

# Arquitetura Pedagógica Apoiada por IA para o Desenvolvimento da Aprendizagem Autorregulada em Estudantes

Geycy D. O. Lima<sup>1,2</sup>, Juliete A. R. Costa<sup>1,3</sup>, Rafael D. Araújo<sup>1</sup>, Fabiano A. Dorça<sup>1</sup>

<sup>1</sup>Faculdade de Computação (FACOM)  
Universidade Federal de Uberlândia (UFU), Uberlândia, MG – Brasil

<sup>2</sup>Instituto Federal de Educação, Ciência e Tecnologia do Sul de Minas  
(IFSULDEMINAS), Inconfidentes, MG – Brasil

<sup>3</sup>Instituto Federal de Educação, Ciência e Tecnologia do Sul de Minas  
(IFSULDEMINAS), Carmo de Minas, MG – Brasil

{geycy.lima, juliete.costa}@ifsuldeminas.edu.br  
{rafael.araujo, fabianodor}@ufu.br

**Abstract.** *This study investigates the impacts of a Pedagogical Architecture (PA) supported by Artificial Intelligence (AI) on student engagement and the promotion of Self-Regulated Learning (SRL) in Virtual Learning Environments (VLEs). The research was conducted in an introductory Python programming extension course, where the proposed architecture was implemented in Moodle, one of the most widely used VLE platforms globally. Through the analysis of educational data and the application of data mining techniques, this study aims to identify student interaction patterns and correlate them with academic performance, offering a deeper understanding of the architecture's effectiveness in fostering self-regulation skills and improving educational outcomes.*

**Resumo.** *Este trabalho investiga os impactos de uma Arquitetura Pedagógica (AP) apoiada por Inteligência Artificial (IA) no engajamento dos estudantes e na promoção da Aprendizagem Autorregulada (SRL) em Ambientes Virtuais de Aprendizagem (AVAs). A pesquisa foi realizada em um curso de extensão de Introdução à Programação em Python, onde foi implementada a arquitetura proposta no Moodle. Através da análise de dados educacionais e da aplicação de técnicas de mineração de dados, este estudo busca identificar padrões de interação dos estudantes e relacioná-los com o desempenho acadêmico, oferecendo uma compreensão aprofundada sobre a eficácia da arquitetura em fomentar habilidades de autorregulação e melhorar os resultados educacionais.*

## 1. Introdução

A Pandemia da COVID-19 [World Health Organization 2020] gerou mudanças drásticas na educação em todo o mundo, obrigando as instituições de ensino a adaptarem seus métodos para garantir a continuidade da educação enquanto mitigavam os riscos de contaminação. Os Ambientes Virtuais de Aprendizagem (AVAs) tornaram-se cruciais nessa adaptação, permitindo que a aprendizagem continuasse de forma remota.

AVAs são sistemas online voltados para a educação, que permitem a interação entre estudantes e professores, acesso a materiais didáticos, realização de atividades avaliativas e monitoramento do progresso acadêmico. A flexibilidade e acessibilidade desses ambientes os tornam essenciais para a educação moderna, especialmente durante a pandemia, que limitou a educação presencial. O Moodle é um dos AVAs mais usados globalmente [Moodle 2024]. A rápida adaptação a esses sistemas gerou grandes volumes de dados educacionais, úteis para analisar e melhorar métodos de ensino [Coman et al. 2020]. Esses dados são especialmente valiosos para aprimorar a Aprendizagem Autorregulada (*do inglês, Self-Regulated Learning - SRL*), oferecendo insights detalhados sobre a interação e o desenvolvimento dos estudantes em ambientes virtuais.

Visando melhorar o desempenho acadêmico e proporcionar uma experiência de aprendizagem mais eficaz e autônoma, desenvolvemos uma AP apoiada em IA para auxiliar a SRL. A AP foi implementada no Moodle, e dados reais de um curso de extensão de Introdução ao Python foram coletados. O principal objetivo é evidenciar os perfis de SRL dos estudantes utilizando técnicas de Mineração de Dados Educacionais (do inglês, *Educational Data Mining - EDM*) e relacionar com o seu desempenho acadêmico. A questão central que orienta esta pesquisa é: quais são os impactos da implementação de uma AP baseada em IA sobre o engajamento dos estudantes e na promoção da SRL em um AVA?

## **2. Trabalhos Relacionados**

### **2.1. Aprendizagem Autorregulada**

A SRL é um framework conceitual que abrange aspectos cognitivos, metacognitivos, comportamentais, motivacionais e emocionais/afetivos da aprendizagem [Panadero 2017]. Em contextos competitivos e avaliativos, as realizações humanas dependem fortemente da capacidade de autorregulação do indivíduo [Zimmerman e Martinez-Pons 1986].

Segundo [Zimmerman e Martinez-Pons 1986], estudantes com alto desempenho acadêmico tendem a realizar autoavaliações com mais frequência, o que permite redefinir metas e desenvolver novas estratégias de aprendizagem para melhorar o desempenho acadêmico. Os modelos de SRL, que são cíclicos, abrangem três fases principais: a) Planejamento, b) Execução e c) Avaliação, com cada fase focando em diferentes aspectos do processo de autorregulação [Panadero 2017] [Puustinen e Pulkkinen 2001].

### **2.2. Arquitetura Pedagógica**

AP são abordagens que integram aspectos pedagógicos e tecnológicos para criar propostas educacionais inovadoras [Menezes et al. 2020]. Elas se baseiam na articulação entre a concepção construtivista de aprendizagem e a pedagogia da pergunta, focando em resolver problemas reais, transformar informações em conhecimento, incentivar a autoria e a cooperação, e promover a metacognição. Essas arquiteturas exigem uma postura ativa dos estudantes, envolvendo pesquisa, atividades interativas e o uso de tecnologias digitais, com o professor desempenhando um papel crucial na orientação e criação de um ambiente de aprendizagem colaborativo e reflexivo [Silva et al. 2023].

Ampliando a necessidade de um ambiente de aprendizagem interativo e reflexivo, os autores [Biancardi et al. 2021] destacam que o objetivo de uma AP é transformar o ambiente de ensino e aprendizagem, promovendo uma pedagogia que valorize a criatividade, a reflexão, a contestação e a inovação. No mesmo trabalho, eles afirmam que uma

AP busca criar um ecossistema cognitivo onde a tecnologia não é apenas um suporte, mas um elemento constitutivo das novas relações e formas de pensar.

### 2.3. Mineração de Dados Educacionais

EDM é uma área específica de mineração de dados que tem como foco a análise de dados relacionados a contextos educacionais [Costa et al. 2020]. O principal objetivo do EDM é melhorar a qualidade do processo de ensino e aprendizagem através da análise dos dados. De acordo com [Fischer et al. 2020], a análise desses dados é essencial para compreender melhor os estudantes, os processos de aprendizagem e o ambiente educacional. Essa exploração permite identificar padrões e tendências que podem personalizar e aprimorar as estratégias educativas, resultando em um ensino mais eficaz e adaptado às necessidades individuais. Especificamente, a análise de dados pode oferecer insights valiosos sobre a aprendizagem autorregulada, permitindo que educadores desenvolvam intervenções direcionadas para apoiar os estudantes na gestão e definição de sua própria aprendizagem.

## 3. Metodologia

A metodologia deste estudo é de caráter experimental. A Figura 1 apresenta suas etapas: (1) desenvolvimento da AP, (2) execução da abordagem, incluindo a oferta do curso e aplicação de questionários SRL, (3) coleta de dados, (4) pré-processamento dos dados para definir os atributos do *dataset*, (5) agrupamento e (6) análises dos resultados, relacionando o engajamento dos estudantes com os recursos da AP e seu desempenho acadêmico



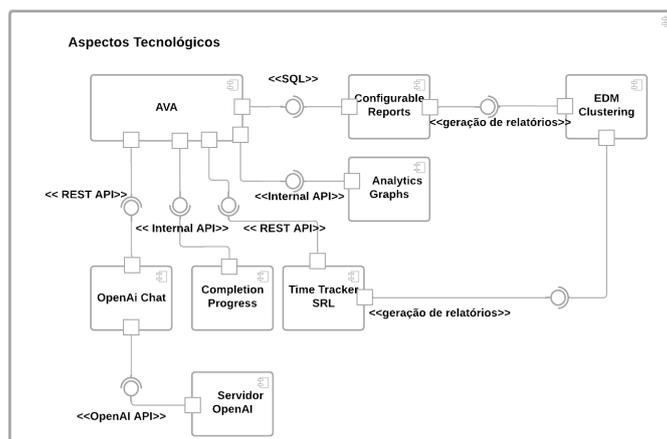
Figura 1. Etapas da Metodologia aplicada no trabalho

### 3.1. Desenvolvimento da Arquitetura Pedagógica

Este estudo baseou-se na definição proposta por [Behar et al. 2020], que posiciona a AP como o núcleo de um modelo pedagógico. A AP é composta por aspectos organizacionais, de conteúdo, metodológicos e tecnológicos, e as interações entre esses componentes são fundamentais para dar à AP seu verdadeiro significado. A Figura 2 mostra um diagrama de componentes Linguagem de Modelagem Unificada (UML) do módulo Aspectos Tecnológicos, que é o foco dessa pesquisa.

Conforme o diagrama o AVA fornece dados por meio de APIs REST e internas, acessados por plugins como o Configurable Reports, que gera relatórios posteriormente utilizados pelo componente EDM Clustering para análises dos dados coletados. O Analytics Graphs é responsável por criar visualizações interativas a partir dos dados internos do Moodle, enquanto o OpenAI Chat se comunica com o Moodle via API REST e utiliza a API da OpenAI para oferecer suporte em tempo real aos alunos. O Completion Progress utiliza APIs internas para monitorar o progresso dos alunos, e o Time Tracker SRL acompanha o tempo gasto nas atividades, também utilizando APIs REST.

A definição dos aspectos tecnológicos incluiu a instalação do Moodle em um servidor, utilizando a infraestrutura da Google Cloud. Para garantir a estabilidade e acessibilidade do ambiente virtual, foi configurado um domínio próprio e um IP fixo. Essa



**Figura 2. Diagrama de Componentes do Módulo - Aspectos Tecnológicos**

configuração inicial é crucial para assegurar que o ambiente de ensino seja robusto e confiável, proporcionando uma base sólida para as atividades subsequentes.

Em seguida, foi realizada a configuração do Moodle, incluindo o desenvolvimento, instalação e ajuste de plugins essenciais para apoiar a aprendizagem autorregulada. Um novo plugin, denominado Time Tracker SRL, foi desenvolvido especificamente para monitorar o tempo que os estudantes dedicam às atividades, permitindo que o professor defina um tempo estimado que os estudantes devem gastar em cada tarefa.

O processo de desenvolvimento envolveu o uso de PHP, a linguagem central para o desenvolvimento do plugin. A linguagem JavaScript foi empregado para melhorar a interatividade e a responsividade da interface do usuário, permitindo atualizações dinâmicas sem recarregamento completo da página. As linguagens HTML e CSS foram utilizados para estruturar e estilizar a interface. O gerenciamento eficiente de dados foi possibilitado pelo MySQL, o sistema de gerenciamento de banco de dados padrão do Moodle, enquanto XML foi utilizado para definir a estrutura do banco de dados e configurar eventos e serviços do plugin. Além disso, a API do Moodle foi essencial para garantir a integração perfeita com as funcionalidades principais da plataforma, mantendo a compatibilidade com diferentes versões do Moodle.

Além do plugin desenvolvido, foram instalados outros plugins, como o Analytics Graphs<sup>1</sup>, que oferece visualizações detalhadas dos dados de aprendizagem, o Configurável Reports<sup>2</sup>, que permite a criação de relatórios personalizados sobre o desempenho dos estudantes e o Completion Progress<sup>3</sup>, que permite aos estudantes acompanhar graficamente seu progresso no curso. Por fim, o plugin OpenAI Chat<sup>4</sup> foi integrado, permitindo a incorporação do ChatGPT ao Moodle. Essa ferramenta proporciona uma interface gráfica para interação via chat dentro do ambiente do curso.

### 3.2. Execução da Abordagem

A execução da abordagem consistiu na implementação da AP desenvolvida em um ambiente de ensino real, utilizando a plataforma Moodle. Nesta etapa, o professor definiu

<sup>1</sup> [https://moodle.org/plugins/block\\_analytics\\_graphs](https://moodle.org/plugins/block_analytics_graphs)

<sup>2</sup> [https://moodle.org/plugins/block\\_configurable\\_reports](https://moodle.org/plugins/block_configurable_reports)

<sup>3</sup> [https://moodle.org/plugins/block\\_completion\\_progress](https://moodle.org/plugins/block_completion_progress)

<sup>4</sup> [https://moodle.org/plugins/block\\_openai\\_chat](https://moodle.org/plugins/block_openai_chat)

os aspectos metodológicos, o planejamento pedagógico e o conteúdo a ser ministrado no curso, assegurando que a estrutura do curso estivesse alinhada com os objetivos educacionais propostos.

A primeira implementação do curso de Introdução ao Python ocorreu entre maio e junho de 2024, com 50 horas de duração. Um total de 49 estudantes se inscreveu, e o curso foi estruturado em cinco semanas de conteúdo, seguidas de duas semanas para o desenvolvimento de um projeto final. Foram realizadas sessões síncronas e assíncronas para facilitar a interação, promover o engajamento e atender às necessidades educacionais dos estudantes. Além disso, dois questionários adaptados foram aplicados antes e ao final do curso para avaliar as estratégias de autorregulação dos estudantes. Esses questionários forneceram dados qualitativos e quantitativos valiosos sobre a eficácia da AP em promover a autorregulação.

### 3.3. Coleta de Dados

A coleta de dados foi realizada no Moodle, com base na participação dos estudantes do curso de extensão em Introdução à Python em uma instituição de ensino pública. É importante destacar que, antes do início da coleta de dados, o projeto foi submetido e aprovado pelo Comitê de Ética da instituição, assegurando que todos os procedimentos seguissem as diretrizes éticas de pesquisa.

Os logs de atividade do Moodle são utilizados para monitorar as interações dos estudantes com a plataforma. Esses logs fornecem informações detalhadas sobre o uso dos recursos do curso. Para a construção do *dataset* são coletados quatro arquivos: 1) Relatório de Notas, que contém as notas dos estudantes em cada atividade e a nota final na disciplina; 2) Relatório de *Logs*, que registra todos os eventos realizados pelos usuários no curso; e 3) Relatório do *plugin* Configurable Reports, que detalha a quantidade de tempo que cada usuário dedicou a cada disciplina; 4) Relatório gerado pelo *plugin* Time Tracker SRL, que fornecem uma visão detalhada do tempo despendido pelos estudantes em cada atividade cadastrada do curso, como a participação em fóruns.

Além dos dados de uso do Moodle, questionários estruturados foram aplicados antes e após o curso para avaliar as habilidades de autorregulação dos estudantes. Esses questionários, baseados no MSLQ (*Motivated Strategies for Learning Questionnaire*) [Pintrich et al. 1991], permitirão medir a evolução das habilidades de autorregulação ao longo do curso. A aplicação dos questionários é crucial para identificar mudanças nas estratégias de aprendizagem dos estudantes e avaliar o impacto da AP proposta.

### 3.4. Pré-Processamento

O pré-processamento e a construção do *dataset final* foram realizados utilizando a biblioteca Pandas em Python, que oferece estruturas de dados intuitivas e ferramentas robustas para análise e manipulação de grandes volumes de dados [McKinney et al. 2010]. O curso contou com 49 estudantes inscritos, mas 11 deles nunca acessaram a plataforma, não gerando logs de eventos. Foram excluídos os logs de eventos gerados exclusivamente por professores (N=8) e administradores (N=40), resultando em 36 logs de eventos relevantes no sistema. No total, 38 estudantes geraram logs de eventos e obtiveram nota final no curso.

O Moodle coleta uma variedade de atributos em seus *logs* de eventos, cuja quantidade e tipos podem variar dependendo das configurações específicas e dos *plugins* adicio-

nais instalados. Para analisar a relação entre variáveis, foi utilizada a matriz de correlação com o coeficiente de Spearman, uma vez que os dados não seguiram uma distribuição normal conforme o teste de Shapiro-Wilk ( $valor_p < 0.05$ ). O coeficiente de Spearman, que mede a relação monotônica entre duas variáveis [Spearman 1961], foi aplicado ao *dataset*, e atributos com forte correlação ( $> 0.7$ ) foram agregados [Zar 2005].

Os atributos finais do *dataset* incluem: [1] *id* do usuário; [2] *publicacao* (quantidade de publicações feitas pelo estudante); [3] *visualizacoes* (quantidade de visualizações de recursos durante o curso); [4] *atividade\_concluida* (quantidade de atividades concluídas); [5] *questionario* (quantidade de ações relacionadas a questionários); e [6] *tempo* (em segundos, dedicado ao curso na plataforma). Os atributos *id* e *tempo* não são eventos gerados pelo sistema.

### 3.5. Agrupamento

O estudo avalia três algoritmos de clustering no Moodle para evidenciar perfis de SRL: K-Means, HDBSCAN e Clustering Aglomerativo. O K-Means foi escolhido pela eficiência em criar *clusters* bem definidos, o Clustering Aglomerativo por permitir uma análise detalhada das relações entre dados, e o HDBSCAN por lidar com densidades variadas e *outliers*. A combinação desses algoritmos proporciona uma análise que possa evidenciar perfis de SRL, oferecendo insights sobre engajamento e desempenho acadêmico. A Tabela 1 apresenta as melhores métricas de validação de *cluster* para cada algoritmo. O HDBSCAN não possui medidas de validação para  $K=3, 4$  e  $5$  porque não requer um número fixo de clusters.

**Tabela 1. Métricas de validação de clustering para diferentes algoritmos**

Algoritmo	Medidas de Validação	Clusters			
		2	3	4	5
K-means	Coefficiente de Silhueta	0.60	0.48	0.45	0.47
	Dunn Index	1.13	0.83	0.83	0.84
	Calinski-Harabasz	78.57	63.80	52.76	44.56
	Davies-Bouldin	0.53	0.91	0.78	0.68
Agglomerative Clustering	Coefficiente de Silhueta	0.59	0.48	0.47	0.44
	Dunn Index	0.23	0.27	0.31	0.33
	Calinski-Harabasz	76.13	63.80	51.98	46.87
	Davies-Bouldin	0.50	0.91	0.83	1.07
HDBSCAN	Coefficiente de Silhueta	0.533			
	Dunn Index	0.02			
	Calinski-Harabasz	40.39			
	Davies-Bouldin	2.65			

Índices do HBSCAN:  $min\_cluster\_size = 4, min\_samples = 2; outliers=2$

O K-Means com  $K = 2$  foi escolhido como o melhor algoritmo de clusterização pois se mostrou superior aos demais algoritmos testados em termos de métricas de validação interna. Ele obteve a maior pontuação no Índice de Silhouette 0.60 e Calinski-Harabasz 78.57, indicando boa coesão e separação dos clusters e maior Índice de Dunn 1.133, destacando sua homogeneidade e separação clara entre clusters.

## 4. Resultados e Discussão

Os resultados do agrupamento mostram que o **Cluster 0** é composto por 15 estudantes e o **Cluster 1** por 23 estudantes. As distribuições de densidade dos atributos (ver Figura 3) revelam diferenças significativas entre os *clusters*, confirmadas pelo teste Kruskal-Wallis com ( $valor_p < 0.05$ ) para todos os atributos. O **Cluster 0** apresenta uma maior concentração de estudantes com menor tempo de curso, enquanto o **Cluster 1** exibe tempos significativamente mais elevados, indicando maior dedicação. Além disso, os estudantes do **Cluster 0** têm menos visualizações e publicações, além de menor participação

em questionários, comparado aos do **Cluster 1**, que apresentam números substancialmente maiores em todas essas áreas. Os estudantes do **Cluster 1** também concluem mais atividades e fazem mais submissões, indicando maior interação com as atividades avaliativas. Os gráficos de densidade na Figura 3 destacam que os estudantes do **Cluster 1** são mais engajados e participativos no curso.

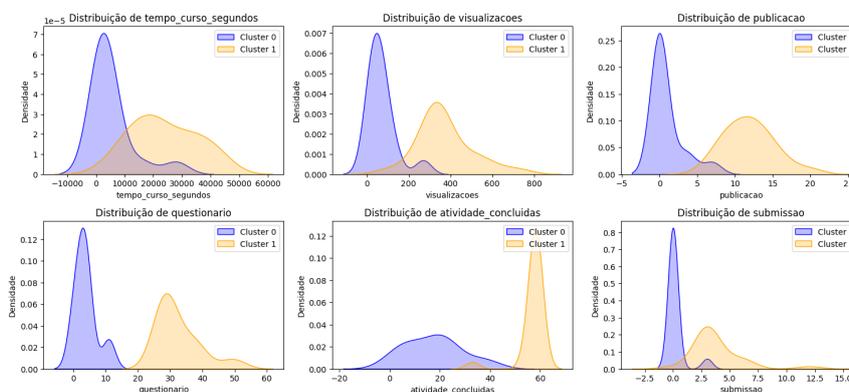


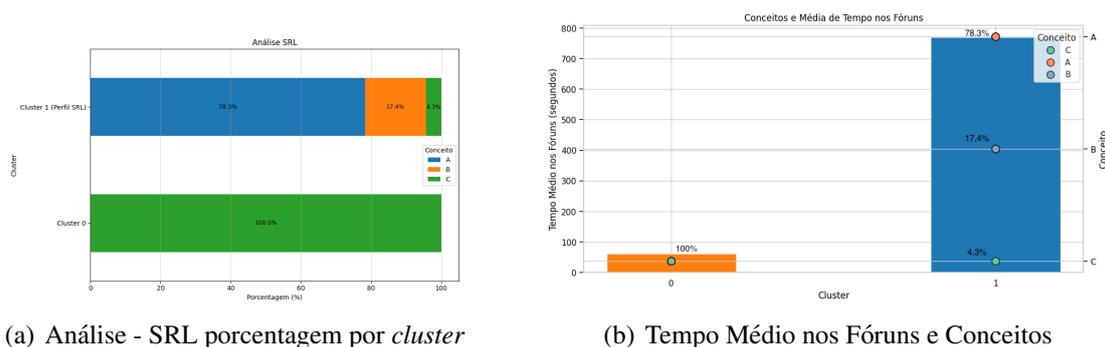
Figura 3. Gráficos de densidade para cada atributo

A Figura 4(a) mostra a distribuição dos conceitos dentro dos *clusters*. O **Cluster 1**, que evidencia um perfil SRL, é majoritariamente composto por estudantes com Conceito A, seguido por B e uma pequena fração com Conceito C, sugerindo que estudantes mais engajados tendem a obter melhores desempenhos acadêmicos. Em contraste, o **Cluster 0**, formado inteiramente por estudantes com Conceito C, evidencia um perfil SRL mais fraco, com menor participação nas atividades do curso. O teste de significância estatística *U* de Mann-Whitney [Urdan 2010] foi aplicado para verificar diferenças significativas entre as notas dos estudantes dos *clusters*, confirmadas pelo teste com  $valor_p < 0.05$ . Inicialmente, foi comprovado pelo teste Shapiro-Wilk que as notas dos estudantes em cada *cluster* não seguiam uma distribuição normal.

A Figura 4(b) que relaciona os conceitos com o tempo médio nos fóruns, observa-se que o **Cluster 0**, composto exclusivamente por estudantes com Conceito C, possui um tempo médio de participação nos fóruns significativamente menor. Em contraste, o **Cluster 1**, que inclui estudantes com Conceitos A (78.3%), B (17.4%) e C (4.3%), apresenta uma média de tempo nos fóruns muito maior, especialmente para aqueles com conceito A. Com base nessas análises, podemos inferir que estudantes com maior participação e dedicação nas atividades do curso, especialmente nos fóruns, tendem a evidenciar um perfil SRL, refletido em melhores conceitos acadêmicos. Portanto, a análise do tempo de participação nos fóruns e a composição dos clusters é crucial para identificar e fomentar comportamentos de aprendizagem autorregulada.

Questionários de autorregulação foram aplicados no início e ao final do curso, com um total de 22 estudantes participando de ambos os questionários. Os questionários foram adaptados a partir dos instrumentos de [Pintrich et al. 1991] e [Maldonado-Mahauad et al. 2020]. Com 18 perguntas, o questionário aborda aspectos como motivação, estratégias de aprendizagem cognitivas e metacognitivas, incluindo planejamento e definição de metas, além de estratégias de gerenciamento de recursos, como busca de ajuda, gerenciamento de tempo e organização do ambiente de estudo.

Os resultados da comparação das médias das respostas dos estudantes antes e de-



(a) Análise - SRL percentagem por *cluster*

(b) Tempo Médio nos Fóruns e Conceitos

**Figura 4. Análise dos perfis SRL em cada *cluster***

pois do curso mostram melhorias significativas em áreas-chave da autorregulação, especialmente nas estratégias de aprendizagem metacognitivas, que tiveram o maior aumento, com uma diferença de 1.045, indicando maior habilidade dos estudantes em estabelecer metas claras. A autoavaliação também apresentou uma melhoria substancial, com um aumento de 0.909, sugerindo que os estudantes se tornaram mais reflexivos e críticos em relação ao seu desempenho. No entanto, a questão relacionada à busca de ajuda mostrou uma redução de 0.318, sugerindo que os estudantes se tornaram menos propensos a procurar ajuda após o curso.

## 5. Conclusão

A análise dos eventos registrados nos logs do Moodle e seu pré-processamento resultaram em um *dataset* refinado, que permitiu uma avaliação detalhada dos padrões de interação e desempenho dos estudantes. Os algoritmos K-Means, HDBSCAN e Clustering Aglomerativo foram comparados, com o K-Means ( $K = 2$ ) apresentando os melhores resultados. Observou-se que estudantes com evidência de perfis SRL geralmente alcançam um desempenho acadêmico superior no curso. O **Cluster 1** com maior engajamento nos recursos de aprendizagem, como fóruns, apresentou uma proporção mais elevada de estudantes com melhores conceitos.

A análise dos dados do questionário de autorregulação revelou que os estudantes que utilizaram a AP apoiada por IA desenvolveram habilidades de autorregulação, refletidas em melhores desempenhos acadêmicos. Esses resultados corroboram a hipótese de que a utilização dos recursos da AP está associada a um melhor desempenho acadêmico. Futuros estudos poderiam explorar intervenções mais direcionadas para fortalecer ainda mais essas habilidades e investigar o impacto em diferentes contextos educacionais.

### 5.1. Próximas Etapas

As próximas etapas do trabalho visam aprofundar a análise dos dados coletados e fortalecer a compreensão dos impactos da AP no desenvolvimento da SRL. As ações planejadas incluem a condução de entrevistas em grupo focal com os estudantes, a fim de obter insights qualitativos sobre suas experiências e percepções do curso; a classificação detalhada dos atributos dos dados coletados, baseando-se na Teoria SRL; e a análise dos *datasets* construídos para identificar padrões e correlações, orientando futuras intervenções pedagógicas e melhorias na AP.

## Agradecimentos

Os autores agradecem o apoio do Instituto Federal de Educação, Ciência e Tecnologia do Sul de Minas Gerais - IFSULDEMINAS e da Universidade Federal de Uberlândia.

## Referências

- Behar, P., Chae, H., Natriello, G., e Silva, K. (2020). A pedagogical architecture from a hybrid course in a u.s media course: focused on digital competences. *Educação Unisinos*, 24:1–27.
- Biancardi, C., Cristina dos Santos de Andrade, J., Santana, S., e Silva de Menezes, C. (2021). Apa2i - uma arquitetura pedagógica aberta, adaptativa e inteligente para construção cooperativa de conhecimento. *Revista Novas Tecnologias na Educação*, 18(2):131–140.
- Coman, C., Țiru, L. G., Meseșan-Schmitz, L., Stanciu, C., e Bularca, M. C. (2020). Online teaching and learning in higher education during the coronavirus pandemic: Students' perspective. *Sustainability*, 12(24):10367.
- Costa, J., Dorça, F., e Araújo, R. (2020). Avaliação do comportamento de estudantes em um ambiente educacional ubíquo. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação*, páginas 182–191, Porto Alegre, RS, Brasil. SBC.
- Fischer, C., Pardos, Z. A., Baker, R. S., Williams, J. J., Smyth, P., Yu, R., Slater, S., Baker, R., e Warschauer, M. (2020). Mining big data in education: Affordances and challenges. *Review of Research in Education*, 44(1):130–160.
- Maldonado-Mahauad, J., Pérez-Sanagustín, M., e Beyle, C. (2020). A questionnaire for measuring self-regulated learning in massive open online courses. In *2020 XLVI Latin American Computing Conference (CLEI)*, páginas 400–409. IEEE.
- McKinney, W. et al. (2010). Data structures for statistical computing in python. In *Proceedings of the 9th Python in Science Conference*, volume 445, páginas 51–56. Austin, TX.
- Menezes, C. d., Castro Junior, A. d., e Aragón, R. (2020). Arquiteturas pedagógicas para aprendizagem em rede. *Série de livros texto da CEIE-SBC*. Disponível em: <https://educacao.ceie-br.org/arquiteturas-pedagogicas/>. Acessado: em, 7:21–08.
- Moodle (2024). Registered Moodle sites. Registered Moodle sites. Disponível em <https://stats.moodle.org/sites/index.php?country=BR>.
- Panadero, E. (2017). A Review of Self-regulated Learning: Six Models and Four Directions for Research. *Frontiers in Psychology*, 8:422.
- Pintrich, P. R. et al. (1991). A manual for the use of the motivated strategies for learning questionnaire (mslq).
- Puustinen, M. e Pulkkinen, L. (2001). Models of self-regulated learning: A review. *Scandinavian Journal of Educational Research*, 45:269–286.
- Silva, F., Menezes, C., e Junior, A. C. (2023). Ensino introdutório de programação: Um estudo rumo ao uso das arquiteturas pedagógicas. In *Anais do XXXIV Simpósio Brasileiro de Informática na Educação*, páginas 428–438, Porto Alegre, RS, Brasil. SBC.
- Spearman, C. (1961). The proof and measurement of association between two things. *The American Journal of Psychology*, 100(3/4):441–471.
- Urdan, T. (2010). *Statistics in Plain English, Third Edition*. Taylor & Francis.
- World Health Organization (2020). WHO Director-General's opening remarks at the media briefing on COVID-19 - 11 March 2020. World Health Organization. Avail-

lable at <https://www.who.int/director-general/speeches/detail/who-director-general-s-opening-remarks-at-the-media-briefing-on-covid-19—11-march-2020>.

Zar, J. H. (2005). Spearman rank correlation. *Encyclopedia of biostatistics*, 7.

Zimmerman, B. e Martinez-Pons, M. (1986). Development of a structured interview for assessing student use of self-regulated learning strategies. *American Educational Research Journal*, 23:614–628.