

# Aplicação e Avaliação de um Sistema Adaptativo Baseado em Lógica Fuzzy para o Ensino de Robótica com Arduino

Renan Grion<sup>1</sup>, Laura O. Moraes<sup>1</sup>

<sup>1</sup>Universidade Federal do Estado do Rio de Janeiro (UNIRIO)  
Rio de Janeiro – RJ – Brasil

renan.grion@edu.unirio.br, laura@uniriotec.br

**Abstract.** *This paper presents the application and evaluation of an adaptive learning system based on fuzzy logic to support the teaching of robotics with Arduino. The educational resource incorporates three learning dimensions—cognitive, metacognitive, and affective—as inputs to the fuzzy inference engine, enabling automatic recommendations for reinforcement, regular, or challenge learning paths. Data collected throughout the course include performance indicators and learning progression patterns, which were examined through exploratory and quantitative analyses. Preliminary findings suggest that continuous adaptation supports learners with diverse profiles and contributes to more balanced learning trajectories in computing education.*

**Resumo.** *Este artigo apresenta a aplicação e a avaliação de um sistema adaptativo baseado em lógica fuzzy para apoiar o ensino de robótica com Arduino. O recurso educacional utiliza três dimensões da aprendizagem — cognitiva, metacognitiva e afetiva — como entradas do mecanismo de inferência, permitindo direcionar automaticamente os estudantes para trilhas de reforço, regular ou desafio. A aplicação do curso permitiu coletar dados de desempenho e progressão da aprendizagem, os quais foram analisados por meio de abordagens exploratórias e quantitativas. Os resultados preliminares indicam que a adaptação contínua contribui para apoiar estudantes com perfis diversos e favorecer trajetórias de aprendizagem mais equilibradas em educação em computação.*

## 1. Introdução

O ensino de Robótica com Arduino tem se consolidado como uma estratégia relevante para aproximar estudantes de conceitos fundamentais de ciência, tecnologia e programação, especialmente em contextos educacionais em que o acesso a recursos tecnológicos é limitado. Estudos recentes mostram que o Arduino, por ser um recurso acessível, versátil e de baixo custo, favorece a aprendizagem prática e o desenvolvimento de competências relacionadas ao pensamento computacional, criatividade e resolução de problemas [García-Tudela and Marín-Marín 2023, Ananias and Gaspar 2022]. A combinação entre experimentação prática, construção de protótipos e interação direta com dispositivos físicos contribui para o desenvolvimento de habilidades cognitivas e socioemocionais, ao mesmo tempo em que estimula a curiosidade científica e o engajamento dos estudantes [Maryono et al. 2025].

No cenário brasileiro, iniciativas de extensão universitária têm buscado reduzir desigualdades educacionais por meio de ações de inclusão digital, aproximando crianças e adolescentes de saberes tecnológicos que tradicionalmente não chegam às periferias urbanas. Projetos desse tipo ampliam oportunidades formativas e possibilitam que estudantes de contextos socialmente vulneráveis tenham acesso a experiências significativas no campo da ciência e da tecnologia [Ananias and Gaspar 2022].

Este trabalho apresenta um recurso educacional denominado *Robótica com Arduino – Sistema Adaptativo Baseado em Lógica Fuzzy*, desenvolvido no âmbito da UNIRIO e aplicado por meio do Programa de Extensão da Educação Superior na Pós-Graduação (PROEXT-PG) e do Centro de Extensão e Pesquisa em Favelas (CEP Favelas) – Letramento digital, midiático e de inteligência artificial. O curso foi ofertado a crianças e adolescentes de 12 a 17 anos, moradores das comunidades Babilônia e Chapéu Mangueira, no Rio de Janeiro/RJ, participantes dos projetos Sementes e Ngoma, em um contexto de baixa disponibilidade de equipamentos, diversidade de perfis de aprendizagem e oportunidades reduzidas de acesso à formação STEM (*Science, Technology, Engineering and Mathematics* — Ciência, Tecnologia, Engenharia e Matemática). Esse cenário demanda soluções educacionais capazes de apoiar estudantes com diferentes ritmos, níveis de conhecimento prévio e graus de autoconfiança.

A literatura recente demonstra que abordagens de aprendizagem adaptativa podem contribuir para personalizar percursos instrucionais, ajustando conteúdos, níveis de dificuldade e formas de apoio às necessidades individuais dos alunos. Sistemas adaptativos frequentemente incorporam mecanismos de inteligência artificial para modelar o desempenho e o estado do aprendiz, fornecendo recomendações personalizadas para otimizar o processo de aprendizagem [Chrysafiadi et al. 2023, Hwang et al. 2020]. A utilização de lógica fuzzy, em particular, tem se mostrado uma alternativa promissora para lidar com incertezas, subjetividades e nuances típicas de ambientes educacionais, permitindo representar níveis intermediários de proficiência, motivação e engajamento [Hwang et al. 2020, Szczepański and Marciniak 2023].

Ao mesmo tempo, estudos em educação evidenciam que intervenções bem-sucedidas não dependem apenas da adaptação cognitiva, mas também da capacidade de sustentar a motivação, promover interações significativas e oferecer feedbacks formativos que apoiem a autorregulação da aprendizagem [Panadero 2017]. Pesquisas sobre sistemas tutores inteligentes reforçam que avaliações contínuas, recomendações precisas e mecanismos de apoio influenciam positivamente o engajamento e o desempenho dos estudantes [Eryılmaz and Adabashi 2020, Chrysafiadi et al. 2023]. Nesse sentido, integrar técnicas de IA simbólica a um recurso educacional voltado ao ensino de robótica amplia as possibilidades de oferecer experiências pedagógicas mais responsivas e inclusivas.

O recurso educacional apresentado neste artigo incorpora um modelo adaptativo baseado em lógica fuzzy para direcionar estudantes às trilhas de Reforço, Regular ou Desafio, considerando aspectos cognitivos, metacognitivos e afetivos capturados por meio de um diagnóstico inicial e do desempenho ao longo das atividades. A proposta busca atender às demandas de um público heterogêneo, oferecendo caminhos personalizados que favoreçam tanto estudantes com dificuldades iniciais quanto aqueles que demonstram maior domínio dos conteúdos. Este artigo descreve a concepção, organização, arquitetura e avaliação do recurso educacional, discutindo seus resultados iniciais e limitações.

## 2. Fundamentação Teórica

Esta seção apresenta os fundamentos teóricos que sustentam o desenvolvimento do curso educacional e sistema adaptativo, abordando aprendizagem adaptativa, dimensões cognitiva, metacognitiva e afetiva, lógica fuzzy em ambientes educacionais e robótica.

### 2.1. Aprendizagem Adaptativa

A aprendizagem adaptativa refere-se ao uso de técnicas computacionais para ajustar conteúdos, níveis de dificuldade e formas de apoio de acordo com as características individuais de cada estudante. Sistemas desse tipo buscam identificar necessidades específicas, oferecendo recomendações que acompanham o progresso e o ritmo de aprendizagem do usuário [Chrysafiadi et al. 2023].

Pesquisas que comparam sistemas personalizados e modelos tradicionais indicam que a adaptação baseada em dados pode resultar em trajetórias mais eficazes de aprendizagem, ao permitir que os estudantes avancem conforme seu domínio conceitual e recebam suporte adicional quando necessário [Singh et al. 2022]. Outras propostas, baseadas em algoritmos de recomendação e estratégias de seleção automática de conteúdo, reforçam o potencial de modelos computacionais para personalizar a experiência educacional e identificar padrões úteis para orientar intervenções pedagógicas [Prihar et al. 2022]. Esses achados apontam que, em contextos reais, a adaptatividade pode desempenhar papel essencial para apoiar estudantes com diferentes níveis de conhecimento prévio, autoconfiança e engajamento.

A proposta adaptativa deste trabalho fundamenta-se na teoria da Zona de Desenvolvimento Proximal (ZDP), proposta por [Vygotsky and Cole 1978], segundo a qual a aprendizagem é potencializada quando o estudante é apoiado em tarefas situadas entre aquilo que já consegue realizar de forma autônoma e aquilo que ainda não domina. No curso de robótica, essa mediação ocorre de forma prática, por meio da experimentação com circuitos e programação, nas quais dificuldades emergem durante a execução das atividades. O sistema adaptativo baseado em lógica fuzzy operacionaliza a ZDP ao direcionar os estudantes para trilhas de Reforço, Regular ou Desafio, oferecendo suporte adicional ou aumento gradual de complexidade conforme indicadores cognitivos, metacognitivos e afetivos, promovendo progressão gradual e equidade no processo de aprendizagem.

Além disso, a organização do curso dialoga com princípios do modelo de aprendizagem cooperativa *Student Teams–Achievement Divisions* (STAD), no qual o estudo individual é combinado com atividades em grupo e avaliação individual do desempenho. No recurso educacional, os conteúdos teóricos e avaliações foram realizados individualmente, enquanto as atividades práticas de montagem e experimentação em robótica ocorreram em grupos, favorecendo a colaboração e a troca de conhecimentos [Slavin 1995].

### 2.2. Dimensões Cognitiva, Metacognitiva e Afetiva da Aprendizagem

A aprendizagem pode ser compreendida de forma multidimensional, envolvendo aspectos cognitivos, metacognitivos e afetivos. A dimensão cognitiva está relacionada ao processamento de informações e à construção do conhecimento, conforme modelos clássicos que descrevem como os indivíduos selecionam, organizam e integram informações durante o

processo de aprendizagem [Mayer 2002]. A dimensão metacognitiva refere-se à capacidade do estudante de monitorar e regular o próprio processo de aprendizagem, incluindo a percepção de dificuldade e o uso de estratégias cognitivas [Flavell 1979]. Já a dimensão afetiva envolve fatores como motivação, interesse e autoconfiança, que influenciam diretamente o engajamento e a persistência do aluno [Anderson and Krathwohl 2001].

### **2.3. Lógica Fuzzy em Ambientes Educacionais**

A lógica fuzzy tem sido amplamente utilizada como mecanismo de suporte à decisão em sistemas educacionais, especialmente em cenários que envolvem incertezas, subjetividade e variabilidade entre os aprendizes. Diferentemente de abordagens tradicionais baseadas em classificações rígidas, a lógica fuzzy permite representar gradualidades, como níveis intermediários de proficiência, esforço, motivação ou dificuldade percebida. Essa flexibilidade oferece vantagens importantes para modelar situações pedagógicas nas quais múltiplos fatores influenciam o desempenho do estudante [Al Duhayyim and Newbury 2018].

Modelos fuzzy aplicados à educação demonstram ser capazes de integrar informações cognitivas, metacognitivas e afetivas, produzindo recomendações personalizadas para orientar o percurso do aluno [Hwang et al. 2020]. Pesquisas mostram que controladores fuzzy podem ajustar dinamicamente conteúdos e atividades de acordo com indicadores de desempenho, contribuindo para experiências de aprendizagem mais responsivas e eficientes [Szczepeński and Marciniak 2023]. Além disso, sistemas de apoio baseados em lógica fuzzy — como chatbots educacionais que adaptam interações conforme o estado do aluno — evidenciam que tais estruturas podem melhorar a qualidade do suporte pedagógico e favorecer o engajamento [Troussas et al. 2023].

Nesse contexto, o uso de lógica fuzzy para direcionar estudantes a trilhas de Reforço, Regular ou Desafio constitui uma estratégia adequada para lidar com a heterogeneidade observada em ambientes educacionais diversos.

### **2.4. Robótica Educacional e Aprendizagem Ativa**

A robótica educacional tem se consolidado como uma abordagem relevante para promover aprendizagem ativa, exploratória e interdisciplinar. A manipulação de componentes físicos, aliada à programação e à experimentação, favorece o desenvolvimento do pensamento computacional, da criatividade e da resolução de problemas. Revisões recentes indicam que plataformas como o Arduino são especialmente adequadas para ambientes escolares e projetos educativos, em razão de sua acessibilidade, versatilidade e potencial de engajamento [García-Tudela and Marín-Marín 2023].

Além de facilitar a compreensão de conceitos tecnológicos, a robótica promove competências socioemocionais, como colaboração, autonomia e persistência, tornando-se uma ferramenta alinhada às metodologias de aprendizagem ativa. A adoção de recursos de baixo custo amplia ainda mais seu potencial em iniciativas de inclusão digital, permitindo que estudantes de diferentes contextos tenham acesso a experiências práticas e significativas [Ananias and Gaspar 2022].

Ao integrar robótica educacional a um sistema adaptativo baseado em lógica fuzzy, este recurso educacional busca potencializar o processo de aprendizagem, ofere-

cendo caminhos flexíveis que considerem tanto o desempenho quanto o perfil dos estudantes.

### 3. Metodologia

Esta seção descreve os procedimentos metodológicos adotados no desenvolvimento, aplicação e avaliação do recurso educacional proposto, incluindo a organização do curso, o sistema adaptativo baseado em lógica fuzzy, o conjunto de dados e as técnicas de análise empregadas.

#### 3.1. Descrição do Recurso Educacional

O recurso educacional desenvolvido neste trabalho consiste em um curso introdutório de Robótica com Arduino. O curso integra atividades práticas de eletrônica, programação e montagem de circuitos utilizando Arduino e Tinkercad, articuladas a um sistema adaptativo baseado em lógica fuzzy que personaliza o percurso de aprendizagem conforme o desempenho do estudante.

O curso foi organizado em cinco tópicos principais: (1) introdução à robótica e ao Arduino; (2) componentes eletrônicos básicos; (3) montagem de circuitos simples; (4) programação estruturada aplicada ao Arduino; e (5) projeto integrador final. Cada tópico possui uma trilha Regular, além de variações de Reforço e Desafio, selecionadas automaticamente segundo critérios definidos pelo sistema adaptativo.

A Figura 1 ilustra a tela inicial do curso, a partir da qual os estudantes acessam o diagnóstico e iniciam o percurso adaptativo.



Figura 1. Tela inicial do curso Robótica com Arduino.

O recurso está estruturado em três módulos principais: (i) diagnóstico inicial, contendo coleta de perfil e pré-teste; (ii) ambiente de aprendizagem com conteúdos e quizzes automatizados; e (iii) mecanismo adaptativo baseado em lógica fuzzy. Toda a implementação foi realizada em HTML, JavaScript e Google Apps Script, permitindo registro automático de ações, tomada de decisão adaptativa e continuidade do progresso. O material está disponibilizado sob licença **CC BY 4.0**.

#### 3.2. Arquitetura e Funcionamento do Sistema Adaptativo

O sistema adaptativo foi construído a partir de um mecanismo de inferência fuzzy, técnica amplamente utilizada em sistemas educacionais por sua capacidade de lidar com incerte-

zas, variabilidade de desempenho e combinações de fatores cognitivos, metacognitivos e afetivos [Hwang et al. 2020, Szczepański and Marciniak 2023].

A lógica fuzzy utiliza como entradas: (i) nota obtida nos quizzes (dimensão cognitiva), (ii) percepção de dificuldade (dimensão metacognitiva) e (iii) autoconfiança (dimensão afetiva). Cada variável é modelada por funções de pertinência triangulares e trapezoidais, seguindo recomendações de [Al Duhayyim and Newbury 2018, Hursen and Bicen 2025].

As funções de pertinência utilizadas no modelo fuzzy foram inicialmente calibradas com base na opinião de dois especialistas na área de Educação em Computação e Robótica Educacional, os quais participaram de entrevistas estruturadas para definição dos intervalos linguísticos e limiares de decisão.

Após a agregação fuzzy, o sistema realiza defuzzificação para gerar um escore contínuo (0–100), que determina a trilha mais apropriada para o estudante em cada tópico, permitindo adaptação dinâmica ao longo do percurso.

### 3.3. Conjunto de Dados

O conjunto de dados analisado contém registros completos de 14 estudantes, incluindo:

- informações socioeducacionais e perfil de aprendizagem;
- desempenho no pré-teste (0–10);
- indicadores cognitivos (nota e acertos por tópico);
- indicadores metacognitivos (percepção de dificuldade);
- indicadores afetivos (autoconfiança);
- trilhas atribuídas pelo sistema (Reforço, Regular, Desafio);
- valor numérico do escore fuzzy;
- pontuação final do curso.

O processamento dos dados foi realizado em Python via Google Colab, empregando *pandas*, *scikit-learn*, *scipy* e *matplotlib*. Variáveis categóricas foram codificadas por *one-hot encoding* [Géron 2022], valores ausentes foram tratados e variáveis numéricas foram padronizadas por *z-score*.

### 3.4. Clusterização Baseada no Diagnóstico

Para identificar perfis iniciais de estudantes, aplicou-se a técnica de clusterização não supervisionada *k-means* [Tan et al. 2016], utilizando exclusivamente dados do diagnóstico e do pré-teste, de modo a evitar vazamento de informação do processo adaptativo. O número ideal de clusters foi determinado pelos métodos da Curva do Cotovelo e do Coeficiente de Silhueta [Rousseeuw 1987], produzidos no Colab. Ambos os métodos sugeriram que  $k = 2$  era a solução mais estável, levando à definição de dois perfis iniciais: *cluster 0* e *cluster 1*.

Cada estudante recebeu um rótulo em `cluster_diag`, permitindo análises comparativas ao longo das dimensões cognitivas, metacognitivas, afetivas e adaptativas.

### 3.5. Procedimentos Estatísticos

Após a definição dos perfis, aplicaram-se testes inferenciais para verificar diferenças entre clusters. As distribuições foram avaliadas quanto à normalidade pelo teste de Shapiro–Wilk [Razali and Wah 2011] e quanto à homogeneidade de variâncias pelo teste de Levene [Levene 1960]. Em seguida, empregou-se o teste *t* para grupos independentes (ou

variante de Welch quando aplicável) para comparar o pré-teste e a pontuação final, conforme recomendações de [Derrick et al. 2016]. O tamanho de efeito foi calculado por meio do índice de Cohen's  $d$  [Cohen 1988].

A associação entre clusters e trilhas adaptativas foi examinada pelo teste Qui-Quadrado de Independência, com tabelas de contingência geradas diretamente no Colab. Gráficos Q-Q foram utilizados para complementar a inspeção de normalidade. A Figura 2 apresenta um exemplo dos gráficos Q-Q gerados para avaliação das distribuições.




Figura 2. Gráficos Q-Q utilizados para avaliar a normalidade no pré-teste entre clusters.

### 3.6. Análises em Múltiplas Dimensões

A análise quantitativa foi organizada em quatro dimensões complementares:

1. **Dimensão cognitiva:** comparação das notas por tópico entre clusters.
2. **Dimensão metacognitiva:** percepção de dificuldade.
3. **Dimensão afetiva:** autoconfiança reportada.
4. **Dimensão adaptativa:** escore fuzzy e trilhas escolhidas.

Além disso, análises integradas permitiram identificar pontos de convergência e divergência entre clusters ao longo do curso, considerando não apenas indicadores cognitivos, metacognitivos e afetivos utilizados no processo adaptativo, mas também a experiência do usuário avaliada ao final da intervenção, bem como a sensibilidade da lógica fuzzy às alterações de desempenho e percepção dos estudantes.

## 4. Resultados e Discussão

Esta seção apresenta os achados derivados da análise exploratória, da clusterização baseada no diagnóstico inicial e dos procedimentos estatísticos aplicados para investigar diferenças entre os perfis de estudantes. Os resultados são discutidos à luz das quatro dimensões avaliadas: cognitiva, metacognitiva, afetiva e adaptativa, permitindo compreender como o sistema fuzzy modulou o percurso dos participantes ao longo do curso.

### 4.1. Perfis Iniciais Identificados via Clusterização

O algoritmo *k-means* aplicado aos dados do diagnóstico e do pré-teste indicou a formação de dois clusters, representando perfis distintos de entrada. O *cluster 0* corresponde a estudantes com ligeiramente maior desempenho inicial, enquanto o *cluster 1* agrupa estudantes com menor nota no pré-teste e maior variabilidade em seus indicadores iniciais.

Apesar dessa diferença, o teste  $t$  para o pré-teste não identificou diferença estatisticamente significativa entre os clusters ( $t = 1.75$ ,  $p = 0.106$ ), indicando que ambos iniciaram o curso em condições relativamente semelhantes. Esse equilíbrio inicial é relevante para a validade interna, pois evita que diferenças prévias confundam a interpretação das trajetórias subsequentes.

#### 4.2. Dimensão Cognitiva: Desempenho por Tópico

A Tabela 1 apresenta as médias cognitivas por tópico. Observou-se que o *cluster 0* obteve notas mais altas em T01 e T02, refletindo sua vantagem inicial. No entanto, no T03 — ponto de maior complexidade do curso — ambos os grupos convergiram para desempenho semelhante (56.0 vs. 57.8). Essa convergência sugere que o tópico exige habilidades que desafiam todo o grupo, independentemente do perfil inicial.

**Tabela 1. Médias cognitivas por tópico e por cluster.**

Cluster	T01	T02	T03	T04	T05
0	96.0	84.0	56.0	56.0	68.0
1	77.8	82.2	57.8	37.8	53.3

Nos tópicos finais (T04 e T05), o *cluster 1* manteve desempenho inferior, refletindo dificuldades acumuladas. Entretanto, essas diferenças não foram suficientemente grandes para gerar distinções significativas na avaliação final, conforme discutido posteriormente. Esses achados são consistentes com estudos que mostram que sistemas adaptativos podem reduzir disparidades de desempenho ao longo do tempo [Hwang et al. 2020].

#### 4.3. Dimensão Metacognitiva: Percepção de Dificuldade

A análise de dificuldade percebida (Tabela 2) revela que estudantes do *cluster 1* relataram maior dificuldade em quase todos os tópicos, especialmente em T02 e T05. Em T03, ambos os grupos reportaram dificuldade elevada (média = 4.0), reforçando a identificação do tópico como ponto crítico.

**Tabela 2. Médias de dificuldade percebida por tópico.**

Cluster	T01	T02	T03	T04	T05
0	3.00	2.80	4.00	3.40	3.20
1	3.78	4.78	4.00	3.67	4.22

Esse padrão sugere que, embora a performance cognitiva dos clusters tenha convergido em diversos momentos, a percepção subjetiva de dificuldade foi mais elevada entre estudantes com menor proficiência inicial, alinhando-se aos achados de [Hwang et al. 2020] sobre o papel da percepção metacognitiva em ambientes adaptativos.

#### 4.4. Dimensão Afetiva: Autoconfiança

A análise afetiva mostrou que o *cluster 0* apresentou maiores níveis de autoconfiança em todos os tópicos (Tabela 3). Em T03, ambos os grupos exibiram queda acentuada, o que reforça sua complexidade cognitiva. Estudantes do *cluster 1* mantiveram autoconfiança consistentemente mais baixa, o que pode influenciar a seleção de trilhas adaptativas e a necessidade maior de suporte pedagógico.

**Tabela 3. Médias de autoconfiança por tópico.**

Cluster	T01	T02	T03	T04	T05
0	3.60	3.80	2.40	2.80	3.00
1	2.56	2.89	2.22	2.67	2.56


#### 4.5. Dimensão Adaptativa: Scores Fuzzy e Trilhas Seleccionadas

Os valores do escore fuzzy (Tabela 4) refletem a integração das dimensões anteriores. O *cluster 0* apresentou escores mais altos em todos os tópicos, sobretudo em T01 e T02. Em T03, os escores de ambos os grupos caíram significativamente, evidenciando um ponto de maior exigência cognitiva.

**Tabela 4. Médias dos scores fuzzy por tópico.**

Cluster	T01	T02	T03	T04	T05
0	84.0	76.8	40.8	41.8	55.2
1	57.1	51.0	30.8	30.0	40.3

A distribuição das trilhas adaptativas (Figura 3) confirma a coerência do comportamento do sistema: o *cluster 0* recebeu maior proporção de trilhas de Desafio nos primeiros tópicos, enquanto o *cluster 1* recebeu mais trilhas de Reforço ao longo do curso. O T03 novamente se destacou, com altos índices de Reforço em ambos os grupos.

**Figura 3. Distribuição percentual das trilhas adaptativas por tópico e por cluster.**

O teste Qui-Quadrado aplicado à distribuição das trilhas não identificou associações estatisticamente significativas entre cluster e trilha (todas as comparações com  $p \geq 0.11$ ). Esse resultado é esperado diante da amostra reduzida (14 estudantes) e não invalida as diferenças observadas nos padrões de trajetória. Estudos prévios destacam que sistemas adaptativos tendem a produzir ajustes graduais, e não distinções rígidas entre perfis [Chrysafiadi et al. 2023].

#### 4.6. Experiência do Usuário (UX)

A experiência do usuário foi avaliada por meio de sete itens (ux1–ux7), contemplando clareza das explicações, adequação do nível de dificuldade, percepção de aprendizagem, autoconfiança nas atividades práticas, uso do ambiente Tinkercad, colaboração entre pares

**Tabela 5. Descritivo da Experiência do Usuário (UX) por Cluster.**

Cluster	<i>UX_mean</i>	<i>UX_sum</i>
0	3.23 (0.69)	22.6 (4.83)
1	3.43 (0.96)	24.0 (6.71)

e motivação para continuidade dos estudos em robótica. O escore médio (*UX\_mean*) foi calculado a partir das respostas, com médias por cluster descritas na Tabela 5.

A comparação entre os clusters por meio do teste de *Mann–Whitney U* não indicou diferença estatisticamente significativa na experiência do usuário ( $U = 17.0$ ,  $p = 0.5031$ ), com tamanho de efeito pequeno ( $r = 0.196$ ). A consistência interna do instrumento foi considerada adequada, conforme o valor de Cronbach's alpha ( $= 0.8038$ ).

Do ponto de vista pedagógico, a similaridade na experiência do usuário entre os clusters, apesar de diferenças nos perfis cognitivos e metacognitivos, sugere que o sistema adaptativo proporcionou uma experiência de aprendizagem equilibrada, alinhando-se a evidências de que abordagens adaptativas podem reduzir disparidades na percepção do aprendizado [Chrysafiadi et al. 2023].

#### 4.7. Comparação de Desempenho Final

A comparação entre os clusters na pontuação final revelou ausência de diferença estatisticamente significativa ( $t = 0.72$ ,  $p = 0.488$ ), com tamanho de efeito pequeno ( $d = 0.40$ ). No entanto, o *cluster 0* apresentou média ligeiramente superior (7.0 vs. 6.22). Esse comportamento é consistente com a literatura que descreve sistemas adaptativos como mecanismos equalizadores, capazes de reduzir disparidades de desempenho entre grupos heterogêneos [Singh et al. 2022].

#### 4.8. Discussão do Impacto do Sistema Adaptativo

Os resultados indicam que, embora o sistema adaptativo tenha oferecido trilhas diferenciadas para os dois clusters, a experiência do usuário foi positiva e similar, sugerindo que a adaptação pedagógica não afetou negativamente a percepção dos estudantes sobre o curso. A principal contribuição do sistema parece estar na sua capacidade de equalizar as trajetórias de aprendizagem, sem comprometer a qualidade da experiência educacional. Esses achados corroboram com a literatura sobre sistemas adaptativos em ambientes de aprendizagem, que destacam a importância da personalização para a eficácia pedagógica [Al Duhayyim and Newbury 2018, Prihar et al. 2022]. Esses achados reforçam o potencial da lógica fuzzy como estratégia de personalização em cursos introdutórios de computação, especialmente em contextos com heterogeneidade de perfis.

### 5. Conclusão

Este trabalho apresentou o desenvolvimento e a avaliação de um recurso educacional adaptativo para o ensino introdutório de Robótica com Arduino, fundamentado em um mecanismo de inferência fuzzy capaz de integrar dimensões cognitivas, metacognitivas e afetivas na recomendação de trilhas personalizadas. A análise quantitativa realizada com dados reais de 14 estudantes permitiu compreender, de forma integrada, como diferentes perfis de entrada interagem com o sistema e como as decisões adaptativas influenciam o percurso formativo.

A clusterização baseada no diagnóstico inicial identificou dois perfis distintos de estudantes. Embora o *cluster 0* tenha apresentado desempenho ligeiramente superior no pré-teste, não foram observadas diferenças estatisticamente significativas entre os grupos, sugerindo condições iniciais relativamente homogêneas. Ao longo do curso, contudo, emergiram diferenças claras na percepção de dificuldade, nos níveis de autoconfiança e nos escores fuzzy, indicando que estudantes com menor proficiência inicial enfrentaram maiores desafios, especialmente no Tópico 3, que se destacou como ponto de maior complexidade cognitiva e emocional.

Apesar dessas diferenças, o desempenho final dos estudantes não apresentou distinção estatisticamente significativa, e o tamanho de efeito calculado foi pequeno. Esse achado sugere que o sistema adaptativo pode ter exercido um papel equalizador, oferecendo suporte adicional a estudantes com maiores dificuldades por meio de trilhas de Reforço, ao mesmo tempo em que desafiou estudantes mais avançados por meio de trilhas de Desafio. A distribuição das trilhas ao longo dos tópicos confirma que a lógica fuzzy respondeu de modo coerente às variações de desempenho e percepção dos participantes.

Os resultados obtidos reforçam o potencial da lógica fuzzy como elemento de personalização em ambientes educacionais, especialmente em contextos marcados pela heterogeneidade de perfis e pela necessidade de atender simultaneamente a estudantes com níveis distintos de conhecimento. A combinação de mecanismos adaptativos, atividades práticas de robótica e estratégias de monitoramento contínuo mostrou-se capaz de promover trajetórias de aprendizagem mais equilibradas, com indícios de redução de disparidades entre grupos.

Por fim, este estudo contribui para a literatura ao demonstrar, em ambiente real, a aplicação integrada de análises cognitivas, metacognitivas, afetivas e adaptativas, apoiadas por um pipeline reprodutível de análise estatística em Python.

## 6. Trabalhos Futuros

Como continuidade deste estudo, identificam-se oportunidades em três frentes principais. A primeira consiste na ampliação da amostra, permitindo elevar o poder estatístico das análises e aprofundar a investigação de diferenças entre perfis de estudantes. A segunda envolve a evolução do mecanismo adaptativo, incluindo novas regras fuzzy, calibração dinâmica das funções de pertinência e exploração de modelos híbridos que combinem lógica fuzzy com técnicas de aprendizagem de máquina supervisionada e não supervisionada. Por fim, sugere-se a realização de estudos longitudinais para avaliar efeitos de médio e longo prazo sobre autonomia, engajamento e aprendizagem em contextos de educação em computação.

## 7. Ameaças à Validade

Este estudo apresenta algumas limitações que devem ser consideradas. **Validade interna:** o tamanho reduzido da amostra (14 participantes) limitou a significância estatística de alguns testes, podendo mascarar efeitos reais. Ressalta-se, contudo, que o mecanismo adaptativo fuzzy opera em nível individual, produzindo decisões pedagógicas contínuas baseadas em inferência local, independentemente de generalizações populacionais. Ainda assim, reconhece-se que estudos com amostras maiores são necessários para fortalecer a robustez estatística dos achados. **Validade externa:** os resultados refletem um

grupo específico de estudantes, inseridos em um contexto sociopedagógico particular; assim, a generalização para outras populações deve ser feita com cautela. **Validade de construção:** embora o sistema adaptativo integre dimensões cognitivas, metacognitivas e afetivas, alguns construtos — como autoconfiança e dificuldade percebida — foram medidos por autorelato, o que pode introduzir vieses conhecidos em pesquisas educacionais. **Validade estatística:** a baixa frequência de algumas trilhas dificultou a aplicação de testes como o Qui-Quadrado, reduzindo a sensibilidade para identificar associações entre clusters e percursos adaptativos.

## 8. Considerações Éticas

O estudo foi conduzido em conformidade com as diretrizes da Resolução CNS 510/2016, que regulamenta pesquisas em Ciências Humanas e Sociais no Brasil, e foi submetido ao Comitê de Ética em Pesquisa da UNIRIO, registrado na Plataforma Brasil sob o CAAE: 92792825.7.0000.5285. Todos os participantes — por serem menores de idade — foram incluídos mediante Termo de Assentimento Livre e Esclarecido (TALE) e autorização de seus responsáveis. Os dados foram coletados de forma automatizada e anonimizados antes da análise, garantindo a proteção da identidade dos estudantes, em conformidade com a Lei Geral de Proteção de Dados (LGPD). O recurso educacional não envolve riscos físicos ou emocionais aos participantes, e sua utilização se deu exclusivamente para fins pedagógicos e de pesquisa. Optou-se por não constituir grupo controle, de modo a garantir igualdade de oportunidades de aprendizagem entre os participantes, considerando tratar-se de menores de idade e que a intervenção tinha finalidade educacional.

### Conformidade com Ciência Aberta

Os scripts e notebooks utilizados nas análises estatísticas, visualizações e processos de clusterização, bem como os códigos necessários para reprodução do curso adaptativo e do mecanismo fuzzy implementado, estão disponíveis publicamente em: <https://github.com/rgrion/adaptativorobotica>. A iniciativa reforça o compromisso com a transparência, replicabilidade e reprodutibilidade científica, estimulando o reaproveitamento metodológico por educadores e pesquisadores interessados na análise de dados educacionais e no desenvolvimento de sistemas adaptativos com ferramentas acessíveis.

### Uso de Inteligência Artificial

Ferramentas de Inteligência Artificial Generativa, como o ChatGPT, foram empregadas unicamente para apoiar a revisão textual, aprimorar a clareza de trechos e organizar referências bibliográficas. Todo o conteúdo científico — incluindo concepção da pesquisa, definição da metodologia, desenvolvimento dos códigos, execução das análises e interpretação dos resultados — foi elaborado integralmente pelos autores, que assumem total responsabilidade pelo trabalho.

### Agradecimentos

Este estudo contou com financiamento parcial da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e da Universidade Federal do Estado do Rio de Janeiro (UNIRIO), no âmbito de projeto desenvolvido institucionalmente e aplicado por meio do Programa de Extensão da Educação Superior na Pós-Graduação (PROEXT-PG) e do Centro de Extensão e Pesquisa em Favelas (CEP Favelas).

## Referências

- Al Duhayyim, M. and Newbury, P. (2018). Concept-based and fuzzy adaptive e-learning. In *Proceedings of the 3rd International Conference on Information and Education Innovations*, ICIEI '18, page 49–56, New York, NY, USA. Association for Computing Machinery.
- Ananias, E. and Gaspar, P. D. (2022). A low-cost collaborative robot for science and education purposes to foster the industry 4.0 implementation. *Applied System Innovation*, 5(4).
- Anderson, L. W. and Krathwohl, D. R. (2001). *A Taxonomy for Learning, Teaching, and Assessing: A Revision of Bloom's Taxonomy of Educational Objectives*. Addison Wesley Longman.
- Chrysafiadi, K., Virvou, M., Tsihrintzis, G. A., and Hatzilygeroudis, I. (2023). Evaluating the user's experience, adaptivity and learning outcomes of a fuzzy-based intelligent tutoring system for computer programming for academic students in greece. *Education and Information Technologies*, 28(6):6453–6483.
- Cohen, J. (1988). *Statistical Power Analysis for the Behavioral Sciences*. Lawrence Erlbaum Associates, 2 edition.
- Derrick, B., Toher, D., and White, P. (2016). Why welch's test is type i error robust. *The Quantitative Methods for Psychology*, 12(1):30–38.
- Eryılmaz, 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).
- Flavell, J. H. (1979). Metacognition and cognitive monitoring: A new area of cognitive-developmental inquiry. *American psychologist*, 34(10):906.
- García-Tudela, P. A. and Marín-Marín, J.-A. (2023). Use of arduino in primary education: A systematic review. *Education Sciences*, 13(2).
- Géron, A. (2022). *Hands-On Machine Learning with Scikit-Learn, Keras, and Tensor-Flow*. O'Reilly Media, 3 edition.
- Hursen, C. and Bicen, H. (2025). Global scientific landscape of ai and fuzzy logic in education: A bibliometric and thematic evolution analysis. In *CEUR Workshop Proceedings: Workshops at the 8th International Conference on Applied Informatics (ICAIW 2025)*, pages 80–89, Ben Guerir, Morocco. CEUR-WS.org.
- Hwang, G.-J., Sung, H.-Y., Chang, S.-C., and Huang, X.-C. (2020). A fuzzy expert system-based adaptive learning approach to improving students' learning performances by considering affective and cognitive factors. *Computers and Education: Artificial Intelligence*, 1:100003.
- Levene, H. (1960). Robust tests for equality of variances. In *Contributions to Probability and Statistics: Essays in Honor of Harold Hotelling*, pages 278–292. Stanford University Press.
- Maryono, D., Sajidan, Akhyar, M., Sarwanto, Wicaksono, B. T., and Prakisyta, 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.
- Mayer, R. E. (2002). Multimedia learning. In *Psychology of Learning and Motivation*, volume 41, pages 85–139. Elsevier.
- Panadero, E. (2017). A review of self-regulated learning: Six models and four directions for research. *Frontiers in psychology*, 8:422.
- Prihar, E., Haim, A., Sales, A., and Heffernan, N. (2022). Automatic interpretable personalized learning. In *Proceedings of the Ninth ACM Conference on Learning @ Scale, L@S '22*, page 1–11, New York, NY, USA. Association for Computing Machinery.
- Razali, N. M. and Wah, Y. B. (2011). Power comparisons of shapiro–wilk, kolmogorov–smirnov, lilliefors and anderson–darling tests. *Journal of Statistical Modeling and Analytics*, 2(1):21–33.
- Rousseeuw, P. J. (1987). Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*, 20:53–65.
- Singh, N., Gunjan, V. K., and Nasralla, M. M. (2022). A parametrized comparative analysis of performance between proposed adaptive and personalized tutoring system “seis tutor” with existing online tutoring system. *IEEE Access*, 10:39376–39386.
- Slavin, R. E. (1995). *Cooperative Learning: Theory, Research, and Practice*. Allyn and Bacon.
- Szczepański, M. and Marciniak, J. (2023). Application of a fuzzy controller in adaptive e-learning content used to evaluate student activity. *Procedia Comput. Sci.*, 225(C):2526–2535.
- Tan, P.-N., Steinbach, M., and Kumar, V. (2016). *Introduction to data mining*. Pearson Education India, 1 edition.
- Troussas, C., Krouska, A., Mylonas, P., and Sgouropoulou, C. (2023). Personalized learner assistance through dynamic adaptation of chatbot using fuzzy logic knowledge modeling. *2023 18th International Workshop on Semantic and Social Media Adaptation & Personalization (SMAP)18th International Workshop on Semantic and Social Media Adaptation & Personalization (SMAP 2023)*, pages 1–5.
- Vygotsky, L. S. and Cole, M. (1978). *Mind in society: Development of higher psychological processes*. Harvard university press.