

Sistema Adaptativo Baseado em Regras para o Ensino de Programação em Python: Um Estudo Experimental

Ana Barreto, Alexandre Boente, Marcelo Rodrigues, Renan Grion, Márcio Medina

Colégio Militar do Rio de Janeiro (CMRJ)
Rio de Janeiro – RJ – Brasil

aluciabar@gmail.com, asboente@gmail.com, rodrigues@eb.mil.br,
grion.renan@gmail.com, professormedina@hotmail.com

Abstract. *This paper presents the application and evaluation of a rule-based adaptive system for teaching Python programming, implemented using Google Forms. The study involved 24 basic education students divided into two groups, considering performance, learning, and user experience. The results indicate improved performance and high levels of satisfaction, as well as convergence among students with different initial knowledge levels. Students with lower initial performance showed greater improvement, while reinforcement activities served as a support mechanism. The findings indicate the potential of this approach to personalize learning and reduce educational inequalities.*

Keywords— *Adaptive Systems, Personalized Learning, Programming Education.*

Resumo. *Este trabalho apresenta a aplicação e avaliação de um sistema adaptativo baseado em regras para o ensino de programação em Python, implementado no Google Forms. O estudo envolveu 24 estudantes da educação básica, distribuídos em duas turmas, considerando desempenho, aprendizagem e experiência do usuário. Os resultados evidenciam melhora no desempenho e elevada satisfação, além de convergência entre estudantes com diferentes níveis iniciais. Estudantes com menor desempenho inicial apresentaram maior evolução, enquanto os reforços atuaram como mecanismo de suporte. Os achados indicam potencial da abordagem para personalizar a aprendizagem e reduzir desigualdades educacionais.*

Palavras-chave— *Sistemas Adaptativos, Aprendizagem Personalizada, Ensino de Programação.*

1. Introdução

O avanço das tecnologias digitais tem promovido transformações significativas no campo educacional, especialmente com a incorporação de técnicas de Inteligência Artificial (IA) no processo de ensino e aprendizagem. Nesse contexto, sistemas adaptativos educacionais têm se destacado como uma abordagem promissora para lidar com a diversidade de perfis dos estudantes, permitindo a personalização do ensino de acordo com necessidades individuais [Prihar *et al.* 2022].

Um dos principais desafios enfrentados na educação é a heterogeneidade dos estudantes, que apresentam diferentes níveis de conhecimento prévio, ritmos de aprendizagem, níveis de motivação e autoconfiança. Modelos tradicionais de ensino,

baseados em abordagens lineares e uniformes, tendem a não atender adequadamente essa diversidade, podendo resultar em dificuldades de aprendizagem para alguns alunos e desmotivação para outros [Shute 2008].

Nesse cenário, sistemas adaptativos buscam oferecer experiências educacionais personalizadas por meio da análise contínua do desempenho dos estudantes e da adaptação dinâmica do conteúdo apresentado. Diferentes abordagens têm sido propostas na literatura, incluindo modelos baseados em aprendizado de máquina, rastreamento de conhecimento e sistemas tutores inteligentes [Vie and Kashima 2019; Mao *et al.* 2024]. Embora essas abordagens apresentem bons resultados, frequentemente envolvem limitações relacionadas à interpretabilidade, ao custo computacional e à necessidade de grandes volumes de dados. Como alternativa, abordagens baseadas em regras têm ganhado atenção por sua simplicidade, transparência e facilidade de implementação, sendo mais acessíveis para professores e instituições com menor infraestrutura tecnológica [Eryilmaz and Adabashi 2020]. Nesse sentido, iniciativas recentes têm explorado o uso de ferramentas acessíveis para viabilizar soluções adaptativas de baixo custo, ampliando o acesso à personalização da aprendizagem [Rodrigues *et al.* 2025; Fernandes *et al.* 2026; Grion and Moraes 2026].

Este trabalho apresenta a aplicação e avaliação de um sistema adaptativo baseado em regras para o ensino de programação em Python, implementado por meio da plataforma Google Forms. O sistema organiza o conteúdo em trilhas adaptativas, direcionando os estudantes para atividades de reforço ou progressão conforme seu desempenho ao longo do curso.

A proposta foi aplicada no contexto de um clube de robótica educacional do Colégio Militar do Rio de Janeiro, com estudantes da educação básica, no qual a programação em Python foi introduzida como complemento às atividades práticas. Nesse cenário, foram avaliados aspectos relacionados ao desempenho acadêmico, ganho de aprendizagem, uso das trilhas adaptativas e experiência do usuário. Os resultados indicam melhoria no desempenho dos estudantes, bem como a presença de um efeito de convergência entre diferentes perfis iniciais, sugerindo que o sistema atua como um mecanismo de suporte compensatório no processo de aprendizagem.

Dessa forma, o presente trabalho contribui para a área ao demonstrar que sistemas adaptativos baseados em regras, mesmo com arquitetura simples e baixo custo de implementação, podem promover a personalização da aprendizagem e apoiar a redução de desigualdades educacionais.

2. Fundamentação Teórica

Esta seção apresenta os principais conceitos que fundamentam o sistema proposto, com foco em sistemas adaptativos, personalização da aprendizagem e feedback no contexto educacional.

2.1. Sistemas Adaptativos na Educação

Os sistemas adaptativos educacionais constituem uma abordagem consolidada para a personalização da aprendizagem em ambientes digitais, permitindo o ajuste de conteúdo e estratégias de ensino com base no desempenho dos estudantes [Prihar *et al.* 2022]. Abordagens recentes incluem modelos de aprendizado de máquina, rastreamento de conhecimento e sistemas tutores inteligentes [Vie and Kashima 2019; Mao *et al.* 2024].

Embora eficazes, tais métodos frequentemente apresentam limitações relacionadas à interpretabilidade, ao custo computacional e à necessidade de grandes volumes de dados. Nesse contexto, abordagens baseadas em regras são frequentemente utilizadas em sistemas adaptativos educacionais por sua simplicidade, transparência e baixo custo de implementação, características que favorecem sua aplicação em ambientes educacionais reais [Eryilmaz and Adabashi 2020].

2.2. Personalização da Aprendizagem

A personalização da aprendizagem envolve a adaptação do ensino às características individuais dos estudantes, considerando aspectos como conhecimento prévio, desempenho e engajamento. Estudos indicam que essas variáveis são relevantes para compreender o comportamento do estudante e orientar decisões adaptativas [Alshabandar *et al.* 2020]. Assim, sistemas que utilizam informações simples, como desempenho em atividades, podem oferecer mecanismos eficazes de personalização. Além disso, abordagens baseadas em análise de dados têm sido utilizadas para compreender padrões de comportamento em diferentes contextos, reforçando seu potencial na modelagem de perfis de aprendizagem.

2.3. Feedback e Engajamento

O feedback formativo é fundamental no processo de aprendizagem, orientando o estudante e contribuindo para seu desenvolvimento contínuo [Shute 2008]. Em sistemas adaptativos, esse feedback pode ocorrer de forma implícita por meio da organização do conteúdo em trilhas diferenciadas, permitindo que estudantes com dificuldades recebam suporte adicional, enquanto outros avancem em conteúdos mais complexos. Estratégias complementares, como progressão estruturada e elementos motivacionais, também podem favorecer o engajamento e o desempenho dos estudantes [Maryono *et al.* 2025]. Em síntese, a combinação entre adaptação, personalização e feedback pode contribuir para a melhoria da aprendizagem e para o atendimento da diversidade de perfis em ambientes educacionais.

3. Metodologia

Esta seção descreve o contexto de aplicação do estudo, a estrutura do curso, o funcionamento do sistema adaptativo baseado em regras, bem como os procedimentos de coleta e análise dos dados utilizados na avaliação da proposta.

3.1. Contexto de Aplicação e Participantes

O estudo foi realizado no âmbito de um clube de robótica educacional do Colégio Militar do Rio de Janeiro, envolvendo estudantes da educação básica, no qual a programação em Python foi utilizada como complemento às atividades práticas. A amostra foi composta por 24 participantes, distribuídos em duas turmas: 2025 ($n = 13$) e 2026 ($n = 11$), possibilitando a comparação entre diferentes contextos de aplicação. Os participantes apresentaram perfil heterogêneo quanto ao nível de escolaridade, incluindo estudantes do Ensino Fundamental II (8º e 9º ano) e do Ensino Médio (1º ao 3º ano).

As turmas foram expostas ao curso em momentos distintos do ano letivo, com diferenças relevantes em relação ao conhecimento prévio. A turma de 2025 realizou o curso no meio do ano letivo, após contato com programação em blocos no contexto das

atividades de robótica. Já a turma de 2026 participou do curso no início do ano letivo, sem experiência prévia em programação. Essa distinção de contexto foi considerada na análise dos resultados, especialmente em relação ao desempenho inicial e à evolução dos estudantes ao longo do curso.

3.2. Estrutura do Curso

O curso foi estruturado em oito tópicos sequenciais, abordando conceitos introdutórios de programação em Python. Cada tópico era composto por conteúdo instrucional, uma atividade avaliativa objetiva e o registro do desempenho do estudante. Antes do início das atividades, os estudantes realizaram um diagnóstico inicial por meio de um pré-teste, com o objetivo de avaliar o conhecimento prévio. O pré-teste e o pós-teste foram compostos pelas mesmas dez questões objetivas de múltipla escolha, abrangendo os oito tópicos do curso. Cada questão valia um ponto, totalizando nota de 0 a 10, possibilitando a comparação do desempenho dos estudantes antes e após a intervenção. A Tabela 1 apresenta a organização dos tópicos abordados ao longo do curso.

Tabela 1. Estrutura dos tópicos do curso

Tópico	Conteúdo
T1	Variáveis e Tipos de Dados
T2	Operadores Aritméticos e Lógicos
T3	Estruturas Condicionais (<i>if, else, elif</i>)
T4	Laços de Repetição (<i>for</i> e <i>while</i>)
T5	Funções em Python
T6	Listas e Tuplas
T7	Dicionários
T8	Entrada e Saída de Dados e Tratamento de Erros

Além das atividades principais, o curso incluía mecanismos de reforço para estudantes que apresentassem dificuldades, permitindo revisitar conteúdos e consolidar a aprendizagem. Ao final do percurso, os estudantes realizaram uma avaliação final (pós-teste), permitindo mensurar a evolução da aprendizagem, bem como responderam a um questionário de experiência do usuário (UX), com o objetivo de avaliar a percepção em relação ao curso.

3.3. Sistema Adaptativo Baseado em Regras

O sistema adaptativo foi implementado utilizando a plataforma Google Forms, com suporte de lógica baseada em regras para direcionamento dos estudantes ao longo do curso. A escolha da plataforma Google Forms está alinhada a propostas recentes que utilizam ferramentas amplamente acessíveis para implementação de sistemas adaptativos educacionais, demonstrando viabilidade metodológica e potencial de aplicação em larga escala [Rodrigues *et al.* 2025]. A Fig. 1 apresenta o fluxo de funcionamento do sistema adaptativo, destacando o processo de decisão baseado no desempenho do estudante em cada tópico.




Figura 1. Fluxo de funcionamento do sistema adaptativo baseado em regras.

De forma operacional, ao final de cada tópico é apresentada uma questão objetiva de múltipla escolha, elaborada para verificar a compreensão do conceito central abordado naquele conteúdo, que orienta a progressão do estudante no curso. Caso o estudante responda corretamente, ele é direcionado para o próximo tópico do curso. Em caso de erro, o sistema encaminha o estudante para um tópico de reforço, no qual é apresentado um feedback explicativo previamente elaborado para a questão, seguido de conteúdo complementar e uma nova questão avaliativa. Esse processo se repete ao longo do curso, permitindo a adaptação contínua do percurso de aprendizagem com base no desempenho do estudante. Essa abordagem caracteriza um modelo de adaptação simples, porém eficaz, no qual decisões pedagógicas são explicitamente definidas por regras.

3.4. Coleta e Organização dos Dados

Os dados foram coletados automaticamente por meio da plataforma, resultando em um conjunto de dados estruturado com 26 variáveis, sem valores ausentes, garantindo consistência para análise. As principais variáveis utilizadas no estudo estão descritas na Tabela 2.

Tabela 2. Principais variáveis analisadas no estudo

Variável	Descrição
nota_pret	Nota do pré-teste (0–10)
nota_post	Nota do pós-teste (0–10)
ganho_bruto	Diferença entre pós-teste e pré-teste
ganho_hake	Ganho normalizado de aprendizagem
qtd_reforços	Quantidade de atividades de reforço acessadas
acertos_topicos	Total de acertos nos tópicos principais
ux_01 a ux_05	Itens de avaliação da experiência do usuário
ux_media	Média geral da experiência do usuário

3.5. Procedimentos de Análise

A análise dos dados foi conduzida em etapas, combinando estatística descritiva e inferencial. Inicialmente, foram calculadas medidas descritivas, incluindo médias e desvios padrão, com o objetivo de caracterizar o desempenho dos estudantes e o uso do sistema adaptativo. Em seguida, foi avaliada a normalidade das distribuições por meio

do teste de Shapiro-Wilk. Com base nos resultados, foram aplicados testes estatísticos apropriados:

- Teste t de Student para variáveis com distribuição normal;
- Teste de Mann-Whitney para variáveis não paramétricas.

Também foi calculado o tamanho de efeito por meio do coeficiente de Cohen, permitindo avaliar a relevância prática dos resultados. Além disso, foram realizadas análises de correlação (Pearson e Spearman) para investigar relações entre variáveis, como desempenho inicial, ganho de aprendizagem e uso de reforços. Por fim, foi avaliada a consistência interna da escala de experiência do usuário por meio do coeficiente alfa de Cronbach, com o objetivo de verificar a confiabilidade do instrumento.

Todas as análises foram realizadas em ambiente computacional, utilizando ferramentas de análise de dados em Python. A escolha dos testes estatísticos considerou as características da amostra e das variáveis analisadas, sendo adotadas práticas consolidadas na literatura para comparação de grupos e análise de medidas repetidas [Langenberg *et al.* 2023]. Além disso, a condução das análises e a organização dos dados seguiram práticas comuns em estudos que empregam técnicas de modelagem computacional em diferentes domínios, reforçando a aplicabilidade dessas abordagens em contextos educacionais [Barreto *et al.* 2026].

4. Resultados

Esta seção apresenta os principais resultados obtidos a partir da aplicação do sistema adaptativo, incluindo análises descritivas, comparações entre grupos e evidências relacionadas ao desempenho dos estudantes, uso das trilhas adaptativas e experiência do usuário.

4.1. Análise Descritiva

A análise inicial dos dados indicou um aumento expressivo no desempenho dos estudantes ao longo do curso. A média do pré-teste foi de 4,75, enquanto a média do pós-teste atingiu 8,12, evidenciando evolução significativa após a intervenção pedagógica. Além do aumento no desempenho médio, observou-se redução do desvio padrão, passando de 2,27 no pré-teste para 1,67 no pós-teste, sugerindo maior homogeneização do desempenho entre os estudantes, conforme ilustrado na Fig. 2.




Figura 2. Comparação entre pré-teste e pós-teste.

4.2. Ganho de Aprendizagem

O ganho médio bruto foi de 3,37 pontos, indicando melhora consistente no desempenho dos estudantes. Entretanto, foram observados casos isolados de regressão, com valores mínimos de -2,00, evidenciando variabilidade individual no processo de aprendizagem.

O ganho normalizado de Hake, amplamente utilizado em pesquisas educacionais para mensurar a evolução do desempenho a partir de pré e pós-testes [Hake 1998], apresentou média de 0,55, sendo classificado como médio a elevado, indicando efetividade do processo de ensino. A variabilidade do ganho foi significativa (desvio padrão de 0,48), sugerindo que o impacto do sistema adaptativo não foi uniforme entre os participantes.

4.3. Comparação entre Grupos

Considerando as diferenças de contexto entre as turmas descritas na Seção de Metodologia, observa-se que a turma de 2026 apresentou maior média no pré-teste, enquanto a turma de 2025 partiu de um nível inicial inferior. Esse comportamento é consistente com o fato de que os estudantes da turma de 2025 já haviam tido contato prévio com programação em blocos, ao passo que a turma de 2026 iniciou o curso sem experiência anterior. A partir desse cenário, torna-se possível compreender as diferenças observadas no ganho de aprendizagem e na evolução ao longo do curso.

A análise comparativa entre as turmas revelou uma tendência de desempenho inicial superior na turma de 2026 ($M = 5,27$) em comparação à turma de 2025 ($M = 4,30$); entretanto, essa diferença não foi estatisticamente significativa ($p > 0,05$). Ao final do curso, ambas as turmas apresentaram desempenho semelhante no pós-teste (2025: $M = 8,15$; 2026: $M = 8,09$), indicando convergência no desempenho dos estudantes. Embora a turma de 2025 tenha apresentado maior ganho médio (3,84 contra 2,81), essa diferença não foi estatisticamente significativa ($p > 0,05$), conforme ilustrado na Fig. 3.




Figura 3. Ganho de aprendizagem por grupo

4.4. Uso do Sistema Adaptativo

O sistema adaptativo foi efetivamente acionado ao longo do curso. Como o curso continha oito atividades de reforço possíveis, uma associada a cada tópico, os estudantes acessaram, em média, 2,12 atividades de reforço, com valores máximos de até 5 acessos. Observou-se que a turma com menor desempenho inicial (2025) utilizou mais frequentemente os recursos de reforço ($M = 2,30$) em comparação à turma de 2026 ($M = 1,90$). Além disso, parte dos reforços resultou em acertos subsequentes, sugerindo potencial de recuperação da aprendizagem, conforme apresentado na Fig. 4.




Figura 4. Uso de reforços por grupo.

4.5. Análises Complementares

As análises de correlação indicaram uma tendência negativa entre o desempenho inicial e o ganho de aprendizagem ($\rho = -0,33$), sugerindo que estudantes com menor conhecimento prévio tendem a apresentar maior evolução ao longo do curso. A Fig. 5 ilustra a relação entre o desempenho inicial dos estudantes e o ganho de aprendizagem, evidenciando a dispersão dos dados e possíveis diferenças entre os grupos.




Figura 5. Relação entre conhecimento inicial (pré-teste) e ganho de aprendizagem por grupo.

Por outro lado, não foi observada correlação significativa entre a quantidade de reforços acessados e o ganho de aprendizagem, indicando que o uso do reforço não impacta diretamente o ganho, mas atua como mecanismo de suporte.

A análise da experiência do usuário, obtida por meio de um questionário composto por cinco afirmações avaliadas em escala Likert de 1 (discordo totalmente) a 5 (concordo totalmente), relacionadas à compreensão dos conteúdos, adaptação do curso, motivação, organização e percepção de preparo para aplicação prática, apresentou média geral de 4,29, indicando uma avaliação positiva da experiência pelos participantes. A consistência interna da escala de UX foi considerada moderada ($\alpha = 0,65$), sendo aceitável para estudos exploratórios. Adicionalmente, observou-se uma correlação positiva moderada entre UX e ganho de aprendizagem ($\rho = 0,37$), sugerindo que estudantes com melhor percepção do curso tendem a apresentar melhores resultados, conforme ilustrado na Fig. 6.




Figura 6. Avaliação da experiência do usuário.

4.6. Síntese dos Resultados

De forma consolidada, a Tabela 3 apresenta os principais indicadores obtidos ao longo do estudo, incluindo desempenho, ganho de aprendizagem, uso do sistema adaptativo e experiência do usuário. Os valores de ganho são apresentados como média $\pm$ desvio padrão.

Tabela 3. Resumo dos principais resultados por grupo

Indicador	Turma 2025	Turma 2026
Média Pré-teste	4,30	5,27
Média Pós-teste	8,15	8,09
Ganho Médio Bruto	3,84 $\pm$ 2,67	2,81 $\pm$ 2,68
Ganho Hake	0,58 $\pm$ 0,55	0,50 $\pm$ 0,42
Reforços Médios	2,30	1,90
UX Média	4,35	4,21

5. Discussão

Os resultados obtidos neste estudo indicam que o sistema adaptativo baseado em regras foi capaz de promover ganhos relevantes de aprendizagem no ensino de programação em Python. O aumento expressivo entre as médias do pré-teste e pós-teste, aliado a um ganho normalizado de Hake classificado como médio a elevado, sugere que a abordagem adotada foi eficaz no contexto investigado.

Entretanto, um dos achados mais relevantes não está apenas no aumento do desempenho médio, mas na redução da variabilidade entre os estudantes. A diminuição do desvio padrão entre o pré e o pós-teste indica uma tendência de homogeneização do desempenho, sugerindo que o sistema contribuiu para reduzir as diferenças de desempenho entre estudantes com distintos níveis iniciais de conhecimento.

Esse comportamento é reforçado pela análise comparativa entre as turmas. Nesse contexto, as diferenças entre os grupos, especialmente em relação ao contato prévio com programação, ajudam a explicar os padrões observados nos resultados. A turma de 2025, que já possuía experiência com programação em blocos, apresentou

desempenho inicial inferior ao da turma de 2026, mas teve maior ganho ao longo do curso. Por outro lado, a turma de 2026, sem experiência prévia, iniciou com desempenho mais elevado, porém apresentou evolução mais moderada. Ainda assim, ambas as turmas atingiram níveis semelhantes ao final do curso, o que pode ser interpretado como um efeito de convergência de aprendizagem, no qual estudantes com menor desempenho inicial apresentam maior evolução relativa, reforçando o papel do sistema adaptativo na compensação de diferenças iniciais de conhecimento.

Tal resultado está alinhado com a literatura sobre personalização da aprendizagem, que aponta a adaptação do conteúdo como um fator relevante para atender à diversidade de perfis em ambientes educacionais [Prihar *et al.* 2022]. Nesse sentido, o sistema proposto demonstra potencial para atuar como mecanismo de compensação pedagógica, favorecendo estudantes com maiores dificuldades.

A análise do uso do sistema adaptativo reforça essa interpretação. Observou-se que estudantes com menor desempenho inicial acessaram mais frequentemente as atividades de reforço, indicando que o sistema foi capaz de direcionar adequadamente os alunos conforme suas necessidades. No entanto, a ausência de correlação significativa entre o número de reforços e o ganho de aprendizagem sugere que o impacto do reforço não é linear.

Esse resultado pode ser interpretado à luz do conceito de feedback formativo, no qual o objetivo não é necessariamente maximizar o desempenho imediato, mas orientar o estudante em seu processo de aprendizagem [Shute 2008]. Dessa forma, o reforço atua como um mecanismo de suporte, contribuindo para evitar que estudantes com dificuldades fiquem para trás, mesmo que seus ganhos não sejam proporcionalmente maiores.

Além disso, os resultados sugerem que estudantes com menor conhecimento prévio tendem a se beneficiar mais do sistema, o que reforça seu papel na promoção da equidade educacional.

Outro aspecto relevante diz respeito à experiência do usuário. Os altos valores de UX indicam boa aceitação do sistema, o que é consistente com estudos que destacam a importância do engajamento no processo de aprendizagem [Maryono *et al.* 2025]. A correlação positiva observada entre UX e ganho de aprendizagem sugere que a percepção do estudante em relação ao ambiente educacional pode influenciar seus resultados.

Adicionalmente, a análise por perfis de aprendizagem revelou padrões distintos entre os estudantes. Aqueles com maior ganho apresentaram menor uso de reforços e maior avaliação de UX, indicando que o desempenho não depende exclusivamente do acesso ao suporte, mas de uma combinação entre conhecimento prévio, engajamento e interação com o sistema.

Do ponto de vista metodológico, a ausência de significância estatística em algumas análises, associada à presença de tamanhos de efeito moderados, indica que os resultados devem ser interpretados com cautela. Esse cenário é comum em estudos educacionais com amostras reduzidas, nos quais efeitos práticos relevantes podem não ser capturados por testes estatísticos tradicionais.

Além disso, a integração entre análise de dados e modelagem de comportamento, observada em estudos recentes, reforça a importância de abordagens

que considerem múltiplas dimensões do processo de aprendizagem, incluindo aspectos cognitivos e comportamentais [Barreto *et al.* 2026].

A utilização de técnicas de análise de dados e modelagem, ainda que em nível exploratório, está alinhada a estudos que empregam abordagens de aprendizado de máquina para compreensão de padrões em diferentes domínios, evidenciando o potencial dessas técnicas para apoiar processos de tomada de decisão [Grion *et al.* 2026].

Em síntese, os resultados sugerem que sistemas adaptativos baseados em regras, mesmo com arquitetura simples, podem desempenhar um papel importante na personalização da aprendizagem. Mais do que aumentar o desempenho médio, tais sistemas demonstram potencial para reduzir desigualdades educacionais, oferecendo suporte diferenciado aos estudantes conforme suas necessidades.

Esses achados dialogam com estudos anteriores sobre sistemas adaptativos educacionais aplicados a conteúdos de computação e tecnologia, nos quais a personalização do percurso de aprendizagem mostrou-se relevante para apoiar estudantes com diferentes níveis de conhecimento prévio [Grion and Moraes 2026].

6. Conclusão

Este trabalho apresentou o desenvolvimento e a avaliação de um sistema adaptativo baseado em regras para o ensino de programação em Python, aplicado a estudantes da educação básica. A proposta buscou oferecer uma abordagem de personalização da aprendizagem por meio de trilhas adaptativas, direcionando os estudantes conforme seu desempenho ao longo do curso.

Os resultados evidenciaram ganhos relevantes de aprendizagem, com aumento significativo dos desempenhos entre o pré e pós-teste, além de níveis elevados de satisfação dos estudantes em relação à experiência do usuário. Destaca-se, ainda, a presença de um fenômeno de convergência de desempenho, no qual estudantes com diferentes níveis iniciais de conhecimento atingiram resultados finais semelhantes.

Esse comportamento sugere que o sistema atua como um mecanismo de suporte compensatório, contribuindo para a redução das desigualdades de aprendizagem. Em vez de promover ganhos uniformes, o sistema demonstrou maior impacto relativo sobre estudantes com menor conhecimento prévio, reforçando a importância de abordagens adaptativas no contexto educacional.

Outro aspecto relevante refere-se à viabilidade de implementação. A utilização de um sistema baseado em regras, integrado a uma plataforma amplamente acessível como o Google Forms, demonstra que soluções simples e de baixo custo podem ser eficazes na promoção da personalização da aprendizagem, ampliando o potencial de aplicação em diferentes contextos educacionais.

Como limitações, destaca-se o tamanho reduzido da amostra, que pode ter influenciado a ausência de significância estatística em algumas análises, apesar da presença de efeitos práticos relevantes. Além disso, o estudo foi conduzido em um contexto específico, o que limita a generalização dos resultados.

Como trabalhos futuros, sugere-se a ampliação da amostra e a aplicação do sistema em diferentes contextos educacionais, incluindo ambientes de ensino remoto e

híbrido. Também se recomenda a investigação de novas variáveis, como engajamento em tempo real e comportamento de navegação, bem como a integração com abordagens mais avançadas de personalização.

Em síntese, este estudo contribui ao demonstrar que sistemas adaptativos baseados em regras podem representar uma alternativa viável e eficaz para a personalização da aprendizagem, com potencial para apoiar a equidade educacional e melhorar a experiência dos estudantes. Embora os resultados sejam promissores, estudos com amostras maiores e em diferentes contextos educacionais são necessários para ampliar a validade externa dos achados.

Considerações Éticas

O estudo foi conduzido em conformidade com os princípios éticos aplicáveis à pesquisa envolvendo seres humanos no contexto educacional. A aplicação foi previamente autorizada pelo comitê interno do Colégio Militar do Rio de Janeiro, responsável pela avaliação das atividades pedagógicas e de pesquisa desenvolvidas na instituição.

Por envolver estudantes menores de idade, todos os participantes foram incluídos mediante assinatura do Termo de Assentimento Livre e Esclarecido (TALE), enquanto seus respectivos responsáveis legais assinaram o Termo de Consentimento Livre e Esclarecido (TCLE). Os dados foram coletados de forma automatizada e analisados de maneira anonimizada, garantindo a preservação da identidade dos participantes e o uso exclusivamente acadêmico das informações obtidas.

Ameaças à Validade

Uma das limitações deste estudo refere-se à ausência de um grupo controle. A decisão de não utilizar uma abordagem comparativa tradicional foi motivada pelo contexto educacional da aplicação, envolvendo estudantes menores de idade em um ambiente extracurricular de robótica educacional. Nesse cenário, optou-se por garantir que todos os participantes tivessem acesso à experiência proporcionada pelo sistema adaptativo, evitando a exclusão de parte dos estudantes dos recursos de personalização e reforço pedagógico oferecidos ao longo do curso. Além disso, o estudo foi realizado com uma amostra reduzida e em uma única instituição de ensino, o que limita a generalização dos resultados para outros contextos educacionais.

Conformidade com Ciência Aberta

Com o objetivo de promover transparência e reprodutibilidade, os materiais utilizados neste estudo, incluindo scripts de análise, códigos e recursos empregados no processamento dos dados e na geração dos resultados, foram disponibilizados publicamente. O conjunto de artefatos pode ser acessado em: <https://zenodo.org/records/20208723>. A disponibilização desses recursos permite a verificação independentemente dos resultados, bem como a replicação e adaptação da abordagem proposta em diferentes contextos educacionais, contribuindo para o avanço de pesquisas na área de aprendizagem adaptativa.

Uso de Inteligência Artificial

Ferramentas de Inteligência Artificial Generativa foram utilizadas como apoio à revisão textual, organização das ideias e aprimoramento da clareza na redação deste manuscrito.

Todas as etapas relacionadas ao desenvolvimento da pesquisa — incluindo a definição do problema, delineamento metodológico, implementação do sistema, análise dos dados e interpretação dos resultados — foram conduzidas pelos autores. Os autores assumem total responsabilidade pelo conteúdo apresentado, garantindo a integridade científica do trabalho.

Agradecimentos

Os autores agradecem ao Departamento de Educação e Cultura do Exército (DECEX), à Diretoria de Educação Preparatória e Assistencial (DEPA) do Exército Brasileiro pelo apoio institucional concedido ao desenvolvimento desta pesquisa e ao Colégio Militar do Rio de Janeiro (CMRJ) pela disponibilização da infraestrutura, pelo suporte institucional e pelo ambiente propício à realização deste estudo. O apoio dessas instituições foi essencial para a execução da pesquisa e para o fortalecimento da produção científica na área de tecnologias aplicadas à educação.

Referências

- Alshabandar, R., Hussain, A., Keight, R., and Khan, W. (2020). “Students performance prediction in online courses using machine learning algorithms”. In *2020 International Joint Conference on Neural Networks (IJCNN)*, pp. 1–7. IEEE. <https://doi.org/10.1109/IJCNN48605.2020.9207196>.
- Barreto, A., Boente, A., Grion, R., Dantas, C., Chavarri, F. (2026). “Sistema RICON aplicado à neurociência do consumidor: um estudo desenvolvido no Colégio Militar do Rio de Janeiro com apoio de aprendizado de máquina”. *Revista Científica Fundação Osorio*, 10(1), 82–86. <https://doi.org/10.5281/zenodo.18769862>.
- Eryilmaz, M. and Adabashi, A. (2020). “Development of an intelligent tutoring system using Bayesian networks and fuzzy logic for a higher student academic performance”. *Applied Sciences*, 10(19), 6638. <https://doi.org/10.3390/app10196638>.
- Fernandes, I., Passos, C., Barreto, A. L., Rodrigues, M., Boente, A., Grion, R., de Lima, L., Sulaiman, A., and Goldschmidt, R. (2026). “Formação Docente para Uso de IA na Educação Básica: Avaliando Resultados de uma Capacitação Experimental”. In *Workshop sobre Educação em Computação (WEI)*, pp. 233–244. SBC. <https://doi.org/10.5753/wei.2026.22704>.
- Grion, R., Koifman, A. B., Moraes, L. O., and Ferreira, M. S. L. (2026). “Predictive Modeling of Rice Production in South America Using Machine Learning”. In *Simpósio Brasileiro de Sistemas de Informação (SBSI)*, pp. 576–595. SBC. <https://doi.org/10.5753/sbsi.2026.248573>.
- Grion, R. and Moraes, L. O. (2026). “Aplicação e Avaliação de um Sistema Adaptativo Baseado em Lógica Fuzzy para o Ensino de Robótica com Arduino”. In *Simpósio Brasileiro de Educação em Computação (EduComp)*, pp. 770–783. SBC. <https://doi.org/10.5753/educomp.2026.18658>.
- Hake, R. R. (1998). “Interactive-engagement versus traditional methods: A six-thousand-student survey of mechanics test data for introductory physics courses”. *American Journal of Physics*, 66(1), 64–74. <https://doi.org/10.1119/1.18809>.

- Langenberg, B., Janczyk, M., Koob, V., Kliegl, R., and Mayer, A. (2023). “A tutorial on using the paired t test for power calculations in repeated measures ANOVA with interactions”. *Behavior Research Methods*, 55(5), 2467–2484. <https://doi.org/10.3758/s13428-022-01902-8>.
- Mao, A., Chen, J., and Liu, Y.-J. (2024). “Improving knowledge tracing via considering conceptual structure and individual differences”. In *Proceedings of the ACM Turing Award Celebration Conference-China 2024*, pp. 59–65. <https://doi.org/10.1145/3674399.3674427>.
- Maryono, D., Sajidan, Akhyar, M., Sarwanto, Wicaksono, B. T., and Prakisyia, N. P. T. (2025). “NgodingSeru.com: an adaptive e-learning system with gamification to enhance programming problem-solving skills for vocational high school students”. *Discover Education*, 4(1), 157. <https://doi.org/10.1007/s44217-025-00581-9>.
- Prihar, E., Haim, A., Sales, A., and Heffernan, N. (2022). “Automatic interpretable personalized learning”. In *Proceedings of the Ninth ACM Conference on Learning@Scale*, pp. 1–11. <https://doi.org/10.1145/3491140.3528267>.
- Rodrigues, M., Boente, A., Sant Anna, I., Grion, R., and Barreto, A. L. (2025). “Google Forms como ferramenta para sistemas adaptativos educacionais: uma proposta metodológica com suporte de IA generativa”. *Revista Babilônia*, 11(1). <https://doi.org/10.5281/zenodo.19116540>.
- Shute, V. J. (2008). “Focus on formative feedback”. *Review of Educational Research*, 78(1), 153–189. <https://doi.org/10.3102/0034654307313795>.
- Vie, J.-J. and Kashima, H. (2019). “Knowledge tracing machines: Factorization machines for knowledge tracing”. In *Proceedings of the AAAI Conference on Artificial Intelligence*, 33(1), 750–757. <https://doi.org/10.1609/aaai.v33i01.3301750>.