

# Recomendação Pedagógica Personalizada a partir do Sequenciamento de Ações Baseadas na Taxonomia de Bloom e no Perfil RASI usando Planejamento em Inteligência Artificial apoiado por Algoritmo Genético Multiobjetivo

Newarney Torrezão da Costa<sup>1,3</sup>, Márcia Aparecida Fernandes<sup>2,3</sup>

<sup>1</sup>Instituto Federal Goiano (IF Goiano)  
Iporá – GO – Brasil

<sup>2</sup>Faculdade de Computação – Universidade Federal de Uberlândia (UFU)  
Uberlândia – MG – Brasil

<sup>3</sup>Programa de Pós-Graduação em Ciência da Computação – UFU

`newarney.costa@ifgoiano.edu.br, marcia@ufu.br`

**Abstract.** *The sequencing and recommendation of personalized pedagogical actions are relevant aspects of virtual learning environments (VLEs) in an attempt to promote and make effective computer-mediated teaching. This paper proposes a multiobjective genetic algorithm to sequence pedagogical actions based on Bloom's Taxonomy and recommend digital activities. The sequencing customization is according to the student's profile provided by the Revised Approaches to Studying Inventory (RASI). Experiments and statistical analysis showed promising results and pointed to the proposal's viability with the potential to compose VLEs.*

**Resumo.** *O sequenciamento e a recomendação de ações pedagógicas personalizadas em ambientes virtuais de aprendizagem (AVAs) são aspectos relevantes na tentativa de promover e tornar efetivo o ensino mediado por computador. Este trabalho propõe um algoritmo genético multiobjetivo para sequenciar ações pedagógicas baseadas na Taxonomia de Bloom e recomendar atividades digitais. Tal sequenciamento é personalizado segundo o perfil do estudante dado pelo Revised Approaches to Studying Inventory (RASI). Experimentos e análise estatística apresentaram resultados promissores e apontaram para a viabilidade da proposta com potencial para compor AVAs.*

## 1. Introdução

O sequenciamento e a recomendação de ações pedagógicas, ambos personalizados, são alguns aspectos importantes em Ambientes Virtuais de Aprendizagem (AVAs) [Peng et al. 2019, Moro et al. 2021]. O sequenciamento personalizado de ações pedagógicas visa determinar para cada estudante a sequência de ações mais adequada ao seu perfil de aprendizagem. Vale destacar que, para um sujeito específico, diversas características podem ser consideradas. Pode-se perceber uma intrínseca relação entre sequenciamento e Planejamento Automatizado (PA), ou Planejamento em Inteligência Artificial

(IA), pois ambos os problemas residem na determinação de sequências de ações que permitam, a partir de um certo estado inicial, atingir algum outro estado onde objetivos ou metas possam ser realizados [Russel et al. 2013, p. 366–436].

Como relatado em [Costa et al. 2019b], uma alternativa para implementação do PA é o uso de algoritmos baseados em computação bio-inspirada para realização de sequenciamento de ações pedagógicas. Tal enfoque parte do princípio de que essa categoria de problema pode ser interpretada como um problema de otimização. Diante disso, a grande disponibilidade de dados justifica o uso de Algoritmo Genético (AG) como uma alternativa às implementações tradicionais de PA [Hssina and Erritali 2019].

A modelagem das ações pedagógicas é um fator importante no sequenciamento pedagógico [Costa et al. 2019b]. A Taxonomia de Bloom (TB)<sup>1</sup>, desenvolvida por [Bloom et al. 1984] e revisada por [Krathwohl 2002], fornece um arcabouço teórico para realiza tal modelagem, pois estrutura as ações a partir do domínio cognitivo do estudante. Na TB, o desenvolvimento das habilidades cognitivas começa pelas de ordem inferior e indo para as habilidades cognitivas de ordem superior, definidas na literatura, respectivamente, como *Lower Order Cognitive Skills* (LOCS) e *Higher Order Cognitive Skills* (HOCS). Assim, TB está relacionada às ações que podem ser utilizadas para desenvolver as habilidades do estudante ao longo do processo de aprendizagem. Por outro lado, o *Revised Approaches to Studying Inventory* RASI define o perfil cognitivo do estudante, categorizando seus pontos fortes em três eixos: *Surface*, *Strategic* e *Deep*. Assim como na TB, o processo cognitivo do estudante em RASI se desenvolve no sentido de LOCS para HOCS [Entwistle and Tait 2013].

Diante disso, esta pesquisa é norteadada pela investigação sobre as possibilidades de sequenciamento automatizado e personalizado, de tal sorte que esse não dependa da estrutura curricular. Com isso, O escopo deste trabalho foi delimitado pela seguinte Questão de Pesquisa (QP): “*É possível produzir recomendações pedagógicas independentes da estrutura curricular?*”. Além disso, três Questões de Pesquisa Auxiliares (QPAs) foram definidas, são elas: QPA1 — “*É possível associar as teorias TB e RASI para sequenciar ações pedagógicas?*”; QPA2 — “*O sequenciamento de ações pedagógicas pode ser delineado como um problema de otimização por conseguinte, abordado com AG?*”; e QPA3 — “*A recomendação pedagógica baseada na TB, personalizada segundo o perfil RASI e promovida a partir do sequenciamento automatizado por AG é perceptível ao estudante?*”

Assim, a proposta deste trabalho é sequenciar e recomendar ações pedagógicas baseadas no processo cognitivo do estudante. Desse modo, são apresentados tanto o sequenciador de ações modeladas pela TB, quanto o recomendador, sendo que o segundo utiliza atividades digitais baseadas na sequência de ações pedagógicas personalizada e automatizada. A personalização é realizada considerando o perfil cognitivo RASI do estudante. O sequenciamento das ações pedagógicas utiliza PA apoiado por um AG multiobjetivo.

## 2. Fundamentação Teórica

Para haver a personalização do sequenciamento pedagógico, é necessário estabelecer uma relação entre as ações a serem sequenciadas e as características do estudante. No trabalho

---

<sup>1</sup>Neste trabalho, as menções à Taxonomia de Bloom dizem respeito à versão revisada, proposta em [Krathwohl 2002].

proposto em [Entwistle and Tait 2013] é relatada a utilização do RASI como componente do perfil cognitivo do estudante. Este distingue abordagens à aprendizagem, a partir de um questionário. Além disso, o RASI oferece uma interface com a TB, ao caracterizar tal abordagem do estudante numa escala evolutiva de LOCS para HOCS. Tal interface é explorada de maneira parcial em [Brown et al. 2015] e em [Shang 2019], acendendo a investigação sobre tal a capacidade de relacionamento. Conforme relatado em [Duff 2004], o RASI é um questionário amplamente utilizado no auxílio à identificação das abordagens de aprendizagem de estudantes no ensino superior. Através desse questionário, é possível avaliar o perfil cognitivo do estudante sob 3 dimensões: *Surface*, *Strategic* e *Deep*. Cada uma dessas dimensões é composta por subescalas.

Segundo [Krathwohl 2002], a TB oferece uma hierarquia de objetivos educacionais, pautada no processo cognitivo do estudante. Tal arcabouço abrange três domínios: cognitivo; afetivo; e psicomotor. O domínio cognitivo, utilizado neste trabalho, é analisado sob as dimensões do conhecimento e do processo cognitivo. Assim, os objetivos educacionais são descritos como verbos, compondo a Dimensão do Processo Cognitivo (DPC) com seis níveis (*Lembrar*, *Compreender*, *Aplicar*, *Analisar*, *Avaliar* e *Criar*). Outra dimensão, denominada Dimensão do Conhecimento (DC), é composta por quatro níveis (*Factual*, *Conceitual*, *Procedural* e *Metacognitivo*).

A estrutura de objetivos educacionais da TB permite sua aplicação em diversos cenários [Costa and Fernandes 2020]. Ainda em [Costa et al. 2019a], são apontados trabalhos que abordam aspectos intrínsecos ao uso de PA no contexto educacional. Tais propostas implementam o PA via *Planning Domain Definition Language* aplicada em ambientes de *e-learning*, entretanto esbarram o fato de que à medida que as características do estudante são refinadas, as heurísticas tendem a não ser efetivas no espaço de busca [Ariyaratne and Fernando 2014]. Para suprir a limitação supracitada, é observado o uso de algoritmos bio-inspirados para realização do PA é observado em diversos contextos [Costa and Fernandes 2020]. Além disso, conforme discutido em [Costa and Fernandes 2021], algoritmos bio-inspirados também são utilizados para a implementação do PA no contexto educacional. Em tais trabalhos, o sequenciamento curricular, ou a personalização de rotas de aprendizagem estão entre os principais objetivos do planejador.

Por fim, a possibilidade de utilizar as características do estudante, fornecidas pelo RASI, como parâmetros para o AG no processo de sequenciamento personalizado de ações pedagógicas mostra-se promissora devido à relação observada entre o RASI e a TB. A utilização dessa relação numa perspectiva de sequenciamento pedagógico automatizado e personalizado contribui com o avanço no estado da arte, uma vez que considera o processo cognitivo do estudante, além de ser independente de estruturas curriculares. Nesse aspecto, um mapeamento que relacione todos os eixos do RASI e as categorias da TB representa um avanço em relação aos trabalhos analisados, já que tal relação foi explorada parcialmente nesses trabalhos.

### **3. Planejador de Ações Pedagógicas por Algoritmo Genético Multiobjetivo**

Este trabalho visa sequenciar ações pedagógicas no lugar de conceitos ou objetos de aprendizagem. Portanto, seu uso é mais generalizado, pois, é possível aplicá-lo a qualquer domínio. Tal proposta faz uso da composição das teorias desenvolvidas na TB e no

RASI, dado que ambas tratam o estado cognitivo do estudante partindo de LOCS para HOCS. Conforme discutido e apresentado em [Costa and Fernandes 2021], as ações pedagógicas desta proposta são sequenciadas de acordo com a análise bidimensional da TB, considerando as dimensões do processo cognitivo e do conhecimento, DPC e DC, respectivamente. A matriz bidimensional da TB produz 24 posições (células), correspondentes aos objetivos educacionais na TB, sendo assim, foram definidas 24 ações (*Ação 1, ..., Ação 24*) cada uma correspondente à uma posição nessa matriz. Da primeira para a última ação, há também uma variação no sentido de LOCS para HOCS. Para se tornar possível a recomendação pedagógica a partir de uma sequência de ações, é necessário que cada ação esteja associada à uma atividade digital. Neste trabalho foi realizado o mapeamento das atividades da TBD para cada uma das ações proposta, conforme discutido e apresentado em [Costa et al. 2022a].

A pesquisa desenvolvida em [Costa and Fernandes 2021] determina a significância de cada categoria da Dimensão do Processo Cognitivo da TB para cada eixo RASI, comparando os itens do questionário RASI com as definições das subcategorias da DPC. As questões RASI foram associadas à categoria Dimensão do Processo Cognitivo mais compatível, observando os verbos principais e as definições da categoria e as questões RASI. Consequentemente, o mapeamento (compatibilidade) entre a TB e o RASI foi obtido. Tal mapeamento representa o percentual de questões por eixo RASI que possuem algum elemento (verbo-chave ou definição) conceitualmente compatível com as categorias da Dimensão do Processo Cognitivo da TB. Esse mapeamento é mais uma contribuição deste trabalho e cada uma das questões do RASI foi classificada segundo tais parâmetros e o resultado detalhado é apresentado em [Costa et al. 2022b].

A hierarquia da TB pode ser ajustada conforme os objetivos de aprendizagem. Desse modo, são 24 ações pedagógicas possíveis e  $2^{24}$  sequências de ações distintas. Além disso, conforme discutido na Seção 2, algoritmos evolutivos, como os AGs, são adequados para pesquisa em um grande espaço de busca. Assim, este trabalho propõe um AG para encontrar a sequência adequada de ações da TB para o perfil RASI do estudante. Nesta proposta, um indivíduo é um vetor binário composto por 24 bits, onde cada bit representa uma ação pedagógica, e esta possui uma atividade digital correspondente, conforme ilustrado na Figura 1.

No indivíduo binário exemplificado na Figura 1, os bits definidos como 1 indicam que as ações correspondentes estão presentes na sequência, caso contrário, não. Cada posição no vetor binário possui uma correspondência com as dimensões do conhecimento e do processo cognitivo. Note que da esquerda para direita, cada ação apresenta uma variação crescente de habilidades cognitivas (LOCS – HOCS). Além disso, são exibidas as atividades digitais mapeadas para cada ação da TB e sua ordem de apresentação ao estudante, conforme detalhado em [Costa et al. 2022a].

Como o intuito é encontrar uma sequência mais adequada para o perfil RASI do estudante, uma função objetivo ( $FO_1$ ) do AG mede o quão a sequência está próxima do perfil RASI do estudante. Para realizar a comparação entre o perfil RASI do estudante e a sequência de ações, é necessário determinar os índices RASI da sequência que expressam a equivalência de cada estado cognitivo (*Lembrar, ..., Criar*) na sequência, ponderada pela relevância deste estado para cada eixo RASI (*Surface, Strategic e Deep*). Formalmente, esses índices são dados pelo produto entre o peso do estado cognitivo

Representação do indivíduo no AG - vetor binário																									
Índice do vetor	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	
Exemplo de um indivíduo	1	1	0	1	1	1	1	1	0	0	0	0	0	0	1	0	1	1	1	1	0	1	0	1	
Dimensão do Processo Cognitivo	Lembrar				Compreender				Aplicar				Analisar				Avaliar				Criar				
Dimensão do Conhecimento	FC	CN	PR	MT	FC	CN	PR	MT	FC	CN	PR	MT	FC	CN	PR	MT	FC	CN	PR	MT	FC	CN	PR	MT	
Ações Pedagógicas da TB	A1	A2	A3	A4	A5	A6	A7	A8	A9	A10	A11	A12	A13	A14	A15	A16	A17	A18	A19	A20	A21	A22	A23	A24	
Total de Ações: 14 =	3				4				0				1				4				2				
Atividades da TBD	T1	T2		T4	T5	T6	T7	T8					T15	T17	T18	T19	T20					T22			T24
Ordem de Sequenciamento	1	2		3	4	5	6	7					8	9	10	11	12					13			14
	LOCS												HOCS												
	Legenda: FC. Factual; CN. Conceitual; PR. Processual; MT. Metacognitivo																								

Figura 1. Exemplo de um indivíduo binário / significado de cada bit.

( $P_{\text{estado\_cognitivo}}$ ) e os índices do eixo RASI ( $D_{\text{categoria}}$ ) conforme mapeamento apresentado em [Costa and Fernandes 2021, p. 452], onde ( $P_{\text{estado\_cognitivo}}$ ) é o produto do número de bits definido como 1 no estado cognitivo e 0,25.

A correspondência da sequência em relação cada perfil RASI – *Surface* (*su*), *Strategic* (*st*) e *Deep* (*de*) – para o indivíduo no AG é calculada conforme exemplo dado em [Costa et al. 2022b, p. 54–56]. Note que aqui são utilizadas as taxas definidas em [Costa and Fernandes 2021]. Considerando que um perfil RASI de um estudante também é caracterizado pelos valores dos três eixos, então a função objetivo (*fitness*)  $FO_1$  é dada pela Eq. 1, onde  $I$  e  $S$  são os índices RASI do indivíduo e do estudante respectivamente,  $dist(I, S)$  é a distância euclidiana entre esses índices e  $pnl(I, S)$  é uma penalidade.

$$FO_1(I) = dist(I, S) + pnl(I, S) \quad (1)$$

Note que  $FO_1$  é uma função de minimização entre os índices RASI do estudante e do indivíduo. A distância euclidiana é calculada entre os valores de cada eixo RASI calculado para o indivíduo e o estudante, conforme Eq. 2.

$$dist(I, S) = \sqrt{(su(I) - su(S))^2 + (st(I) - st(S))^2 + (de(I) - de(S))^2} \quad (2)$$

A magnitude dos valores do eixo RASI resulta em uma ordem de prioridade. Assim, o eixo com menor valor é menos relevante e o eixo com maior valor é mais relevante para o perfil cognitivo do estudante. Essa ordem de relevância considera pesos com os seguintes valores:  $P_1 = 1$  (Peso 1) para o eixo menos relevante;  $P_2 = 2$  (Peso 2) para o eixo intermediário; e  $P_3 = 3$  (Peso 3) para o eixo mais relevante. Um exemplo pode ser visto em [Costa and Fernandes 2021, p. 495]. Para cada eixo RASI com divergência na ordem de relevância entre o estudante e o indivíduo, esse peso é multiplicado por  $1/6$  da distância euclidiana entre o aluno e o eixo RASI do indivíduo. Assim, a penalidade pode no máximo dobrar o valor da função  $FO_1$  em relação à distância euclidiana como mostra a Eq. 3.

$$pnl(I, S) = dist(I, S) / 6 \times P_1 + dist(I, S) / 6 \times P_2 + dist(I, S) / 6 \times P_3 \quad (3)$$

Note que se não houver diferença na ordem de relevância em qualquer eixo RASI,  $P_1$ ,  $P_2$  ou  $P_3$  são definidos como 0.

A implementação do planejador proposto neste trabalho, utilizando AG, ocorreu em duas etapas. Na primeira, foi implementado um AG mono-objetivo utilizando a função  $FO_1$ , apresentada na Eq. 1. Na segunda etapa foi implementado um AG multiobjetivo, acrescentando uma segunda função objetivo ( $FO_2$ ) ao AG previamente desenvolvido, conforme apresentado na Eq. 4:

$$FO_2(I) = \begin{cases} \frac{ref - tamanho(I)}{ref - 1} & , \text{ se } tamanho(I) > ref \\ \frac{tamanho(I) - ref}{24 - ref} & , \text{ caso contrário} \end{cases} \quad (4)$$

onde  $ref$  é o valor de referência para a quantidade de atividades ideal. A definição dos valores de referência da quantidade de atividades por perfil RASI predominante foram obtidos a partir de experimentos realizados em [Costa and Fernandes 2021]. A partir disso, foi estabelecida a média de atividades conforme o perfil RASI do estudante, sendo os valores de referência: *Surface* = 9, *Strategic* = 13 e *Deep* = 11.

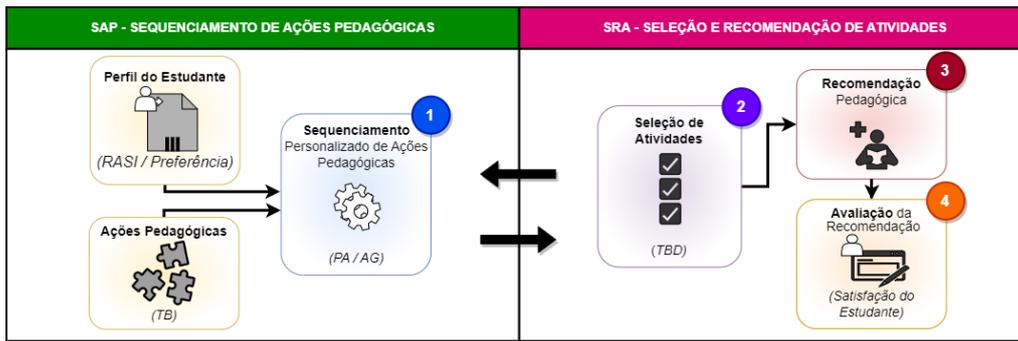
Após a realização de testes afim de identificar os valores dos parâmetros que melhor se ajustam ao AG, concluiu-se que os melhores resultados são obtidos utilizando os valores descritos a seguir: A população inicial tem tamanho de  $MAX_I = 1000$  indivíduos. Avaliação das funções de aptidão dadas pelas equações 1 ( $FO_1$ ) e 4 ( $FO_2$ ) realizando a soma ponderada com os pesos 0.7 e 0.3 para  $FO_1$  e  $FO_2$ , respectivamente. O objetivo do AG é minimizar os valores das funções de aptidão, ou seja, quando tais valores forem zero, significa que a solução ideal foi encontrada. Sendo assim, um critério de parada do algoritmo no passo (3) é quando é encontrado um indivíduo cujo *fitness* seja zero e o outro critério de parada é quando atinge a quantidade de gerações ( $MAX_G$ ) = 100.

O método de torneio é usado para selecionar os indivíduos que farão parte da próxima geração. Nesse processo, três indivíduos são selecionados aleatoriamente, e o melhor deles é escolhido de acordo com uma taxa de probabilidade  $P_T = 60\%$ . O crossover é realizado em blocos adjacentes de 4 bits, considerando as seis subcategorias da dimensão do processo cognitivo na Taxonomia de Bloom. Depois que os novos indivíduos são classificados, os mais bem classificados constituem a população da próxima geração. A mutação, realizada aleatoriamente na população e considerando uma taxa de  $P_M = 10\%$  sendo realizada invertendo um bit aleatório no indivíduo. Na Figura 2 é apresentada uma visão geral da arquitetura proposta.

Na Figura 2, o Processo (1) do Módulo SAP é responsável por sequenciar, via AG, as ações pedagógicas modeladas segundo a Taxonomia de Bloom. O Processo (2), no módulo SRA, seleciona uma atividade digital para cada ação na sequência, usando o mapeamento entre a TBD e a TB. O Processo (3) é responsável por entregar a sequência ao estudante e, no Processo (4), o estudante avalia a recomendação respondendo a um questionário de satisfação.

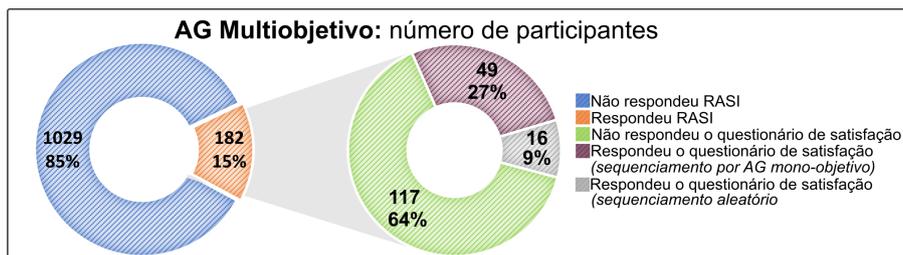
#### 4. Experimentos e Resultados

Os experimentos foram delineados a partir do fluxo de processos apresentados na Figura 2. O detalhamento dos experimentos e os resultados completos são apresentados e discutidos em [Costa et al. 2022b]. A condução dos experimentos se deu em três etapas,



**Figura 2. Modelo de recomendação para ações pedagógicas.**

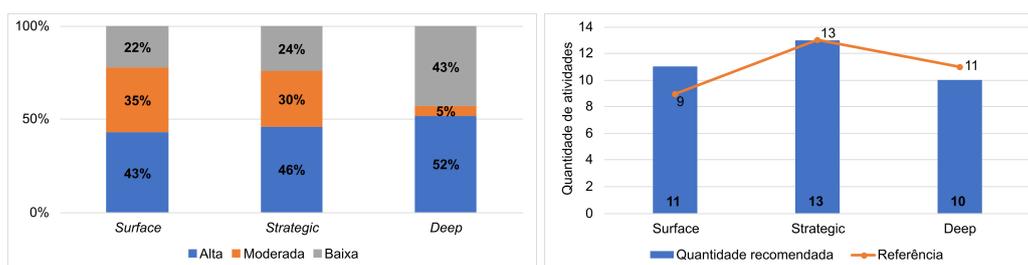
visando averiguar a eficácia dos métodos propostos. São elas: **Etapa 1** – caracterização do Perfil do estudante usando o RASI; **Etapa 2** – Sequenciamento de ações baseadas na TB e atribuição de atividades baseadas na TBD; e **Etapa 3** – recomendação de atividades e aplicação do questionário de satisfação do estudante em relação à sequência recebida. O número de participantes considerando todas as etapas dos experimentos é apresentado na Figura 3. O perfil dos participantes é de estudantes de nível superior em instituições públicas nos estados de Goiás e Minas Gerais.



**Figura 3. Modelo de recomendação para ações pedagógicas.**

Na Etapa 1 dos experimentos, foram identificados os perfis RASI de 182 estudantes. Desses, 65 participantes se voluntariam a participar da etapa de recomendação de atividades (Etapa 3), sendo que 49 receberam sequências de ações personalizadas pelo AG e outros 16 receberam ações sequenciadas aleatoriamente. Na Figura 4(a), é possível observar a taxa de recomendação de atividades consoante o perfil predominante de cada participante e o grau de relevância das atividades para o perfil, considerando os índices do mapeamento apresentado em [Costa and Fernandes 2021, p. 452]. Tais resultados dizem respeito à avaliação do objetivo 1 ( $FO_1$ ) do AG, pois permitem analisar o quão uma sequência de ações é similar a um perfil de estudante, conforme os índices RASI.

Conforme observado na Figura 4(a), para os perfis *Surface* e *Strategic* há uma maior taxa de recomendação de atividades com relevância moderada, 43% e 46% respectivamente. As atividades com relevância baixa para os perfis são menores, 22% e 24% por essa ordem. No perfil *Deep*, a tendência de recomendação de atividades com grau de relevância baixo foi maior (52%) do que alto (43%). Uma possível causa para isso é que os participantes classificados como *Deep* pelo algoritmo têm os índices de um ou dos dois outros perfis, muito próximos ou iguais ao *Deep*. Nessa condição, dentre os perfis *Deep* (32 participantes), 28,1% apresentam o índice *Deep* igual ou diferente em no máximo 1



(a) Taxa de recomendação por perfil, conforme o grau de relevância. (b) Quantidade média de atividades por perfil RASI.

**Figura 4. Análise das seqüências em relação aos objetivos do AG.**

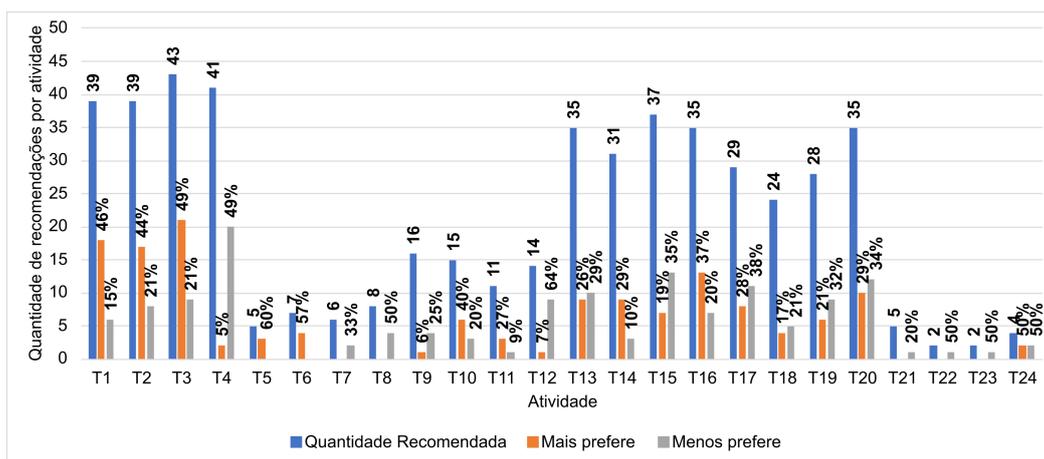
ponto percentual dos demais perfis. No perfil *Strategic* não há ocorrência dessa condição e no perfil *Surface*, esse padrão se repetiu para 1 participante.

A partir de experimentos anteriores, apresentados em [Costa et al. 2022a], notou-se que a quantidade média de atividades por eixo RASI predominante é de 9, 13 e 11 para os eixos *Surface*, *Strategic* e *Deep*, respectivamente. Essas quantidades serviram como referência para realizar o sequenciamento de ações consoante o perfil do estudante. Na Figura 4(b) é observada a quantidade média de atividades recomendada por eixo RASI predominante. A análise dos resultados presentes na Figura 4(b) diz respeito à avaliação da função objetivo  $FO_2$  do AG, pois este adaptou a quantidade de atividades segundo o padrão de preferência notado para o perfil RASI do estudante. Tais resultados mostram-se satisfatórios, pois mostram a viabilidade de considerar a satisfação do estudante para realizar a recomendação. A partir desses resultados, observa-se a necessidade de adequações do AG em trabalhos futuros, de modo a melhor ajustar a quantidade de atividades conforme o perfil do estudante.

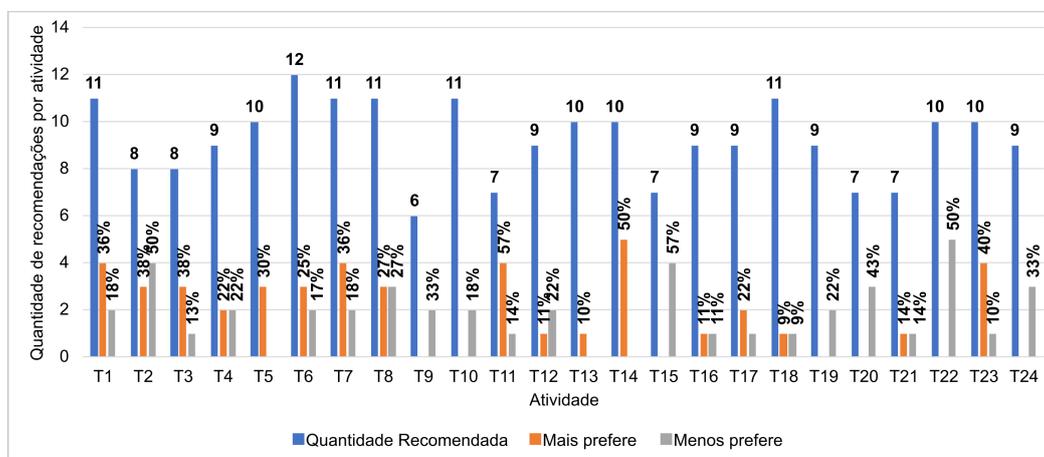
Na etapa 3, foram realizadas recomendações pedagógicas a 65 participantes. Os participantes foram divididos em dois grupos (*experimento* e *controle*) para receberem a recomendação pedagógica sequenciada por AG e sequenciada de forma aleatória, respectivamente. A divisão dos grupos de participantes se deu de maneira aleatória. Uma recomendação apresentada ao estudante consiste numa lista de atividades digitais da TBD, previamente mapeadas em conforme apresentado em [Costa et al. 2022a]. Para cada seqüência recomendada foi apresentado um questionário ao participante, com o intuito de avaliar a satisfação desse em relação às atividades recebidas. As questões relativas à satisfação do estudante são listadas em [Costa et al. 2022b, p. 79–80]. Duas dessas questões dizem respeito à preferência dos participantes acerca das atividades recebidas, sendo elas: “*Dentre as atividades recomendadas, informe três que mais prefere.*” e “*Dentre as atividades recomendadas, informe três que menos prefere.*”. As compilação das respostas pode ser observada na Figura 5. Nesta, são apresentadas as taxas de maior e menor preferência das atividades, conforme as respostas dos participantes. Nessa figura, as respostas estão separadas entre os participantes que receberam a recomendação originada a partir dos sequenciamentos por AG multiobjetivo e aleatório.

Na comparação entre as figuras 5(a) e 5(b), a taxa de atividades mais preferidas na recomendação a partir do sequenciamento por AG multiobjetivo supera a recomendação aleatória em 15 atividades. Tais resultados sugerem uma tendência de maior preferência

das atividades recomendadas usando sequenciamento por AG multiobjetivo. Essa maior preferência relaciona-se a personalização do sequenciamento de ações pedagógicas, considerando o perfil RASI do estudante. Os resultados obtidos acerca da percepção dos estudantes sobre a sequência de atividades recebida é significativo em termos quantitativos, pois ainda que o número de participantes dos experimentos não seja grande, observamos que a partir dos resultados apresentados, há aceitação da recomendação de atividades geradas pelo AG multiobjetivo se comparado com o sequenciamento aleatório.



(a) Sequenciamento por AG multiobjetivo.



(b) Sequenciamento aleatório.

**Figura 5. Taxa de preferência das atividades por método de sequenciamento.**

A partir da análise estatística detalhada entre as questões do questionário de satisfação aplicado aos participantes, disponível em [Costa et al. 2022b, 70–91], foi possível notar que quanto maior a quantidade de atividades, menor a possibilidade deste realizar todas as atividades da sequência. Outra observação foi a de que quanto mais/menos confortável o estudante considera a sequência de atividades, maior/menor a possibilidade deste realizar todas as atividades. Por fim, notou-se que para estudantes com perfil RASI cujo eixo *Deep* é predominante, quanto maior o grau de aprovação com o índice obtido para o eixo *Deep*, menor a insatisfação com a quantidade de atividades recomendada. Tais análises ajudam a evidenciar a eficácia do método proposto e apontam caminhos para refinamentos e melhorias no que diz respeito ao sequenciamento de ações.

Em relação à QPA1, a partir dos experimentos realizados nas etapas 1 e 2, os resultados mostraram a viabilidade em associar o arcabouço teórico constituído por TB e RASI para produzir seqüências de ações pedagógicas. Relativo à QPA2, o resultado do AG mostrou ser possível tratar tal problema sob o viés de otimização. A QPA3 também foi respondida, pois, na etapa 3 dos experimentos foram coletadas as respostas dos estudantes e apresentados os resultados acerca da percepção destes em relação à recomendação pedagógica recebida. De maneira geral, os estudantes perceberam positivas as recomendações personalizadas recebidas. Por fim, a questão de pesquisa principal (QP) também foi respondida, dado que todas as etapas dos experimentos não consideraram um conteúdo específico para gerar o sequenciamento de ações pedagógicas.

## **5. Considerações Finais**

Esta pesquisa apresentou uma abordagem de recomendação pedagógica personalizada independente de conteúdo ou estrutura curricular. Para tal, foi desenvolvido um sequenciador de ações pedagógicas baseadas na TB. O sequenciamento adotou uma abordagem de PA, implementado utilizando um AG multiobjetivo. As características que compuseram o modelo do estudante para personalização do sequenciamento foram o RASI e as preferências do estudante. As atividades recomendadas a partir do sequenciamento foram aquelas dadas pela TBD, possibilitando flexibilidade em relação a futuras implementações e plataformas de aprendizagem, como AVAs, por exemplo.

Os resultados apresentados são promissores, dado que tanto os resultados do sequenciamento por AG, quanto os da satisfação dos participantes são razoáveis e se complementam nessa confirmação. Sendo assim, é possível afirmar que os objetivos deste trabalho foram atingidos em termos qualitativos e quantitativos. Uma contribuição deste trabalho foi a realização do mapeamento entre a TB e o RASI, possibilitando relacionar seqüências de ações pedagógicas dadas pela TB e o RASI e viabilizando então a automatização do processo de sequenciamento personalizado de ações. As funções-objetivo criadas para AG também são contribuições deste trabalho, uma vez que permitem mensurar de maneira automatizada uma seqüência de ações em relação à adequação ao perfil RASI do estudante. Outra contribuição deste trabalho, foi o refinamento do mapeamento das atividades propostas por [Churches 2010], passando a listagem de atividades de uma para duas dimensões da TB.

Tratar o sequenciamento de ações pedagógicas como um problema de otimização baseado no mapeamento entre TB e RASI é um aspecto de originalidade da proposta apresentada, que encontra ressonância na teoria. Os experimentos revelaram que far-se-á necessário um refinamento dos objetivos do AG multiobjetivo tanto para melhor adaptar a seqüência ao perfil RASI do estudante, quanto para aprimorar os valores de referência da quantidade de atividades adequada por perfil. Em suma, o cuidado é com a aprendizagem do estudante e a partir da proposta desenvolvida, novos elementos poderão ser oportunos para compor o perfil do estudante e enriquecer a personalização do sequenciamento de ações. Em trabalhos futuros, estima-se ampliar a pesquisa por atividades digitais e aumentar a quantidade de atividades disponíveis para cada ação pedagógica. Com isso, abre-se caminho para explorar um novo ponto de personalização, o das atividades digitais, a partir de características do estudante, por exemplo, explorando a análise de metadados de um AVA.

## Referências

- Ariyaratne, M. and Fernando, T. (2014). A comparative study on nature inspired algorithms with firefly algorithm. *International Journal of Engineering and Technology*, 4(10):611–617.
- Bloom, B., Engelhart, M., Furst, E., Hill, W., and Krathwohl, D. (1984). *Taxonomy of educational objectives: The classification of educational goals. Handbook 1: Cognitive domain*. David McKay, 1st edition.
- Brown, S., White, S., Wakeling, L., and Naiker, M. (2015). Approaches and study skills inventory for students (assist) in an introductory course in chemistry. *Journal of University Teaching & Learning Practice*. <https://doi.org/10.53761/1.12.3.6>.
- Churches, A. (2010). Bloom's digital taxonomy.
- Costa, N. and Fernandes, M. (2020). Sequenciamento de ações pedagógicas por algoritmo genético utilizando taxonomia de bloom e assist. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação*, pages 1273–1282, Porto Alegre, RS, Brasil. SBC. <https://doi.org/10.5753/cbie.sbie.2020.1273>.
- Costa, N., Júnior, C. P., and Fernandes, M. (2019a). Recomendação de ações pedagógicas utilizando planejamento automático e taxonomia digital de bloom. In *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)*, volume 30, page 1531. <https://doi.org/10.5753/cbie.sbie.2019.1531>.
- Costa, N., Pereira Junior, C., Araújo, R., and Fernandes, M. (2019b). Application of ai planning in the context of e-learning. In *International Conference on Advanced Learning Technologies (ICALT)*, page 57. <https://doi.org/10.1109/ICALT.2019.00021>.
- Costa, N. T., de Almeida, D. J., Oliveira, G. P., and Fernandes, M. A. (2022a). Customized pedagogical recommendation using automated planning for sequencing based on bloom's taxonomy. *International Journal of Distance Education Technologies (IJ-DET)*, 20(1):1–19. <https://doi.org/10.4018/ijdet.296700>.
- Costa, N. T. et al. (2022b). Sequenciamento e recomendação de ações pedagógicas baseados na taxonomia de bloom e no perfil rasi usando planejamento automatizado por algoritmo genético. *Universidade Federal de Uberlândia – Programa de Pós-Graduação em Ciência da Computação*. <http://doi.org/10.14393/ufu.te.2022.535>.
- Costa, N. T. and Fernandes, M. A. (2021). Sequenciamento de ações pedagógicas baseadas na taxonomia de bloom usando planejamento automatizado apoiado por algoritmo genético. *Revista Brasileira de Informática na Educação*, 29:485–501.
- Duff, A. (2004). The revised approaches to studying inventory (rasi) and its use in management education. *Active learning in higher education*, 5(1):56–72. <https://doi.org/10.1177/1469787404040461>.
- Entwistle, N. and Tait, H. (2013). Approaches and study skills inventory for students (assist) (incorporating the revised approaches to studying inventory - rasi). *Edinburgh: Centre for Research on Learning and Instruction, University of Edinburgh*.

- Hssina, B. and Erritali, M. (2019). A personalized pedagogical objectives based on a genetic algorithm in an adaptive learning system. *Procedia Computer Science*, 151:1152–1157. <https://doi.org/10.1016/j.procs.2019.04.164>.
- Krathwohl, D. R. (2002). A revision of bloom's taxonomy: An overview. *Theory Into Practice*, 41(4):212–218. [https://doi.org/10.1207/s15430421tip4104\\_2](https://doi.org/10.1207/s15430421tip4104_2).
- Moro, F. F., Tarouco, L. M. R., and Vicari, R. M. (2021). Proposta de arquitetura baseada em agentes inteligentes integrados em ambientes e-learning. *Revista Educar Mais*, 5(2):249–260. <https://doi.org/10.15536/reducarmais.5.2021.2163>.
- Peng, H., Ma, S., and Spector, J. M. (2019). Personalized adaptive learning: an emerging pedagogical approach enabled by a smart learning environment. *Smart Learning Environments*, 6(1):1–14. <https://doi.org/10.1186/s40561-019-0089-y>.
- Russel, S., Norvig, P., et al. (2013). *Artificial intelligence: a modern approach*. Pearson Education Limited London.
- Shang, H. (2019). Cultural interpretation of deep approach to learning: an empirical analysis in a chinese university. In *Cross-Cultural Business Conference 2019*, page 207.