College (Canadá). Doutorando em Sociologia, Mestre em Engenharia Elétrica e Engenheiro Mecânico. Pesquisador no C4AI-USP, CECS-UFABC (Indústria 4.0) e Expert Independente da WorldSkills International. Experiência como especialista e docente em Educação Profissional nas áreas de Manutenção Industrial, Automação, Ferramentaria e EJA.

<https://orcid.org/0000-0002-4730-9983>