
**Sequenciamento e Recomendação de Ações
Pedagógicas baseados na Taxonomia de Bloom
e no Perfil RASI usando Planejamento
Automatizado por Algoritmo Genético**

Newarney Torrezão da Costa



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Uberlândia
2022

Newarney Torrezão da Costa

**Sequenciamento e Recomendação de Ações
Pedagógicas baseados na Taxonomia de Bloom
e no Perfil RASI usando Planejamento
Automatizado por Algoritmo Genético**

Tese de doutorado apresentada ao Programa de Pós-graduação da Faculdade de Computação da Universidade Federal de Uberlândia como parte dos requisitos para a obtenção do título de Doutor em Ciência da Computação.

Área de concentração: Ciência da Computação

Orientador: Prof.^a Dr.^a Márcia Aparecida Fernandes

Uberlândia

2022

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

C837 Costa, Newarney Torrezão da, 1983-
2022 Sequenciamento e Recomendação de Ações Pedagógicas
baseados na Taxonomia de Bloom e no Perfil RASI usando
Planejamento Automatizado por Algoritmo Genético
[recurso eletrônico] / Newarney Torrezão da Costa. -
2022.

Orientadora: Márcia Aparecida Fernandes.
Tese (Doutorado) - Universidade Federal de Uberlândia,
Pós-graduação em Ciência da Computação.
Modo de acesso: Internet.
Disponível em: <http://doi.org/10.14393/ufu.te.2022.535>
Inclui bibliografia.
Inclui ilustrações.

1. Computação. I. Fernandes, Márcia Aparecida, 1963-
(Orient.). II. Universidade Federal de Uberlândia. Pós-
graduação em Ciência da Computação. III. Título.

CDU: 681.3

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:
Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR PRODUÇÕES TÉCNICO-CIENTÍFICAS NO REPOSITÓRIO INSTITUCIONAL DO IF GOIANO

Com base no disposto na Lei Federal nº 9.610, de 19 de fevereiro de 1998, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia Goiano a disponibilizar gratuitamente o documento em formato digital no Repositório Institucional do IF Goiano (RIIF Goiano), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IF Goiano.

IDENTIFICAÇÃO DA PRODUÇÃO TÉCNICO-CIENTÍFICA

- | | |
|--|---|
| <input checked="" type="checkbox"/> Tese (doutorado) | <input type="checkbox"/> Artigo científico |
| <input type="checkbox"/> Dissertação (mestrado) | <input type="checkbox"/> Capítulo de livro |
| <input type="checkbox"/> Monografia (especialização) | <input type="checkbox"/> Livro |
| <input type="checkbox"/> TCC (graduação) | <input type="checkbox"/> Trabalho apresentado em evento |

Produto técnico e educacional - Tipo:

Nome completo do autor:

Newarney Torrezão da Costa

Matrícula:

1610804

Título do trabalho:

Sequenciamento e Recomendação de Ações Pedagógicas baseados na Taxonomia de Bloom e no Perfil RASI usando Planejamento Automatizado por Algoritmo Genético

RESTRIÇÕES DE ACESSO AO DOCUMENTO

Documento confidencial: Não Sim, justifique:

Informe a data que poderá ser disponibilizado no RIIIF Goiano: 20 / 10 / 2022

O documento está sujeito a registro de patente? Sim Não

O documento pode vir a ser publicado como livro? Sim Não

DECLARAÇÃO DE DISTRIBUIÇÃO NÃO-EXCLUSIVA

O(a) referido(a) autor(a) declara:

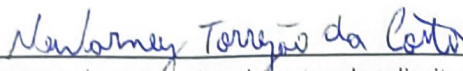
- Que o documento é seu trabalho original, detém os direitos autorais da produção técnico-científica e não infringe os direitos de qualquer outra pessoa ou entidade;
- Que obteve autorização de quaisquer materiais incluídos no documento do qual não detém os direitos de autoria, para conceder ao Instituto Federal de Educação, Ciência e Tecnologia Goiano os direitos requeridos e que este material cujos direitos autorais são de terceiros, estão claramente identificados e reconhecidos no texto ou conteúdo do documento entregue;
- Que cumpriu quaisquer obrigações exigidas por contrato ou acordo, caso o documento entregue seja baseado em trabalho financiado ou apoiado por outra instituição que não o Instituto Federal de Educação, Ciência e Tecnologia Goiano.

Iporá-Go

Local

29 / 09 / 2022

Data



Assinatura do autor e/ou detentor dos direitos autorais



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
 Coordenação do Programa de Pós-Graduação em Ciência da Computação
 Av. João Naves de Ávila, nº 2121, Bloco 1A, Sala 243 - Bairro Santa Mônica, Uberlândia-MG, CEP 38400-902
 Telefone: (34) 3239-4470 - www.ppgco.facom.ufu.br - cpqfacom@ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Ciência da Computação				
Defesa de:	Tese de doutorado, 11/2022, PPGCO				
Data:	15 de Agosto de 2022	Hora de início:	8:30	Hora de encerramento:	12:15
Matrícula do Discente:	11813CCP003				
Nome do Discente:	Newarney Torrezão da Costa				
Título do Trabalho:	Sequenciamento e Recomendação de Ações Pedagógicas baseados na Taxonomia de Bloom e no Perfil RASI usando Planejamento Automatizado por Algoritmo Genético				
Área de concentração:	Ciência da Computação				
Linha de pesquisa:	Inteligência Artificial				
Projeto de Pesquisa de vinculação:	-				

Reuniu-se, via videoconferência, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Ciência da Computação, assim composta: Professores Doutores: Renan Gonçalves Cattelan - FACOM/UFU; Fabiano Azevedo Dorça - FACOM/UFU; Rosa Maria Vicari - UFRGS; Andrey Ricardo Pimentel - UFPR e Márcia Aparecida Fernandes- FACOM/UFU, orientadora do candidato.

A examinadora Rosa Maria Vicari participou desde a seguinte localidade: Porto Alegre/Rs e o examinador Andrey Ricardo Pimentel participou desde a seguinte localidade: Curitiba/PR. Os demais membros e o discente participaram da cidade de Uberlândia/MG.

Iniciando os trabalhos a presidente da mesa, Prof^a Dr^a Márcia Aparecida Fernandes, apresentou a Comissão Examinadora e o candidato, agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir a senhora presidente concedeu a palavra, pela ordem sucessivamente, aos examinadores, que passaram a arguir o candidato. Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o candidato:

Aprovado.

Esta defesa faz parte dos requisitos necessários à obtenção do título de Doutor.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

*Este trabalho é dedicado aos meus pais, Leila e Modesto,
pois sem o apoio deles, eu não chegaria até aqui.*

Agradecimentos

Agradeço à minha orientadora, Márcia Aparecida Fernandes, pela oportunidade de iniciar essa jornada, pelas incontáveis horas dedicadas, pelos momentos de reflexão e pelos valiosos ensinamentos que sua experiência pode me proporcionar. Sem dúvidas, seu exemplo me modificou e terei isso comigo sempre.

A conclusão dessa etapa é fruto de um processo acadêmico que se iniciou antes do doutorado, por isso, agradeço também ao meu ex-orientador no mestrado, Jamil Salem Barbar, por me mostrar a importância da pesquisa.

Agradeço aos docentes e servidores da Faculdade de Computação da UFU, que estiveram sempre disponíveis para auxiliar e foram suporte essencial para o desenvolvimento deste trabalho.

Agradeço aos amigos que mesmo antes do doutorado, me apoiavam na academia, em especial à Luciane de Fátima Silva e ao Rafael Dias Araújo, que com seus conselhos, me tranquilizaram e me apoiaram a iniciar o doutorado.

No doutorado, o convívio com colegas, que posteriormente se tornaram amigos, me ajudou a compreender as diversas faces do doutorado. Destaco meus agradecimentos especialmente à Sara Luzia de Melo, ao Claudiney Ramos Tinoco e ao Tiago Ismaier de Carvalho.

Agradeço aos colegas de trabalho do Instituto Federal Goiano - Campus Iporá, em especial aos amigos Luciana Recart Cardoso, Lívia Mancine Coelho de Campos, Marcos Alves Vieira e Thamer Horbylon Nascimento, que me incentivaram a cursar o doutorado.

Sem dúvidas, esse caminho teve grande contribuição do meu esposo, Cleon Xavier Pereira Júnior, que sempre esteve disponível e pacientemente me motivou e me apoiou nessa jornada. Por isso e por tudo, agradeço a ele.

*“Ninguém ignora tudo. Ninguém sabe tudo. Todos nós sabemos alguma coisa.
Todos nós ignoramos alguma coisa. Por isso aprendemos sempre.”*
(Paulo Freire)

Resumo

O sequenciamento e a recomendação de ações pedagógicas personalizadas em ambientes virtuais de aprendizagem são dois aspectos relevantes na tentativa de promover e tornar efetivo o ensino mediado por computador. Assim, este trabalho investiga o uso de planejamento em Inteligência Artificial para o sequenciamento dessas ações, conforme o perfil do estudante. As ações são modeladas de maneira a corresponder ao processo cognitivo descrito pela Taxonomia de Bloom e o perfil do estudante é determinado segundo o *Revised Approaches to Studying Inventory* (RASI). Os princípios básicos que norteiam a Taxonomia de Bloom e o RASI são equivalentes, entretanto, foi necessário mapear estas duas teorias de modo a mensurar a aderência de uma sequência de ações ao perfil do estudante, sendo este mapeamento uma das contribuições deste trabalho. Desde que planejamento é uma tarefa com alto grau de complexidade, o uso de técnicas da computação evolutiva, tais como algoritmos genéticos, e a formulação do problema como um problema de otimização podem auxiliar na busca por boas soluções (sequências de ações pedagógicas), conforme demonstrado neste trabalho. Para tanto, fez-se necessária a proposição de duas funções objetivo em um algoritmo genético multiobjetivo para avaliar a sequência durante a evolução do algoritmo. As ações recomendadas são aquelas da Taxonomia de Bloom Digital, conforme a pertinência em cada estado do processo cognitivo. Experimentos realizados contaram com estudantes do ensino superior que responderam ao questionário RASI e, após terem recebido as respectivas sequências de ações determinadas pelo planejador proposto neste trabalho, também responderam a um questionário de satisfação em relação à sequência de ações pedagógicas resultante. Tais resultados foram promissores e apontam para a viabilidade da proposta, com potencial para compor ambientes virtuais de aprendizagem.

Palavras-chave: Sequenciamento de ações pedagógicas. Recomendação de ações pedagógicas. Planejamento em inteligência artificial. Taxonomia de Bloom. RASI. Algoritmo Genético.

Abstract

The sequencing and recommendation of personalized pedagogical actions in virtual learning environments are two relevant aspects in the attempt to promote and make effective computer-mediated teaching. Thus, this work investigates the use of Artificial Intelligence (AI) planning for the sequencing of these actions, according to the student's profile. The actions are modeled to correspond to the cognitive process described by Bloom's Taxonomy, and the student's profile is determined according to the Revised Approaches to Studying Inventory (RASI). The basic principles that guide Bloom's Taxonomy and the RASI are equivalent; however, it was necessary to map these two theories to measure the adherence of a sequence of actions to the student's profile, and this mapping is one of the contributions of this work. Since planning is a task with a high degree of complexity, the use of evolutionary computing techniques, such as genetic algorithms, and the formulation of the problem as an optimization problem can help in the search for good solutions (sequences of pedagogical actions), as demonstrated in this work. To this end, it was necessary to propose two objective functions in a multi-objective genetic algorithm to evaluate the sequence during the evolution of the algorithm. The recommended actions are those from Bloom's Digital Taxonomy, according to their relevance in each state of the cognitive process. Experiments carried out included higher education students who answered the RASI questionnaire and, after receiving the respective sequences of actions determined by the planner proposed in this work, also answered a satisfaction questionnaire regarding the resulting sequence of pedagogical actions. Such results were promising and point to the viability of the proposal, with potential to compose virtual learning environments.

Keywords: Sequencing of pedagogical actions. Recommendation of pedagogical actions. Planning in artificial intelligence. Bloom's Taxonomy. RASI. Genetic Algorithm.

Lista de ilustrações

Figura 1 – Ações pedagógicas baseadas na Taxonomia de Bloom.	50
Figura 2 – Mapeamento das atividades digitais (TBD) para a duas dimensões da Taxonomia de Bloom.	51
Figura 3 – Taxa de compatibilidade entre perfis (RASI) e estados cognitivos (TB).	52
Figura 4 – Representação do indivíduo binário no AG.	54
Figura 5 – Fluxograma do Algoritmo Genético.	58
Figura 6 – Modelo de recomendação para ações pedagógicas.	59
Figura 7 – Taxa de participantes por perfil RASI - AG Mono-objetivo.	63
Figura 8 – Percepção dos estudantes sobre o perfil RASI.	65
Figura 9 – Taxas de similaridade entre as sequências de ações e os perfis cognitivos dos estudantes	66
Figura 10 – Satisfação dos estudantes em relação à recomendação das atividades sequenciadas.	69
Figura 11 – Taxa de aceitação por atividade recomendada.	70
Figura 12 – Taxa de rejeição de atividades por categoria RASI predominante do estudante.	71
Figura 13 – Quantidade de participantes por perfil RASI.	73
Figura 14 – Percepção dos estudantes sobre o perfil RASI: a) QB1, QB2 e QB3: em que grau os percentuais RASI deveriam ser diferentes. b) QB4, QB5 e QB6: o quão concorda com o percentual atribuído ao perfil.	75
Figura 15 – Taxa de recomendação por perfil, conforme o grau de relevância (valores normalizados)	76
Figura 16 – Comparação da quantidade média de atividades recomendadas com os valores de referência para cada perfil RASI.	77
Figura 17 – Participantes por grupo (experimento x controle).	79
Figura 18 – <i>Boxplot</i> para as questões QB7, QB8, QB9 e QB10.	81

Figura 19 – Respostas para a questão “Você acredita que a quantidade de atividades é:”	
a) sequenciamento por AG multiobjetivo b) sequenciamento aleatório	83
Figura 20 – Respostas para a questão “O número total de atividades recomendadas é muito elevado.”	
a) sequenciamento por AG multiobjetivo b) sequenciamento aleatório	84
Figura 21 – Respostas para a questão “A sequência de atividades é confortável para lhe conduzir no aprendizado de um novo conteúdo ou disciplina.”	
a) sequenciamento por AG multiobjetivo b) sequenciamento aleatório	84
Figura 22 – Respostas para a questão “Qual a chance de você realizar todas as atividades dessa sequência?”	
a) sequenciamento por AG multiobjetivo b) sequenciamento aleatório	85
Figura 23 – Taxa de preferência das atividades por método de sequenciamento.	
a) sequenciamento por AG multiobjetivo b) sequenciamento aleatório.	86
Figura 24 – Taxa de preferência das atividades por modalidade de ensino (EaD; presencial/remoto.	87

Lista de tabelas

Tabela 1 – Representação bidimensional da Taxonomia de Bloom Revisada.	36
Tabela 2 – Exemplo de atividades digitais para a categoria Lembrar na TBD.	39
Tabela 3 – Subescalas por perfil cognitivo no RASI.	40
Tabela 4 – Trabalhos que utilizam Planejamento Automatizado no contexto educacional.	42
Tabela 5 – Planejamento Automatizado utilizando computação evolutiva.	45
Tabela 6 – Cálculo dos índices RASI para uma sequência de ações.	55
Tabela 7 – Exemplo da ordem de relevância dos índices RASI.	56
Tabela 8 – Questões referentes à percepção dos participantes sobre os índices Revised Approaches to Studying Inventory (RASI) obtidos.	64
Tabela 9 – Grupos de respostas para as questões QA1, QA2, QA3, QA4, QA5 e QA6.	64
Tabela 10 – Grau de relevância entre as categorias RASI e os estados cognitivos da Taxonomia de Bloom (TB).	66
Tabela 11 – Grau de relevância entre as categorias <i>RASI</i> e os estados cognitivos da TB.	67
Tabela 12 – Questionário sobre a satisfação da recomendação pedagógica relativa ao AG mono-objetivo.	68
Tabela 13 – Grupos de respostas para as questões QA4, QA5, QA6, QA7 e QA8.	68
Tabela 14 – Média dos índices RASI para os perfis dos 24 estudantes participantes da Etapa 3 dos experimentos (AG mono-objetivo).	71
Tabela 15 – Questões referentes à percepção dos participantes sobre os índices RASI obtidos.	74
Tabela 16 – Grupos de respostas para as questões QB1, QB2, QB3, QB4, QB5 e QB6.	75
Tabela 17 – Comparação agrupada entre as respostas das questões Q1-Q4, Q2-Q5, Q3-Q6.	75

Tabela 18 – Análise descritiva da quantidade de ações sequenciadas conforme o método usado.	78
Tabela 19 – Questões sobre a satisfação dos participantes em relação à recomendação pedagógica (AG multiobjetivo)	79
Tabela 20 – Grupos de respostas para as questões QB7, QB8, QB9, QB10.	80
Tabela 21 – Descritores estatísticos relativos às respostas para QB7, QB8, QB9 e QB10.	81
Tabela 22 – Teste de Kruskal-Wallis para QB7, QB8, QB9 e QB10.	82
Tabela 23 – Análise correlacional entre as questões QB1, QB2, QB3, QB4, QB5 e QB6.	88
Tabela 24 – Análise correlacional entre as questões QB7, QB8, QB9 e QB10, para o sequenciamento por AG multiobjetivo.	89
Tabela 25 – Análise correlacional entre as questões QB7, QB8, QB9 e QB10, para o sequenciamento aleatório.	89
Tabela 26 – Análise correlacional entre as questões QB1, QB2, QB3, QB4, QB5, QB6, QB7, QB8, QB9 e QB10 entre os participantes com perfil <i>Deep</i>	90
Tabela 27 – Detalhamento do mapeamento entre RASI e TB	113

Lista de siglas

AG Algoritmo Genético

ASSIST Approaches and Study Skills Inventory for Students

AVA Ambiente Virtual de Aprendizagem

AVAs Ambientes Virtuais de Aprendizagem

CAAE Certificado de Apresentação de Apreciação Ética

CEP Comitê de Ética em Pesquisa

CEPs Comitês de Ética em Pesquisa

DC Dimensão do Conhecimento

DPC Dimensão do Processo Cognitivo

EaD Educação a Distância

HOCS Higher Order Cognitive Skills

IA Inteligência Artificial

IF Goiano Instituto Federal de Educação, Ciência e Tecnologia Goiano

IE Informática na Educação

IPC International Planning Competition

LOCS Lower Order Cognitive Skills

NSGA-II Nondominated Sorting Genetic Algorithm II

OAs Objetos de Aprendizagem

PA Planejamento Automatizado

PDDL Planning Domain Definition Language

QP Questão de Pesquisa

QPAs Questões de Pesquisa Auxiliares

RASI Revised Approaches to Studying Inventory

REAs Recursos Educacionais Abertos

SAP Sequenciamento de Ações Pedagógicas

SBIE Simpósio Brasileiro de Informática na Educação

SPEA Strength Pareto Evolutionary Algorithm

SRA Seleção e Recomendação de Atividades

STIs Sistemas Tutores Inteligentes

TB Taxonomia de Bloom

TBD Taxonomia de Bloom Digital

TIC Tecnologia da Informação e Comunicação

TICs Tecnologias da Informação e Comunicação

TOPSIS Technique for Order Preference by Similarity to Ideal Solution

UFU Universidade Federal de Uberlândia

Sumário

1	INTRODUÇÃO	25
1.1	Motivação	28
1.2	Objetivos	29
1.3	Hipótese	30
1.4	Contribuições	31
1.5	Organização da Tese	31
2	REVISÃO DE LITERATURA	33
2.1	Fundamentação Teórica	33
2.1.1	Planejamento Automatizado	33
2.1.2	Taxonomia de Bloom	35
2.1.3	Atividades na Taxonomia de Bloom Digital	38
2.1.4	Perfil RASI do Estudante	40
2.2	Trabalhos Correlatos	41
3	PLANEJADOR DE AÇÕES PEDAGÓGICAS POR ALGO- RITMO GENÉTICO MULTIOBJETIVO	49
3.1	Relacionamento entre Taxonomia de Bloom e <i>RASI</i>	49
3.1.1	Sequências de Ações Pedagógicas	50
3.1.2	Mapeamento: Taxonomia de Bloom x <i>RASI</i>	52
3.2	Sequenciamento usando Algoritmo Genético	53
3.3	Visão Geral da Arquitetura	59
4	EXPERIMENTOS E ANÁLISE DOS RESULTADOS	61
4.1	AG Mono-objetivo: Experimentos e Resultados	62
4.1.1	Etapa 1 - Perfil do Estudante	63
4.1.2	Etapa 2 — Sequenciamento de Ações e Atribuição de Atividades	65
4.1.3	Etapa 3 — Recomendação de Atividades	67

4.2	AG Multiobjetivo: Experimentos e Resultados	72
4.2.1	Etapa 1 — Perfil RASI	72
4.2.2	Etapa 2 — Sequenciamento de Ações	76
4.2.3	Etapa 3 — Recomendação de Atividades	78
5	CONCLUSÕES	93
5.1	Contribuições	93
5.2	Contribuições em Produção Bibliográfica	95
5.3	Trabalhos Futuros	96
	REFERÊNCIAS	97

APÊNDICES **105**

APÊNDICE A	— QUESTIONÁRIO RASI	107
A.1	RASI - versão completa (52 questões)	107
A.2	RASI - versão curta (18 questões)	110
APÊNDICE B	— MAPEAMENTO ENTRE TB E RASI	113
B.1	Tabela de mapeamento (RASI x TB)	113

Introdução

Em estudos recentes, é evidenciada a necessidade de investigar soluções inteligentes atuantes em Ambientes Virtuais de Aprendizagem (AVAs) ou em Sistemas Tutores Inteligentes (STIs), por exemplo, para apoio ao processo pedagógico (PENG; MA; SPECTOR, 2019; MORO; TAROUCO; VICARI, 2021). O sequenciamento e a recomendação, ambos personalizados, de ações pedagógicas são alguns dos aspectos deste processo que podem ser realizados para contribuir na obtenção de tais soluções.

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.

A técnica de PA consiste em definir, de forma automatizada, uma sequência de ações com o propósito de cumprir um objetivo. Nesse processo, o objetivo é a otimização na escolha das ações. Diante disso, existe uma variedade de planejadores e abordagens distintas para classificá-los, como observado em Nau, Ghallab e Traverso (2004, p. 2–16) e Russel, Norvig et al. (2013, p. 366–436). Nos últimos anos, houve uma evolução de trabalhos que utilizam técnicas de PA com o propósito de sequenciar ações com vistas à personalização do processo de sequenciamento. Entretanto, nota-se que a *Planning Domain Definition Language (PDDL)*, linguagem comumente utilizada para o PA, pode não ser a opção mais assertiva nesse cenário, pois, no contexto educacional, por exemplo, à medida que a caracterização do perfil do estudante é refinada e utilizados mais parâmetros para auxiliar no planejamento, tornam-se mais limitadas as heurísticas que possibilitam a busca no espaço de soluções, conforme relatado em Costa et al. (2019).

Como alternativa à *PDDL*, podem ser utilizados algoritmos baseados em computação bio-inspirada para realização de sequenciamento de ações pedagógicas. Tal enfoque, como observado em Hssina e Erritali (2019), parte do princípio de que essa categoria de pro-

blema pode ser interpretada como um problema de otimização. Diante disso, a grande disponibilidade de dados justifica o uso dessa técnica, visto que a manipulação via *PDDL* exigiria alto esforço computacional. Sendo assim, o uso de Algoritmo Genético (AG) pode ser uma alternativa (DWIVEDI; KANT; BHARADWAJ, 2018).

A modelagem das ações pedagógicas é um fator importante no sequenciamento pedagógico. Conforme relatado em Costa et al. (2019), é comum a composição de ações a partir da hierarquia posta entre objetos de aprendizagem ou até mesmo a estrutura curricular de um curso. Em tais abordagens, o processo cognitivo do estudante é geralmente preterido em relação às regras ou restrições de encadeamento de objetos de aprendizagem, ou conteúdo. Também em Costa et al. (2019), a Taxonomia de Bloom (TB)¹, desenvolvida por Bloom et al. (1984) e revisada por Krathwohl (2002), pode ser uma alternativa, pois estrutura as ações a partir do domínio cognitivo do estudante, composto pelo processo cognitivo e pelo conhecimento. Assim, a TB oferece suporte para modelagem de ações com base no processo cognitivo e na sua relação com o conhecimento, oferecendo uma análise bidimensional dos objetivos educacionais.

A TB, mostrada em Krathwohl (2002), e o RASI, discutido em Tait e Entwistle (1996), são adequados para a proposta de uma recomendação pedagógica baseada no processo cognitivo do estudante.

A TB é um modelo bidimensional para o processo de aprendizagem e uma dessas dimensões define o processo cognitivo com seis categorias, começando das habilidades cognitivas de ordem inferior e indo para as habilidades cognitivas de ordem superior, encontradas na literatura, respectivamente, como *Lower Order Cognitive Skills (LOCS)* e *Higher Order Cognitive Skills (HOCS)*. A 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 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.

Uma relação entre RASI e TB foi parcialmente explorada e utilizada para realizar recomendações pedagógicas (BROWN et al., 2015; SHANG, 2019). Recomendações pedagógicas automatizadas podem ser entendidas como um procedimento dividido em identificação dos objetivos de aprendizagem, caracterização do perfil do estudante para identificar suas necessidades e o grau de relação entre o perfil do estudante e os objetivos de aprendizagem. De acordo com Lu et al. (2015) e Tarus, Niu e Mustafa (2018), as regras pedagógicas desempenham um papel essencial na construção de recomendações. Júnior, Dorça e Araujo (2019) descrevem que para recomendadores pedagógicos que utilizam requisitos ou restrições curriculares entre Objetos de Aprendizagem (OAs), a recomendação depende da estrutura curricular e, conseqüentemente, da atuação de especialistas. Assim, a investiga-

¹ Neste trabalho, as menções à Taxonomia de Bloom dizem respeito à versão revisada, proposta em Krathwohl (2002).

ção de outros requisitos, como o processo cognitivo do estudante, é uma alternativa que evita essas dependências e é um dos objetivos deste trabalho.

Um desafio emergente da IA aplicada à Educação é a recomendação pedagógica personalizada para o estudante, cujo objetivo é adaptar o processo de aprendizagem às necessidades deste, segundo suas características. Tal intervenção pode adotar ações reativas ou preventivas, vinculadas às questões pedagógicas definidas. Além disso, os recursos educacionais utilizados podem ser nativos de ambientes de aprendizagem ou disponibilizados externamente, conforme observado em Paiva et al. (2015). Nesse sentido, a personalização da recomendação pedagógica pode ser realizada a partir da observação de diversas características do estudante, como, por exemplo, estilos de aprendizagem, metadados de Ambiente Virtual de Aprendizagem (AVA), nível de satisfação, desempenho em atividades, entre outras (COSTA; JÚNIOR; FERNANDES, 2019).

Para tornar possível a personalização a partir de ações delineadas sob a ótica da TB, um método adequado pode ser a abordagem do estudante à aprendizagem, coletada através do questionário RASI, definido em Tait e Entwistle (1996). Através do RASI, é possível criar uma interface com o domínio cognitivo estabelecido na TB, pois modela a abordagem à aprendizagem preposta pelo estudante, considerando uma evolução de LOCS para HOCS.

Geralmente, o sequenciamento pedagógico está relacionado a estruturas curriculares ou ao encadeamento de conteúdos, como relatado em Costa et al. (2019). Desse modo, um desafio pertinente é a proposição de alternativas que pautem o sequenciamento personalizado em aspectos cognitivos do estudante, de modo a reduzir ou eliminar a dependência de condições impostas por restrições curriculares, relacionamento entre OAs ou encadeamento de conteúdos. Para tal, a TB define um modelo para o estado cognitivo do estudante, sob o qual é possível delinear ações pedagógicas que quando sequenciadas adequadamente, podem auxiliar o processo de aprendizagem.

A TB define objetivos educacionais, que podem ser traduzidos em ações pedagógicas do ponto de vista da Dimensão do Processo Cognitivo (DPC) e da Dimensão do Conhecimento (DC), como proposto em Krathwohl (2002). Nessa conjuntura, as ações pedagógicas representam o processo cognitivo do estudante, podendo ser aplicadas em qualquer estrutura curricular. Tais ações, para se tornarem viáveis do ponto de vista da recomendação automatizada, precisam ser traduzidas em atividades. Uma proposta de atividades digitais é observada na Taxonomia de Bloom Digital, descrita em Churches (2010). Essa, descreve atividades decorrentes da inserção das Tecnologias da Informação e Comunicação (TICs) no cenário educacional, para cada uma das categorias da DPC. Desse modo, o uso da TB torna-se instigante, por prover um arcabouço passível de delinear o sequenciamento de ações, bem como balizar atividades para recomendação.

Portanto, esta pesquisa é norteada pela investigação sobre as possibilidades de sequenciamento automatizado e personalizado, de tal sorte que esse não dependa da estrutura curricular. Assim, a proposta principal deste trabalho é sequenciar e recomendar ações

pedagógicas baseadas no processo cognitivo do estudante. Desse modo, são apresentados tanto o sequenciador, quanto o recomendador, sendo que o segundo utiliza atividades digitais baseado 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 um planejamento automatizado apoiado por um AG multiobjetivo. Além disso, as ações pedagógicas são modeladas pela TB na perspectiva do processo cognitivo do estudante e as atividades digitais são aquelas propostas pela Taxonomia de Bloom Digital (TBD).

1.1 Motivação

A área de Informática na Educação (IE) está relacionada com a pesquisa de processos de ensino, de aprendizagem, ou ambos, em diversos níveis e modalidades educacionais que ocorrem por meio do computador, visando incrementar os ambientes virtuais com estratégias e ferramentas capazes de promover aprendizagem de qualidade. Desse modo, tal processo pode se relacionar com órgãos de pesquisa, escolas públicas ou mesmo o mercado. Por meio da IE já é possível observar a possibilidade de gerar alterações no contexto pedagógico para além da simples automatização de processos educacionais (VALENTE et al., 1999). Nessa área, técnicas computacionais que promovem intervenções, como o sequenciamento pedagógico, podem ser utilizadas para auxiliar no processo de aprendizagem, podendo ainda contar com suporte de PA, como considerado em Moreira, Pimentel e Maschio (2016) e Costa, Júnior e Fernandes (2019), por exemplo.

Observa-se ainda que o sequenciamento personalizado, cujo objetivo é produzir recomendações pedagógicas, se destaca, pois, pode promover a melhora do desempenho do estudante, conforme observado na literatura. Em Cordova e Lepper (1996), esse processo foi explorado com tal propósito, além de contribuir na motivação de estudantes. No trabalho de Kurilovas, Kubilinskiene e Dagiene (2014), é apresentada uma proposta de personalização do ponto de vista de OAs em um AVA, considerando os estilos de aprendizagem do estudante. Em Garrido, Morales e Serina (2016), o planejamento automatizado foi utilizado com a finalidade de prover rotas de aprendizagem personalizadas, por meio do sequenciamento de OAs baseado em requisitos pedagógicos e dos estudantes.

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 proposto em Entwistle e Tait (2013) é relatada a utilização do *Approaches and Study Skills Inventory for Students (ASSIST)* como ferramenta de análise multidimensional para representar as estratégias de predileção dos estudantes no processo de aprendizagem. Uma de suas dimensões, denominada RASI e detalhada em Tait e Entwistle (1996) é componente do perfil cognitivo do estudante e 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 abordada de maneira parcial em Brown et al. (2015) e em Shang (2019), acendendo a investigação sobre a capacidade de relacionamento.

Tanto as ações quanto o perfil do estudante, são elementos importantes para realização do sequenciamento personalizado dessas ações. Observa-se que tal sequenciamento pode ser tratado como um problema de planejamento automatizado. Uma vantagem no uso de técnicas de planejamento automatizado nesse contexto é perceber que essa atua como uma interface entre as necessidades do *e-learning* e a oferta de personalização do processo pedagógico ao estudante, como observado em Garrido e Morales (2014) e em Pireva e Kefalas (2018). Além disso, a utilização de AG para implementar o planejamento automatizado é uma alternativa promissora, como relatado em Ariyaratne e Fernando (2014), e pode auxiliar no desenvolvimento de um arcabouço capaz de prover sequenciamento pedagógico automatizado através de um AVA ou outra ferramenta educacional.

1.2 Objetivos

A utilização de PA pode ser uma alternativa viável para o sequenciamento de ações pedagógicas. Destaca-se ainda que tais ações, quando produzidas a partir do processo cognitivo do estudante, podem contribuir com o diferencial de desvincular esse sequenciamento das estruturas curriculares ou do encadeamento de conteúdos, no intuito de simplificar e tornar mais flexível o processo de recomendação pedagógica. Diante disso, a seguir são apresentados os objetivos geral e específicos deste trabalho.

□ Objetivo Geral:

- Sequenciar e recomendar atividades pedagógicas ao estudante, modeladas pela Taxonomia de Bloom e a partir do sequenciamento personalizado de ações pedagógicas segundo o *Revised Approaches to Studying Inventory*, com base no planejamento automatizado usando algoritmo genético.

□ Objetivos Específicos:

- Modelar o problema de sequenciamento de ações sob a perspectiva do planejamento automatizado.
- Estabelecer relação entre as ações pedagógicas da TB e o perfil *RASI* do estudante.
- Abordar o problema de sequenciamento de ações pedagógicas como um problema de otimização, utilizando um algoritmo genético multiobjetivo e a relação TB/RASI.
- Recomendar sequências de atividades obtidas pelo AG aos estudantes. Analisar a percepção dos estudantes acerca das atividades recomendadas.

A partir disso, o refinamento da modelagem do estudante visando identificar heurísticas que otimizem o PA torna-se um desafio emergente. Concomitantemente, outros desafios nesta proposta relacionam-se com o desenvolvimento de um modelo que possibilite a convergência entre as teorias norteadoras da modelagem das ações pedagógicas e do perfil do estudante.

1.3 Hipótese

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?
- ❑ 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?

Considerando as questões de pesquisa supracitadas, as seguintes hipóteses foram formuladas:

- ❑ Hipótese nula (H0): O sequenciamento de ações pedagógicas baseadas na Taxonomia de Bloom, automatizado por Algoritmo Genético e personalizado segundo o perfil RASI não produz satisfação da necessidade de aprendizagem conforme o perfil ao estudante.
- ❑ Hipótese alternativa (H1): O sequenciamento de ações pedagógicas baseadas na Taxonomia de Bloom, automatizado por Algoritmo Genético e personalizado segundo o perfil RASI produz satisfação da necessidade de aprendizagem conforme o perfil ao estudante.

O conceito de satisfação utilizado neste trabalho considera a discussão apresentada em Moraes et al. (2021), onde a qualidade didática pode ser uma das dimensões para análise da satisfação acadêmica. Nesse sentido, alguns aspectos que podem mensurar a qualidade didática, segundo esta proposta, são: i) quantidade de atividades recomendadas; ii) grau de conforto ao realizar as atividades; e iii) probabilidade de realizar todas as atividades.

Considerando as hipóteses propostas, se estabelece a necessidade da investigação sobre a efetividade da utilização de PA voltado para recomendações com enfoque no processo pedagógico.

1.4 Contribuições

Buscando a interdisciplinaridade, esta pesquisa visa contribuir para as áreas de Inteligência Artificial e Educação. Como já observado, este trabalho propõe a recomendação de atividades digitais a partir do sequenciamento automatizado e personalizado de ações pedagógicas, baseado no perfil RASI do estudante. Essas ações são modeladas de acordo com o domínio cognitivo da TB. Nesse caso, para tornar a recomendação viável, é necessário estabelecer o relacionamento de tais ações com atividades que possam de fato ser executadas pelo estudante. Diante disso, uma das contribuições neste trabalho é o mapeamento entre as atividades digitais da Taxonomia de Bloom Digital dispostas num modelo unidimensional, para um modelo bidimensional.

A pesquisa sobre uma técnica viável para a estruturação de ações sob a ótica do processo cognitivo é uma questão relevante, visto que é componente essencial para o objetivo do PA. Assim, o modelo do estudante também é um fator que pode gerar grande impacto na solução proposta, desse modo, a análise de uma abordagem que estabeleça uma ponte entre o sequenciamento de ações e as características do estudante é outro aspecto significativo. Por fim, para se tornar factível a recomendação é necessário um estudo sobre perspectivas que proporcionem a definição de atividades passíveis de recomendação a partir do sequenciamento de ações.

Outra contribuição deste trabalho é o estabelecimento da relação entre a TB e o RASI, provendo um mapeamento entre as categorias da Dimensão do Processo Cognitivo na TB e os eixos RASI (*Surface*, *Strategic* e *Deep*). Com isso, é viável estabelecer o grau de aderência entre uma sequência de ações e o perfil do estudante. Além disso, o PA é implementado usando AG multiobjetivo e uma de suas funções de aptidão (*fitness*) incorpora o resultado do mapeamento entre a TB e o RASI, sendo outra contribuição deste trabalho. A partir de experimentos iniciais, foram percebidas quantidades de atividades referenciais segundo o perfil do estudante. Essa referência é a base para compor o segundo objetivo do AG e é outra contribuição deste trabalho.

1.5 Organização da Tese

A organização desta tese se dá da seguinte maneira: no Capítulo 2 é apresentada uma revisão da literatura, envolvendo a fundamentação teórica essencial para a compreensão da proposta e uma síntese sobre os trabalhos correlatos; no Capítulo 3 é detalhada a proposta para o sequenciamento e a recomendação pedagógica, destacando o arcabouço desenvol-

vido para atingir o objetivo deste trabalho; no Capítulo 4 são abordados os experimentos e a análise dos resultados, ressaltando os achados oriundos da pesquisa desenvolvida; no Capítulo 5 é apresentada a conclusão, abrangendo as contribuições, as fragilidades e as possibilidades de evolução desta pesquisa.

Revisão de Literatura

O escopo da proposta deste trabalho é a realização do sequenciamento personalizado de ações pedagógicas e sua recomendação ao estudante, sob a forma de atividades digitais. Sendo assim, na Seção 2.1 é apresentado o arcabouço teórico relativo ao planejamento automatizado, necessário para o sequenciamento de ações, bem como a Taxonomia de Bloom, utilizada para modelar tais ações, além do RASI que caracteriza o perfil do estudante. Já na Seção 2.2, é apresentada a revisão da literatura correlata.

2.1 Fundamentação Teórica

Esta seção é dedicada à definição dos principais conceitos necessários ao desenvolvimento da corrente pesquisa. Neste sentido, são apresentadas considerações acerca de: planejamento automatizado; modelagem das ações pedagógicas considerando a Taxonomia de Bloom; atividades digitais propostas na Taxonomia de Bloom Digital; e do modelo do estudante sob a perspectiva do *Revised Approaches to Studying Inventory*.

2.1.1 Planejamento Automatizado

O Planejamento Automatizado é uma área da Inteligência Artificial que trata do sequenciamento de ações de modo a atingir um objetivo, conforme definição em Nau, Ghalab e Traverso (2004, p. 25):

“Planning is the reasoning side of acting. It is an abstract, explicit deliberation process that chooses and organizes actions by anticipating their expected outcomes. This deliberation aims at achieving as best as possible some pre-stated objectives. Automated planning is an area of Artificial Intelligence (AI) that studies this deliberation process computationally.”

Conforme definido em Cimatti, Pistore e Traverso (2008, p. 842), o planejamento automatizado é composto por domínios, planos e objetivos. Os domínios podem ser

não-determinísticos e parcialmente observáveis. Os planos são baseados no histórico de etapas de execução anteriores e podem ser sequenciais (sequência de ações), condicionais (baseados na situação atual), e interativos (executam até a ocorrência de uma situação). Os objetivos correspondem às evoluções desejadas em um domínio do planejamento.

Sendo assim, para realizar o planejamento automatizado, é necessário definir os seguintes artefatos: estado inicial; ações acessíveis num estado; resultado do emprego de uma ação; e teste de objetivo. Uma maneira de realizar o planejamento é por meio da *PDDL*, que consiste na representação do estado do mundo a partir de um conjunto de variáveis, conforme Russell e Norvig (2010, p. 367). Além disso, técnicas como AG podem ser empregadas a partir da modelagem sob a ótica do PA, segundo Russell e Norvig (2010, pp. 185–187).

A *PDDL* é uma linguagem utilizada para o planejamento em inteligência artificial, criada em 1998. Dentre suas vantagens, destaca-se a simplificação na reutilização de pesquisas e, por consequência, uma evolução mais acelerada nessa área (MCDERMOTT et al., 1998; FOX; LONG, 2002). Com a adoção dessa linguagem a partir de 1998 na primeira edição da *International Planning Competition (IPC)*¹, sua evolução se tornou constante, possibilitando representar novos elementos acerca do domínio do planejamento. Para ser viável o planejamento via *PDDL*, são necessários o *parser* e o *planner*, ambos implementados de acordo com versão da *PDDL* a ser utilizada. Uma limitação da *PDDL* re-soa no fato de que à medida que são incluídos novos parâmetros, a dificuldade computacional do problema de busca também é incrementada (ARIYARATNE; FERNANDO, 2014). Sendo assim, outras técnicas de Inteligência Artificial podem ser preferíveis na implementação do planejador, como o uso de Algoritmo Genético, observado em Christudas, Kirubakaran e Thangaiyah (2018).

Problemas de planejamento podem ser modelados sob a ótica da otimização multiobjetivo. Esta é utilizada quando há mais de uma função-objetivo a ser otimizada e restrições a serem satisfeitas para tornar a solução viável, porém, há conflitos entre esses. Ou seja, para que uma função-objetivo seja otimizada, uma ou mais funções são preteridas (ENGELBRECHT ANDRIES, 2007, p. 170). De acordo com Santos (2017, p. 40), considere N_{obj} o número de funções-objetivo compondo o vetor $f(x) = [f_1(x), f_2(x), \dots, f_{N_{obj}}(x)]^T$. Então, temos a Eq. 1:

$$\text{minimizar} | \text{maximizar } f(x) \quad (1)$$

Sujeita às restrições dadas pelas equações 2, 3 e 4, conforme a seguir:

$$g_j(x) \geq 0, j = 1, \dots, J \quad (2)$$

$$h_k(x) = 0, k = 1, \dots, K \quad (3)$$

¹ <https://www.icaps-conference.org/competitions/>

$$x_i^{(inf)} \leq x_i \leq x_i^{(sup)} \quad (4)$$

Onde o vetor de variáveis de decisão $x = [x_1, x_2, \dots, x_{Nvar}]^T$. J é a quantidade de restrições de desigualdade e K a de igualdade. As desigualdades dadas pela Eq. 2 e pela Eq. 3, $g_j(x)$ e $h_k(x)$, respectivamente, são as funções de restrição. Os valores $x_i^{(inf)}$ e $x_i^{(sup)}$, expressos na Eq. 4, são os limites inferior e superior de x_i . Sendo assim, o conjunto das soluções viáveis compõe o espaço de busca. Logo, o vetor de funções-objetivo $f(x) = [f_1(x), f_2(x), \dots, f_{Nobj}(x)]^T$ pertence ao espaço de objetivos. Ou seja, para cada solução x no espaço de decisão, há um ponto $f(x)$ no espaço de objetivos.

Uma maneira de abordar problemas de otimização multiobjetivo é usando a soma ponderada, cujo intuito é transformar um problema multiobjetivo em um problema mono-objetivo. Desta forma, associa-se um peso a cada objetivo, representando a importância do objetivo em relação aos demais, o que culmina numa combinação linear, conforme dado pela Eq. 5:

$$f(x) = \sum_{i=1}^m w_i f_i(x) \quad (5)$$

onde w_i é peso que o objetivo f_i representa em relação aos demais objetivos do problema, sendo $w_i \geq 0$. A soma dos pesos é normalizada, conforme a Eq. 6:

$$\sum_{i=1}^m w_i = 1 \quad (6)$$

Conforme descrito em Engelbrecht Andries (2007, p. 170 e 570), métodos para otimização multiobjetivo requerem, em geral, soluções mais complexas do que nos casos em que há apenas um objetivo a ser otimizado. Nesse sentido, o emprego de algoritmos genéticos pode ser uma estratégia interessante, visto que esses partem sua busca de um conjunto de soluções cujas informações podem pertencer a diversas regiões do espaço de busca.

A partir dessas considerações, neste trabalho, utilizou-se um AG multiobjetivo com 2 objetivos. A otimização desse AG foi realizada por meio da soma ponderada dos objetivos. A escolha da soma ponderada se deveu ao fato de que testes exploratórios considerando a fronteira de Pareto para os algoritmos *Nondominated Sorting Genetic Algorithm II (NSGA-II)* e *Strength Pareto Evolutionary Algorithm (SPEA)*, conforme apresentado em Konak, Coit e Smith (2006), retornaram soluções menos aptas do que utilizando a soma ponderada.

2.1.2 Taxonomia de Bloom

No trabalho apresentado por Costa et al. (2019), é evidenciado que as recomendações pedagógicas oriundas do Planejamento Automatizado, majoritariamente focam na etapa de sequenciamento de objetos de aprendizagem, requerendo conhecimento específico

acerca da estrutura curricular de cursos, bem como o arranjo entre conteúdos. Diante disso, nota-se a carência de trabalhos cujo foco seja o encadeamento de ações que abranjam o processo pedagógico.

Segundo Krathwohl (2002), a Taxonomia de Bloom 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. Outra dimensão, denominada Dimensão do Conhecimento (DC), é composta por quatro níveis e representa o conhecimento a ser alcançado ou produzido pelo estudante. Na Tabela 1 é apresentada tal estrutura para o domínio cognitivo, considerando ambas as dimensões:

Tabela 1 – Representação bidimensional da Taxonomia de Bloom Revisada.

Dimensão do Conhecimento	Dimensão do Processo Cognitivo					
	1. Lembrar	2. Compreender	3. Aplicar	4. Analisar	5. Avaliar	6. Criar
A. Conhecimento Factual						
B. Conhecimento Conceitual						
C. Conhecimento Procedural						
D. Conhecimento Metacognitivo						

Fonte: Adaptado de Krathwohl (2002).

Na Tabela 1, a Dimensão do Processo Cognitivo é composta hierarquicamente por seis estados, representados pelos verbos: *Lembrar*, *Entender*, *Aplicar*, *Analisar*, *Avaliar* e *Criar*. Como descrito em Ferraz, Belhot et al. (2010), os seis estados são representados por verbos no gerúndio, conforme apresentados a seguir:

- ❑ O estado *Lembrar* é representado pelos verbos *Reconhecendo* e *Reproduzindo*. Assim, observa-se a importância da recuperação e reprodução de informação significativa.
- ❑ No estado *Entender* ocorre a relação entre os conhecimentos atual e anterior, adquiridos. Assim, os verbos que representam este estado são: *Classificando*, *Comparando*, *Exemplificando*, *Explicando*, *Inferindo*, *Interpretando* e *Resumindo*.
- ❑ O estado *Aplicar* é representado pelos verbos *Executando* e *Implementando*. Outrossim, observa-se a utilização ou execução de estratégias em situações conhecidas, ou novas.

- ❑ O estado *Analisar* é representado pelos verbos *Diferenciando*, *Organizando*, *Atribuindo* e *Concluindo*. Além disso, há a segmentação da informação entre partes importantes e desnecessárias e como as partes se relacionam.
- ❑ O estado *Avaliar* é representado pelos verbos *Checando* e *Criticando*. Ademais, espera-se o equacionamento por paradigmas e parâmetros qualitativos e quantitativos, além da eficiência e eficácia.
- ❑ O estado *Criar* é representado pelos verbos *Generalizando*, *Planejando*, *Produzindo*. Portanto, espera-se a concepção de novas perspectivas, recursos, arranjos ou paradigmas, utilizando conhecimentos e habilidades pré-existentes.

Ainda na Tabela 1, a Dimensão do Conhecimento diz respeito ao conhecimento adquirido ou produzido sendo dividida em quatro etapas descritas por Ferraz, Belhot et al. (2010) conforme a seguir:

- ❑ O *Conhecimento Factual* vincula-se ao conhecimento elementar, necessário ao estudante para resolver problemas.
- ❑ O *Conhecimento Conceitual* diz respeito à inter-relação de conceitos básicos, aplicados num cenário que exija a ciência de uma estrutura básica para a resolução de determinado problema.
- ❑ O *Conhecimento Procedural* está ligado à forma como será resolvido determinado problema, por técnicas, métodos, critérios e algoritmos adequados.
- ❑ O *Conhecimento Metacognitivo* envolve a identificação da cognição, além de reconhecer o quão ampla e profunda é a aquisição do conhecimento de um conteúdo específico, portanto, nessa etapa, espera-se que a interdisciplinaridade seja aplicada ao desenvolvimento de soluções para problemas.

Os objetivos presentes na representação bidimensional da Taxonomia de Bloom, conforme a Tabela 1, considerando a ordem da esquerda para a direita e de cima para baixo, são uma variação das habilidades cognitivas, partindo de *Lower Order Cognitive Skills* (LOCS) para a *Higher Order Cognitive Skills* (HOCS). Segundo Zoller (1993), LOCS estão relacionadas com a recordação e execução algorítmica de ações, enquanto que HOCS relacionam-se com uma perspectiva de resolução de problemas, pensamento sistêmico crítico e de tomada de decisão. Ainda segundo Zoller (1993), na educação superior, é desejável a utilização de estratégias de ensino que promovam essa evolução cognitiva do estudante no sentido de LOCS para HOCS.

Na Taxonomia de Bloom original, as categorias das dimensões possuem uma hierarquia em relação à complexidade dos objetivos, porém após sua revisão, considerou-se relevante permitir sua flexibilização por parte do docente, quando necessário, de modo a suprimir

uma ou mais categorias consoante as necessidades do estudante. A partir dessa flexibilização hierárquica, as possibilidades de arranjos nas sequências de ações pedagógicas são inúmeras, pois há uma análise bidimensional onde a quantidade de categorias para as dimensões do processo cognitivo e do conhecimento são 6 e 4, respectivamente. A partir disso, podemos considerar um total de 24 ações pedagógicas. Partindo do pressuposto que essas 24 ações podem ou não ser recomendadas, sem necessariamente seguir uma sequência adjacente, temos então 16.777.216 possibilidades de sequenciamento. Cabe ressaltar ser importante nesse sequenciamento seguir a ordem crescente a partir de LOCS para HOCS, mas não necessariamente todas as ações precisam ser recomendadas, dadas as necessidades do estudante.

A estrutura de objetivos educacionais da Taxonomia de Bloom permite sua aplicação em diversos cenários, como no trabalho apresentado por Zhang et al. (2021), que classificou as tarefas de avaliação de forma automatizada por meio do aprendizado de máquina. Já no trabalho proposto por Callaghan-Koru e Aqil (2020), os cursos de graduação em saúde coletiva foram concebidos a partir da hierarquia dos processos cognitivos na Taxonomia de Bloom. O trabalho proposto por Prasad (2021), explora a Taxonomia de Bloom para identificar o desempenho dos estudantes em aulas *online*, explorando o domínio cognitivo. Assim, observa-se ser possível utilizar a hierarquia de objetivos educacionais fornecida pela Taxonomia de Bloom em diversificados cenários.

No entanto, cada posição da Tabela 1 deveria estar associada a uma atividade pedagógica digital, desde que a intenção deste trabalho é que essa atividade seja realizada em ambientes virtuais de aprendizagem. A seleção dessas atividades depende de uma identificação de atividades digitais para cada uma dessas posições, o que pode ser fornecido pela Taxonomia de Bloom Digital.

2.1.3 Atividades na Taxonomia de Bloom Digital

Churches (2010) propõe uma extensão da Taxonomia de Bloom, denominada Taxonomia Digital de Bloom (TBD), relatando as perspectivas de aprendizagem disponíveis a partir da crescente inserção das TICs no cenário educacional. Desse modo, tal abordagem atua na definição de elementos cognitivos, além de métodos e ferramentas passíveis de utilização em um ambiente digital. Em decorrência disso, observamos sua aplicação em outros trabalhos, por representar comportamentos, ações e formas de trabalho emergentes decorrentes dos avanços associados às Tecnologia da Informação e Comunicação (TIC)'s. Na Tabela 2 são transcritas as atividades digitais selecionadas para a categoria *Lembrar*.

Nos trabalhos apresentados por Lambert (2012) e por Ohler (2013), a Taxonomia de Bloom Digital é apresentada como alternativa na alfabetização de crianças, por meio da utilização de OAs adequados para o conto de histórias. No relato apresentado por Leu et al. (2017), é evidenciada a importância da evolução de técnicas utilizadas à realidade proporcionada pela educação mediada por computador e nesse sentido, a Taxonomia de

Tabela 2 – Exemplo de atividades digitais para a categoria Lembrar na TBD.

Remember	Possible Activities
<i>Recalling specific information (Recall or recognition of specific information). Recognizing, Listing, Describing, Identifying, Retrieving, Naming, Locating/Finding, Bullet pointing, highlighting, bookmarking, social networking, Social bookmarking, favoriting/local bookmarking, Searching, googling.</i>	<ul style="list-style-type: none"> * Quiz/Test (Online tools, WP, Cue sheets) * Flashcards (Moodle, Hot potatoes, scorm objects) * Definition (WP – bullets and lists, simple Mind maps, wiki, Moodle Glossary) * Fact (WP – bullets and lists, Mind maps, internet, discussion boards, email) Worksheet/book (WP, Mind map, Web, clozed activities) * Label (WP, graphics tools) * List (WP – bullets and lists, Mind map, Web publishing – personal web page, blog journal) * Reproduction (WP – note writing dication, web publishing personal web page, blog journal, graphics tools, Chatrooms, email, discussion boards) * Bookmarking internet browsers, web 2.0 tools del.icio.us * Social Networking - facebook, mspaces, bebo * Basic Searches - search engines

Fonte: Retirado de Churches (2010).

Bloom Digital é uma ferramenta importante, pois acompanha as mudanças pelas quais passam os estudantes em relação à leitura, escrita, aprendizagem e comunicação, proporcionados pelo avanço tecnológico.

Conforme relatado em Camilleri, Ehlers e Pawlowski (2014), a Taxonomia de Bloom Digital é descrita como um importante elemento na integração entre um AVA e os Recursos Educacionais Abertos (REAs), tornando a TB capaz de descrever atividades que podem ser executadas sobre os OAs disponíveis. No trabalho apresentado em Paiva e Padilha (2012), a Taxonomia Digital de Bloom é utilizada no sob a perspectiva da metodologia *WebQuest*, com o intuito de guiar o desenvolvimento de tarefas sob a perspectiva de novos recursos ofertados pelo desenvolvimento tecnológico.

Um trabalho inspirado na Taxonomia Digital de Bloom, apresentado por Schrock, Kathy (2011), mapeia ferramentas *online* segmentadas por plataforma (iPad², Android³, G Suite⁴ e Web), de acordo com as seis categorias da Dimensão do Processo Cognitivo. Esse trabalho proveu um arcabouço relacionado à Taxonomia de Bloom, de modo que atendesse aos interesses de aprendizagem dos estudantes, além e fornecer suporte aos docentes na disponibilização de opções de atividades digitais que fomentassem o processo de ensino e de aprendizagem. Este trabalho estende a proposta de Churches (2010), mapeando as atividades digitais considerando também a Dimensão do Conhecimento.

² <https://www.apple.com/ipad/>

³ <https://www.android.com/>

⁴ <https://workspace.google.com/>

2.1.4 Perfil RASI do Estudante

Conforme relatado em Duff (2004), o *Revised Approaches to Studying Inventory* (RASI) é um questionário amplamente utilizado no auxílio à identificação das abordagens de aprendizagem de estudantes no ensino superior. Além disso, desde sua proposição, concebido por Entwistle, Hanley e Hounsell (1979) sob o nome de *Approaches to Studying Inventory* (ASI), o RASI visa refletir as mudanças ocorridas no ensino superior.

Através do questionário RASI, é possível avaliar o perfil cognitivo do estudante sob 3 dimensões: *Surface*, *Strategic* e *Deep*. Cada uma dessas dimensões é composta por subescalas, conforme apresentado na Tabela 3.

Tabela 3 – Subescalas por perfil cognitivo no RASI.

Perfis x Subescalas		
Deep	Strategic	Surface
<ul style="list-style-type: none"> - Buscando significado - Relacionando ideias - Uso de evidência - Interesse em ideias - Monitorando a eficácia 	<ul style="list-style-type: none"> - Estudo organizado Gerenciamento de tempo - Realização - Prontidão para demandas de avaliação 	<ul style="list-style-type: none"> - Falta de propósito - Memorização não relacionada - Medo do fracasso - Limite do plano de estudos

Fonte: Adaptado de Entwistle e Tait (2013).

Há duas versões mais recentes do RASI, disponíveis em Entwistle e Tait (2013). Uma versão é composta por 52 questões e a outra por 18 questões⁵. Em ambas as versões, há a distribuição das questões conforme subescalas exibidas na Tabela 3. Para cada uma das questões apresentadas, o estudante tem como opções de resposta uma escala Likert⁶ de 5 níveis, sendo eles: *Discordo*, *Discordo Parcialmente*, *Indiferente*, *Concordo Parcialmente* e *Concordo*.

Um estudante pode apresentar diferentes níveis para cada um desses perfis, compondo um amplo espectro de possibilidades. Em geral, o perfil *Surface*, indica o direcionamento do processo de aprendizagem para os requisitos da avaliação. O perfil *Strategic* é pautado pela satisfação pessoal, ou seja, a priorização de melhores resultados através de um estudo organizado e otimizando o tempo. Já o perfil *Deep* está relacionado ao direcionamento do estudo para atividades de ensino desafiadoras e objetivam a pesquisa pelo significado das coisas (ENTWISTLE; HANLEY; HOUNSELL, 1979).

Ainda no trabalho de Entwistle e Tait (2013), é observado a utilização do RASI como parte de um questionário maior, denominado *Approaches and Study Skills Inventory for Students* (ASSIST). Nesse questionário, as questões são agrupadas sob três perspectivas:

⁵ Ambas as versões foram traduzidas livremente para o Português, conforme apresentado no Apêndice A. A versão original em Inglês desses questionários está disponível em Entwistle e Tait (2013).

⁶ LIKERT, R. A technique for the measurement of attitudes. **Archives of psychology**, 1932.

- ❑ Identificação de como o estudante compreende a aprendizagem. O questionário utilizado nessa dimensão é composto por seis questões.
- ❑ Identificação de como o estudante aborda o estudo, por meio do RASI. O questionário nessa dimensão possui 52 questões, na versão completa, e 18 questões, na versão curta.
- ❑ Identificação das preferências do estudante em relação ao ensino. Nessa dimensão, o questionário apresenta oito questões.

O RASI delinea o processo de evolução cognitiva do estudante, partindo de *Lower Order Cognitive Skills* (LOCS) até *Higher Order Cognitive Skills* (HOCS), assim como a TB. Em Brown et al. (2015) é sugerida tal equivalência, associando o eixo *Surface* e LOCS. Já em Shang (2019) é estabelecida uma relação entre o perfil *Deep* e os estados cognitivos da TB. Diante disso, considerou-se viável utilizar o RASI com o intuito de fornecer parâmetros capazes de subsidiar o sequenciamento de ações pedagógicas baseadas na Taxonomia de Bloom e, assim, esse mapeamento foi detalhado e estendido para os três perfis RASI, sendo uma contribuição deste trabalho.

2.2 Trabalhos Correlatos

Nesta seção é realizada uma resenha a respeito dos trabalhos correlatos. Tais trabalhos abordam aspectos intrínsecos ao uso de planejamento automatizado no contexto educacional. Sendo assim, é apresentada uma revisão de trabalhos que recorrem a *PDDL* para implementar o planejamento, bem como trabalhos que abordam tal categoria de problema a partir de algoritmos bio-inspirados. A intenção dessa revisão é identificar vantagens e desvantagens entre tais métodos de modo a subsidiar o desenvolvimento deste trabalho.

A Tabela 4 resume nove trabalhos que implementam o PA por meio do *PDDL*. Nessa tabela são consideradas questões como o tipo de planejamento utilizado, a modelagem do estudante e as ações pedagógicas adotadas.

O PA baseado em regras de associação foi utilizado em três trabalhos mostrados na Tabela 4. Em Caputi e Garrido (2015), esta técnica foi utilizada com a intenção de selecionar a sequência de atividades de aprendizado mais adequada e na ordem correta para cada estudante, com base em seu perfil, a partir de um conjunto definido pelo professor. No trabalho apresentado em Marinov e Valova (2016), tal técnica de PA se demonstrou eficiente ao propiciar a implementação automatizada de uma estratégia de ensino global, porém individualizada, conforme as informações de cada aluno. Já em Garrido e Onaindia (2013) o foco da utilização desta técnica de PA foi ofertar ao estudante o conteúdo adequado e no momento certo. Para isto, foi necessário o enriquecimento de metadados de OAs, de modo a disponibilizar informações importantes ao planejador automatizado utilizado.

Tabela 4 – Trabalhos que utilizam Planejamento Automatizado no contexto educacional.

Trabalho	Características do Estudante	Tipo de Planejamento	Intervenção Pedagógica
Garrido e Onaindia (2013)	Metadados de AVA; Estilo de aprendizagem (Felder-Silverman); Preferências.	Regras de associação; Lógica temporal.	Geração de rota de aprendizagem personalizada para oferecer cursos personalizados.
Garrido e Morales (2014)	Metadados de AVA; Estilo de Aprendizagem (Felder-Silverman).	Baseado em casos.	Geração de rota de aprendizagem personalizada, por meio do sequenciamento de OA.
Limongelli e Sciarrone (2014)	Estado cognitivo (Taxonomia de Bloom); Estilo de aprendizagem (Felder-Silverman).	Hierárquico; Lógica Temporal Linear.	Geração de avaliações personalizadas, por meio da oferta de hipermedia adaptativa.
Caputi e Garrido (2015)	Metadados de AVA; Estilo de aprendizagem (Felder-Silverman).	Regras de associação.	Criação de rota de aprendizagem personalizada, por meio do sequenciamento de OA.
Torres e Guzmán-Luna (2015)	Estilo de aprendizagem (Honey-Alonso).	Reativo.	Oferta de rotas de aprendizagem adaptadas ao perfil do estudante, por meio da seleção OA.
Garrido, Morales e Serina (2016)	Metadados de AVA; Estilo de Aprendizagem (Felder-Silverman); Preferências.	Baseado em casos.	Geração de rota de aprendizagem personalizada por meio de uma sequência de OA.
Marinov e Valova (2016)	Análise do conhecimento do estudante sobre o conteúdo.	Regras de associação.	Personalização de cursos, por meio da oferta de exercícios baseados no perfil do estudante.
Sanchez Nigenda et al. (2017)	Não discutido.	Hierárquico.	Geração de rota de aprendizagem personalizada, por meio da composição de OA.
Pireva e Kefalas (2018)	Metadados de AVA; Estilo de aprendizagem (Felder-Silverman); Taxonomia de Bloom; Preferências.	Hierárquico.	Geração de rota de aprendizagem personalizada, por meio do sequenciamento de OA.

O planejamento baseado em casos foi utilizado em Garrido e Morales (2014) para personalizar os caminhos de aprendizagem, ou seja, a ordem onde os OAs são ofertados ao estudante, além de executar e monitorar seu progresso, de modo a readaptá-los quando necessário. Como uma das vantagens desta técnica de planejamento, o trabalho aponta ainda que a partir dos caminhos de aprendizagem mapeados numa base de dados, previamente planejados, é possível reutilizá-los para outros estudantes com perfis semelhantes, aumentando assim, a eficiência do sistema proposto.

Dois trabalhos exibidos na Tabela 4 exploraram a utilização do planejamento hierárquico em ambiente de *e-learning*. Em Pireva e Kefalas (2018) esta técnica foi utilizada no contexto de *cloud e-learning*, com o intuito de definir uma sequência de OAs correspondentes ao conhecimento prévio de um aprendiz e ao seu objetivo. No trabalho proposto em Limongelli e Sciarrone (2014), o planejamento hierárquico foi utilizado para auxiliar o estudante durante uma atividade de aprendizagem, por meio do conhecimento prévio de seu estado cognitivo, de seu estilo de aprendizagem e da estratégia didática do professor, para

isto, o sistema proposto associa o planejamento a procedimentos de refinamento de estilos de aprendizagem do estudante. O *space-state planning* é utilizado em Sanchez Nigenda et al. (2017), pois se torna adequado para a representação de currículos de aprendizagem. Além disso, com a finalidade de relaxar as restrições totais de ordenação dos caminhos de aprendizagem, utilizou-se a programação matemática, desse modo, tornou-se possível a computação eficiente das soluções ideais para os modelos de planejamento iniciais.

Na Tabela 4, é possível observar os elementos utilizados para modelar o perfil cognitivo do estudante. Nos trabalhos apresentados por Garrido e Onaindia (2013), Garrido e Morales (2014), Limongelli e Sciarrone (2014), Garrido, Morales e Serina (2016), Pireva e Kefalas (2018) o perfil do estudante foi definido com base nos estilos de aprendizagem proposto em Felder e Silverman (1988) em conjunto com outras características, como, por exemplo: associado aos desejos e necessidades do estudante; em conjunto com os requisitos do curso, impostos por meio das inter-relações entre objetos de aprendizagem; ou ainda associados à Taxonomia de Bloom Revisada Krathwohl (2002), com a finalidade de disponibilizar ao estudante uma rota de aprendizagem otimizada como recurso ou de tempo.

Ainda sobre os trabalhos mostrados na Tabela 4, em Torres e Guzmán-Luna (2015) os estilos de aprendizagem são explorados por meio do inventário de Honey-Alonso, proposto em Alonso, Gallego e Honey (1999), para identificar a melhor composição de objetos de aprendizagem, de modo a otimizar a rota de aprendizagem do estudante. Em Marinov e Valova (2016) o perfil do estudante é definido por meio da identificação do conhecimento do estudante acerca do conteúdo a ser abordado, com o intuito de lhe prover problemas de acordo com suas habilidades e preferências. Diante desses trabalhos, observa-se a necessidade de maior exploração de técnicas que melhor refinem o modelo do estudante. Tal refinamento pode gerar impactos positivos na utilização da técnica de Planejamento Automatizado para recomendação de ações pedagógicas ao estudante, visto que o conhecimento acerca do mundo em que o planejador atuará é essencial na otimização de sua atuação.

Diante do exposto, observa-se uma variedade de técnicas de Planejamento Automatizado usando *PDDL* aplicadas em ambiente de *e-learning* para automatizar a personalização de uma ou mais etapas do processo pedagógico. Nota-se ainda que a utilização de características adequadas do estudante é de suma importância para a utilização efetiva do Planejamento Automatizado. Entretanto, esses trabalhos esbarram no fato de que à medida que as características do estudante são refinadas, as heurísticas tendem a não ser efetivas no espaço de busca (ARIYARATNE; FERNANDO, 2014).

Outra questão relevante diz respeito às ações pedagógicas adotadas nos trabalhos propostos. Geralmente estas baseiam-se em conteúdos específicos, por meio do sequenciamento de OAs. Tal estratégia apresenta vantagens do ponto de vista da simplificação das ações pedagógicas recomendadas, entretanto, não permite explorar o processo pedagógico

em si, pois geralmente privilegia a recomendação de conteúdo. Portanto, a proposição de alternativas cujo foco da recomendação seja o processo cognitivo do estudante, apresenta-se como um desafio que pode contribuir para o avanço na área de IE.

O uso de algoritmos bio-inspirados para realização do planejamento automatizado é observado em diversos contextos. Em Jourdan e Weck (2004), a partir da visão de um problema de otimização multi-objetivo, o Planejamento Automatizado é realizado por meio do AG, para auxiliar na identificação do posicionamento ideal de nós para uma rede de sensores. No trabalho relatado em Wruk et al. (2019), essa técnica também foi implementada por meio de AG para a otimização de redes de distribuição de energia elétrica, de modo a encontrar o plano de reforço mais adequado. Conforme apresentado na Tabela 5, algoritmos bio-inspirados também são utilizados para a implementação do Planejamento Automatizado no contexto educacional. Nesses trabalhos, o sequenciamento curricular, ou a personalização de rotas de aprendizagem estão entre os principais objetivos do planejador.

A modelagem do estudante foi abordada de distintas maneiras nos trabalhos apresentados na Tabela 5. Os estilos de aprendizagem como parte ou componente principal desse parâmetro são explorados nos trabalhos apresentados em Kurilovas, Zilinskiene e Dagiene (2014), Rastegarmoghadam e Ziarati (2017), Dwivedi, Kant e Bharadwaj (2018), Machado, Barrére e Souza (2018). Além disso, as preferências também compõem a modelagem do estudante em Li et al. (2017), Miranda et al. (2019). O nível de conhecimento como premissa para recomendação pedagógica é abordado em Dwivedi, Kant e Bharadwaj (2018), Agbonifo e Olanrewaju (2018), Hssina e Erritali (2019), Miranda et al. (2019). Já em Vanitha, Krishnan e Elakkiya (2019), observa-se que aspectos como objetivos de aprendizagem, estado emocional, habilidade cognitiva e desempenho do estudante foram utilizados na modelagem do estudante.

Dentre as abordagens observadas nos trabalhos da Tabela 5, o Algoritmo de Otimização de Colônia de Formigas foi explorado em Kurilovas, Zilinskiene e Dagiene (2014), Rastegarmoghadam e Ziarati (2017), Vanitha, Krishnan e Elakkiya (2019). Já o Algoritmo Genético é explorado na maioria dos trabalhos, conforme observado em Shmelev, Karpova e Dukhanov (2015), Lin, Chang e Chu (2016), Dwivedi, Kant e Bharadwaj (2018), Agbonifo e Olanrewaju (2018), Goyal e Rajalakshmi (2018), Hssina e Erritali (2019), Miranda et al. (2019), Vanitha, Krishnan e Elakkiya (2019). Além dessas técnicas, o Algoritmo Presa-Predador é abordado em Machado, Barrére e Souza (2018).

Nos trabalhos mostrados na Tabela 5, a abordagem evolutiva é utilizada sob a perspectiva de problemas de otimização em recomendações pedagógicas. A busca pelo caminho de aprendizagem ideal, conforme o perfil do estudante, é observada em Kurilovas, Zilinskiene e Dagiene (2014), Rastegarmoghadam e Ziarati (2017), Hssina e Erritali (2019), Vanitha, Krishnan e Elakkiya (2019). No trabalho proposto por Shmelev, Karpova e Dukhanov (2015), foram sequenciados OAs usando uma ontologia de domínio e a TB, de

Tabela 5 – Planejamento Automatizado utilizando computação evolutiva.

Trabalho	Características do Estudante	Abordagem Bio-inspirada	Problema de Otimização
Kurilovas, Kubilinskiene e Dagiene (2014)	Estilo de aprendizagem.	* Otimização mono-objetivo. * Inteligência de Enxame.	Rota de aprendizagem.
Shmelev, Karpova e Dukhanov (2015)	não há.	* Otimização mono-objetivo. * Algoritmo Genético).	Rota de aprendizagem.
Lin, Chang e Chu (2016)	Preferências.	* Otimização multi objetivo. * Algoritmo Genético (<i>TOP-SIS</i>).	Desempenho do estudante; Tempo.
Rastegarmoghadam e Ziarati (2017)	Estilo de aprendizagem.	* Otimização mono-objetivo. * Inteligência de Enxame.	Rota de aprendizagem.
Dwivedi, Kant e Bharadwaj (2018)	Estilo de aprendizagem; Nível de conhecimento.	* Otimização mono-objetivo. * Algoritmo Genético de Tamanho Variável.	Sequenciamento curricular.
Agbonifo e Olanrewaju (2018)	Nível de conhecimento.	* Otimização mono-objetivo. * Algoritmo Genético.	Sequenciamento curricular.
Goyal e Rajalakshmi (2018)	Não há.	* Otimização mono-objetivo. * Algoritmo Genético.	Conjunto de atividades.
Machado, Barrére e Souza (2018)	Estilo de aprendizagem.	* Inteligência de Enxame.	Tempo; Balanceamento de conceitos.
Hssina e Erritali (2019)	Nível de conhecimento.	* Otimização mono-objetivo. * Algoritmo Genético.	Rota de aprendizagem.
Miranda et al. (2019)	Preferências; Nível de conhecimento.	* Otimização multi-objetivo. * Algoritmo Genético Multi-Objetivo.	Satisfação do estudante; Redução e nivelamento de tempo.
Vanitha, Krishnan e Elakkiya (2019)	Objetivos de aprendizagem; Emoção; Cognição; Desempenho.	* Otimização mono-objetivo. * Inteligência de Enxame; Algoritmo Genético.	Rota de aprendizagem.
Martins et al. (2021)	Habilidade; Estilo de aprendizagem.	* Otimização multi objetivo. * Algoritmo Genético, Inteligência de Enxame; Algoritmo de Presa-predador; Evolução Diferencial.	Sequenciamento curricular.

modo a fornecer rotas de aprendizagem segundo requisitos e conhecimentos prévios. Em Lin, Chang e Chu (2016) o desempenho do estudante e o tempo de aprendizagem são foco do processo de otimização. Já nos trabalhos Dwivedi, Kant e Bharadwaj (2018), Agbonifo e Olanrewaju (2018), Martins et al. (2021) o sequenciamento curricular é o objetivo das propostas. Em Goyal e Rajalakshmi (2018), a personalização do nível de dificuldade de atividades avaliativas, conforme a hierarquia da TB, é o propósito desse trabalho. Já em Miranda et al. (2019), critérios como satisfação de membros de um grupo e minimização do tempo e equalização no tempo de trabalho entre os participantes de um grupo são objetivos da otimização.

Recomendações pedagógicas podem ser interpretadas como problemas de otimização. Sob essa ótica, é viável a utilização de algoritmos bio-inspirados na busca de soluções

para este tipo de problema, conforme observado em Hssina e Erritali (2019), Martins et al. (2021). A grande disponibilidade de dados justifica o uso dessa estratégia, pois a manipulação desses através de outras técnicas, como o PA via *PDDL* por exemplo, exigiriam alto esforço computacional, inviabilizando, portanto, tal aplicação, de acordo com Ariyaratne e Fernando (2014).

Em Lin, Chang e Chu (2016), o uso de AG é empregado com o intuito de planejar um mapa de aprendizado. Nesse trabalho é possível atingir uma meta de aprendizado por diferentes caminhos através de materiais alternativos. Assim, consoante as características do estudante, objetivou-se selecionar o melhor caminho, ou seja, a melhor sequência de materiais para o estudante. O AG utilizado em Lin, Chang e Chu (2016) foi aprimorado por meio da *Technique for Order Preference by Similarity to Ideal Solution (TOPSIS)*, de modo a otimizar a busca pela solução quase ótima. Nesse trabalho, as recomendações pedagógicas são realizadas por meio da seleção de OAs considerando os estilos de aprendizagem do estudante, de modo a gerar um mapa de aprendizagem personalizado. Nota-se que tal proposta pode levar mais tempo na execução da busca pela solução, porém esta é mais confiável e de maior qualidade.

No trabalho proposto por Hssina e Erritali (2019), é apresentada uma abordagem baseada no problema da adaptação como um problema de otimização, em que é utilizado AG para gerar caminhos de aprendizagem adaptados aos perfis dos estudantes. Para isso, o perfil do estudante é determinado pelos resultados obtidos em avaliações e as recomendações pedagógicas são construídas por meio do sequenciamento de OAs adequados aos objetivos pedagógicos determinados pelo professor. O AG também é utilizado na abordagem apresentada em İnce, Yiğit e Işık (2019). Nesse trabalho, é realizada a seleção e recomendação de OAs disponíveis em repositórios, por meio da utilização de AG. Segundo esse autor, tal problema se torna um problema de decisão multi cenário, já que utiliza metadados de modo a melhor personalizar as recomendações. Ainda nesse trabalho, a modelagem do estudante é composta por preferências, extraídas a partir dos metadados do sistema.

O algoritmo de otimização de colônia de formigas é explorado com a intenção de realizar recomendações pedagógicas personalizadas em Kurilovas, Zilinskiene e Dagiene (2014) e Rastegarmoghadam e Ziarati (2017). Em ambos os trabalhos, esse algoritmo é utilizado para recomendação de rotas de aprendizagem personalizadas por meio da seleção de objetos de aprendizagem adequados ao modelo do estudante. Em Kurilovas, Zilinskiene e Dagiene (2014), o modelo do estudante é baseado em estilos de aprendizagem, já em Rastegarmoghadam e Ziarati (2017), o modelo do estudante utiliza, além de estilos de aprendizagem, a resolução de problemas.

No estudo relatado em Martins et al. (2021), o objetivo foi estimular a satisfação do estudante através do sequenciamento curricular adaptativo, considerando as características do estudante. Nesse trabalho, observou-se a viabilidade de utilização de técnicas

bio-inspiradas, visto que o problema de sequenciamento curricular é NP-difícil. Para tal, foram utilizados algoritmos como otimização de enxame de partículas, algoritmo genético e evolução diferencial em um conjunto de dados artificiais.

Nos estudos citados na Tabela 5, observa-se que o processo de otimização está relacionado a aspectos vinculados ao currículo, como OAs ou restrições de atividades e requisitos de conteúdo. Além disso, nota-se que é possível abordar o problema de sequenciamento pedagógico como um problema de otimização, sob a ótica do Planejamento Automatizado. Dentre esses trabalhos, a técnica de otimização via AG apresenta-se interessante, pois é explorada num conjunto maior de características do estudante. De maneira geral, em comparação às técnicas dos trabalhos utilizados na Tabela 4, os trabalhos listados na Tabela 5 não priorizam a utilização de heurísticas para reduzir o espaço de busca, visto que técnicas bio-inspiradas podem apresentar bons resultados em espaços de busca de tamanho significativo.

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 Taxonomia de Bloom. 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 encadear tal sequenciamento. 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.

Diante do cenário exposto, a proposição de um modelo capaz de identificar o perfil cognitivo do estudante visando sequenciar ações pedagógicas que o auxiliem no processo de aprendizagem, apresenta-se viável. Para tanto, faz-se adequado o seguinte modelo: i) identificação de características relacionadas às estratégias utilizadas pelo estudante no processo de aprendizagem, conforme propostas pelo RASI; ii) a utilização de uma estrutura referente ao processo cognitivo, em que é possível conduzir o estudante no desenvolvimento de suas habilidades cognitivas, conforme apresentadas pela Taxonomia de Bloom; iii) seleção de atividades digitais adequadas ao estudante, dadas pela Taxonomia de Bloom Digital.

Planejador de Ações Pedagógicas por Algoritmo Genético Multiobjetivo

Neste capítulo, é apresentado o modelo proposto para um planejador de ações pedagógicas usando AG multiobjetivo. Inicialmente estendeu-se o mapeamento entre a Taxonomia de Bloom e o perfil RASI, com o intuito de obter sequências de ações que se aproximem do perfil RASI do estudante. Em seguida, propõe-se o sequenciamento das ações realizado por um AG. Inicialmente, esse AG considerou apenas a proximidade da sequência ao perfil RASI do estudante como função objetivo. Posteriormente, com o intuito de melhor adequar a sequência de ações ao perfil do estudante, foi implementado um AG multiobjetivo, acrescentando a função objetivo que visa adequar o tamanho da sequência de ações ao perfil do estudante. Foram realizados experimentos com ambas as abordagens.

Assim, na Seção 3.1 é apresentado o mapeamento (TB x RASI). Na Seção 3.2 descreve-se duas versões do AG utilizadas e finalmente, na Seção 3.3 é descrita a arquitetura que integra as propostas de mapeamento, de sequenciamento de ações pedagógicas e de recomendação de atividades digitais. Com isso, o objetivo do modelo proposto para recomendações pedagógicas é oferecer uma alternativa que foque o sequenciamento no processo de construção do conhecimento do estudante, tornando-o mais flexível em relação à estrutura definida por um currículo ou requisitos de conteúdo.

3.1 Relacionamento entre Taxonomia de Bloom e *RASI*

Na discussão conduzida no Capítulo 2, observamos haver uma tendência do sequenciamento pedagógico personalizado se basear em estruturas curriculares ou objetos de aprendizagem, tornando tais abordagens dependentes de um domínio de conhecimento específico. Ao propor o sequenciamento independente no domínio, 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 é viável, a partir da composição das teorias desenvolvidas na TB e no RASI, dado que

ambas tratam o estado cognitivo do estudante partindo de LOCS para HOCS.

3.1.1 Sequências de Ações Pedagógicas

Conforme observado no trabalho de Krathwohl (2002), a TB fornece ações pedagógicas (objetivos educacionais) para a realização do processo de aprendizagem visto que essas ações estão associadas a alguma posição de um arcabouço bidimensional composto pela Dimensão do Processo Cognitivo (DPC) e pela Dimensão do Conhecimento (DC). A partir disso, neste trabalho, propomos a utilização bidimensional da TB, criando uma ação para cada objetivo educacional conforme a matriz apresentada na Figura 1. Na estrutura utilizada, a DPC é dividida em seis categorias (ou estados cognitivos), a saber: *Lembrar*, *Entender*, *Aplicar*, *Analisar*, *Avaliar* e *Criar*. DC é dividida em quatro categorias (*Factual*, *Conceitual*, *Procedimental* e *Metacognitivo*), de acordo com uma hierarquia de LOCS para HOCS.




Figura 1 – Ações pedagógicas baseadas na Taxonomia de Bloom.

Na Figura 1, existem 24 posições, cada uma associada a uma ação pedagógica. O uso geral desse referencial implica atribuir cada objetivo educacional da Taxonomia de Bloom às posições que indicam quais são as ações mais adequadas para atingir esse objetivo. O uso mais frequente desse arcabouço é o manual, o que é difícil e lento. Embora exista uma hierarquia subjacente em cada dimensão, é desejável que as ações mais próximas de LOCS (ações concretas) sejam sequenciadas antes das ações mais próximas de HOCS (ações abstratas). Conforme a Figura 1, a *Ação 1* é a mais concreta e a *Ação 24* a mais abstrata. As ações intermediárias seguem uma ordem crescente de habilidades cognitivas (LOCS para HOCS) exigidas ao estudante. Segundo Krathwohl (2002), as posições (ações) podem ser suprimidas segundo as necessidades do estudante. Em outras palavras, não é

necessário passar por cada nível, um a um. Isso leva a muitas combinações de ações e, conseqüentemente, a um número significativo (2^{24}) de sequências possíveis.

Como dito anteriormente, a cada uma dessas ações (posições) devem estar associadas atividades digitais. Churches (2010) fez um mapeamento de atividades digitais para TB de uma dimensão. Estendemos esse mapeamento para a TB bidimensional, conforme visto na Figura 2, com isso, cada atividade digital considera as dimensões do processo cognitivo e também do conhecimento. Para tal, as atividades digitais foram classificadas das mais concretas às mais abstratas e atribuindo-as a uma das quatro categorias da Dimensão do Conhecimento conforme essa ordem de classificação.



Figura 2 – Mapeamento das atividades digitais (TBD) para a duas dimensões da Taxonomia de Bloom.

O mapeamento estendido mostrado na Figura 2 é uma contribuição deste estudo, pois permite o uso da Taxonomia de Bloom (bidimensional) em ambientes virtuais de aprendizagem. Além disso, uma aplicação prática da abordagem de sequenciamento desenvolvida

neste estudo torna-se viável por meio da recomendação de atividades digitais. Na próxima subseção, é apresentada a relação entre a TB, e o perfil RASI.

3.1.2 Mapeamento: Taxonomia de Bloom x RASI

A Taxonomia de Bloom, assim como o RASI, descrevem o processo cognitivo do estudante de LOCS a HOCS. Em outras palavras, o progresso do estudante é desenvolvido de habilidades concretas para abstratas. Devido a essa interseção teórica, alguns estudos têm procurado compreender e evidenciar tal relação. Brown et al. (2015) apontaram a convergência entre essas teorias, identificando o estado cognitivo do estudante e possíveis ações pedagógicas considerando o eixo *Surface* do RASI. Shang (2019) estabeleceu uma relação entre as subescalas RASI para o eixo *Deep* e os níveis da Dimensão do Processo Cognitivo na Taxonomia de Bloom.

Inspirados nas pesquisas supracitadas, Costa e Fernandes (2021a) determinaram 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 Dimensão do Processo Cognitivo. As 52 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. Na Figura 3, o resultado é a taxa de compatibilidade de cada categoria da Dimensão do Processo Cognitivo para cada eixo RASI. A Figura 3 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. Cada uma das questões do RASI foi classificada segundo tais parâmetros e o resultado detalhado é apresentado no Apêndice B.




Figura 3 – Taxa de compatibilidade entre perfis (RASI) e estados cognitivos (TB).

Na Figura 3, cada barra representa um eixo RASI e as cores representam as categorias da Dimensão do Processo Cognitivo. Analisando esse gráfico, *Lembrar* é predominante para *Surface*, *Avaliar* e *Analisar* são as categorias mais relevantes para *Strategic* e *Deep*, entretanto, no *Deep*, a relevância de *Criar* é maior que para o *Surface* e *Strategic*. Esse mapeamento proposto usa uma metodologia diferente das estratégias apresentadas em Brown et al. (2015) e Shang (2019). No entanto, a semelhança entre esses três mapeamentos para o eixo *Deep* foi de 58,3%, mostrando alguma correlação entre a estratégia adotada por Costa e Fernandes (2021a) e Shang (2019). Como em Shang (2019) foi realizada a associação de sub-escalas do eixo *Deep* compatíveis com os níveis da Taxonomia de Bloom, tal comparação foi realizada observando a quantidade de questões pertencentes a cada sub-escada do eixo RASI.

De acordo com este mapeamento e com a modelagem da Taxonomia de Bloom como sequências de ações, é possível determinar sequências de ações relacionadas ao perfil RASI do estudante.

3.2 Sequenciamento usando Algoritmo Genético

A hierarquia da Taxonomia de Bloom pode ser ajustada conforme os objetivos de aprendizagem. Na estrutura proposta na Figura 1, são 24 ações pedagógicas possíveis e 2^{24} sequências de ações distintas. Além disso, conforme discutido no Capítulo 2, algoritmos evolutivos, como os Algoritmos Genéticos, são adequados para pesquisa em um grande espaço de busca. Assim, este trabalho propõe um Algoritmo Genético (AG) para encontrar a sequência adequada de ações da Taxonomia de Bloom para o perfil RASI do estudante.

A especificação do AG consiste em: representação do indivíduo; uma ou mais funções objetivo (critérios de otimização); e nos operadores genéticos. A definição dos critérios de avaliação de cada sequência durante o processo de busca depende dos aspectos pedagógicos relativos ao sequenciamento. Nesse sentido, tal critério é uma contribuição desta pesquisa, pois é uma proposta de análise e avaliação de uma combinação específica de características pedagógicas.

Na implementação de um AG, um indivíduo é uma solução do problema e no nosso contexto, uma solução é uma sequência de ações. Nesta proposta, um indivíduo é um vetor binário composto por 24 bits, onde cada bit representa uma ação pedagógica, e esta possui uma atividade digita correspondente, conforme ilustrado na Figura 4.

No indivíduo binário exemplificado na Figura 4a, 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, conforme ilustrado na Figura 4b. Note que da esquerda para direita, cada ação apresenta uma variação crescente de habilidades cognitivas (LOCS - HOCS), conforme mostrado na Figura 1. Na Figura 4c, são exibidas as atividades



Figura 4 – Representação do indivíduo binário no AG.

digitais mapeadas na Figura 2 para cada ação da Taxonomia de Bloom e sua ordem de apresentação ao estudante.

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 ($P_{\text{cognitive_state}}$) e os índices do eixo RASI ($D_{\text{categoria}}$) na Figura 3, onde ($P_{\text{cognitive_state}}$) é o produto do número de bits definido como 1 no estado cognitivo e 0,25.

Usaremos como exemplo o indivíduo dado na Figura 4 em que os bits 1 correspondem às posições do vetor: 0, 1, 3, 4, 5, 6, 7, 14, 16, 17, 18, 19, 21, 23. O primeiro estado cognitivo (*Lembrar*) apresenta 3 bits (0, 1 e 3) definidos para 1, o segundo apresenta 4

(4, 5, 6, 7) e assim por diante. Do primeiro ao sexto estado, o número de bits definido como 1 são 3, 4, 0, 1, 4 e 2, respectivamente, então os pesos dos estados cognitivos são 0.75, 1.0, 0, 0.25, 1.0 e 0.5.

Conforme a Figura 3, os índices de compatibilidade entre os perfis RASI para cada estado cognitivo da Taxonomia de Bloom (*Compreender*, ..., *Criar*) são:

$$\square \textit{Surface} = [0.625, 0.125, 0, 0.125, 0 \text{ e } 0.125]$$

$$\square \textit{Strategic} = [0.0625, 0.125, 0.1875, 0.25, 0.3125, 0.0625]$$

$$\square \textit{Deep} = [0.05, 0.15, 0, 0.35, 0.3, 0.15]$$

Portanto, a correspondência da sequência em relação cada perfil RASI — *Surface* (*su*), *Strategic* (*st*) e *Deep* (*de*) — para o indivíduo no AG é calculada conforme apresentado na Tabela 6. Note que aqui são utilizadas as taxas definidas na Figura 3.

Tabela 6 – Cálculo dos índices RASI para uma sequência de ações.

E	lembrar		compreender				aplicar						
	ic	ps	ic	ps	ic	ps	ic	ps	ic	ps	ic	ps	
su	0.625	x	0.75	+	0.125	x	1.0	+	0	x	0	+	...
st	0.0625	x	0.75	+	0.125	x	1.0	+	0.1875	x	0	+	...
de	0.05	x	0.75	+	0.15	x	1.0	+	0	x	0	+	...

E	analisar		avaliar				criar		<i>I</i>					
	ic	ps	ic	ps	ic	ps	ic	ps						
su	...	+	0.125	x	0.25	+	0	x	1	+	0.125	x	0.5	= 0.6875
st	...	+	0.25	x	0.25	+	0.313	x	1	+	0.0625	x	0.5	= 0.578125
de	...	+	0.35	x	0.25	+	0.3	x	1	+	0.15	x	0.5	= 0.65

Legenda: **E**. Eixo RASI; ***I***. Índice RASI do indivíduo; **ic**. índice RASI referente ao mapeamento para a TB; **ps**. Peso associado à cada estado cognitivo da TB.

Assim, os índices RASI do indivíduo no exemplo são: $I = (su = 0.6875; st = 0,578125; de = 0.65)$.

Agora, assumiremos que um perfil RASI hipotético de um estudante é dado por $S = (su = 0.34375; st = 0.5; de = 0.65)$, então a função objetivo (*fitness*) FO_1 é dada pela Eq. 7, 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 $pnlt(I, S)$ é uma penalidade.

$$FO_1(I) = dist(I, S) + pnlt(I, S) \quad (7)$$

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. 8.

$$dist(I, S) = \sqrt{(su(I) - su(S))^2 + (st(I) - st(S))^2 + (de(I) - de(S))^2} \quad (8)$$

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, conforme exemplo mostrado na Tabela 7.

Tabela 7 – Exemplo da ordem de relevância dos índices RASI.

	Índices <i>RASI</i>			Ordem de relevância				
	su	st	de	Peso 3	Peso 2	Peso 1		
Indivíduo (<i>I</i>)	0.6875	0.578128	0.65	<i>su</i>	>	<i>de</i>	>	<i>st</i>
				≠		≠		≠
Estudante (<i>S</i>)	0.34375	0.5	0.65	<i>de</i>	>	<i>st</i>	>	<i>su</i>

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. 9.

$$pnlt(I, S) = dist(I, S) / 6 \times P_1 + dist(I, S) / 6 \times P_2 + dist(I, S) / 6 \times P_3 \quad (9)$$

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.

Considerando o exemplo da Tabela 7, a penalidade é calculada considerando P_1 , P_2 e P_3 , visto que a ordem de relevância para todos os índices é divergente. Então temos:

$$\square pnlt(I, S) = dist(I, S) / 6 + dist(I, E) / 6 \times 2 + dist(I, E) / 6 \times 3$$

Com isso, os exemplos de cálculos para $dist(I, S)$, $pnlt(I, S)$ e $FO_1(I)$ são:

$$\square dist(I, S) = \sqrt{(0.6875 - 0.34375)^2 + (0.578128 - 0.5)^2 + (0.65 - 0.65)^2} = 0.352516$$

$$\square pnlt(I, S) = 0.352516/6 + 0.352516/6 \times 2 + 0.352516/6 \times 3 = 0.352516$$

$$\square FO_1(I) = dist(I, S) + pnlt(I, S) = 0.705302$$

A penalidade para o exemplo da Tabela 7 considera os pesos 3, 2 e 1 visto que a ordem de relevância para todos os eixos é divergente, onde $dist(I, S) = 0,352526$. Então $FO_1(I) = 0,705032$.

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. 7. Na segunda etapa foi implementado um AG multiobjetivo,

acrescentando uma segunda função objetivo (FO_2) ao AG previamente desenvolvido, conforme apresentado na Eq. 10:

$$FO_2(I) = \begin{cases} \frac{ref-tamanho(I)}{ref-1} & , \text{ se } tamanho(I) > ref \\ \frac{tamanho(I)-ref}{24-ref} & , \text{ caso contrário} \end{cases} \quad (10)$$

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 e Fernandes (2021a). Esse estudo diz respeito ao sequenciamento de ações pedagógicas baseadas na Taxonomia de Bloom utilizando o AG mono-objetivo e a função $FO_1(I)$ descrita na Eq. 7. Com base nos resultados desse trabalho, foram realizados novos experimentos cujo foco foi a recomendação de atividades digitais baseadas na Taxonomia de Bloom Digital, conforme listadas na Figura 2 e exemplificado na Figura 4c. Nesse estudo, 24 estudantes receberam uma lista de atividades baseadas no sequenciamento de ações pedagógicas e elegeram as atividades que não gostariam de cumprir. 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 $Deep = 11$.

Ainda no AG multi objetivo, a otimização (minimização) foi realizada por meio da soma ponderada, atribuindo os pesos 0.7 para FO_1 e 0.3 para FO_2 . Tais valores foram definidos após a realização de testes exploratórios para identificar qual o melhor arranjo entre essas funções. Essa relação corrobora ainda a importância maior que FO_1 representa para a busca da solução adequada ao perfil do estudante, dado que esta representa a compatibilidade considerando o perfil RASI do estudante. Por outro lado, FO_2 denota um grau de satisfação do estudante em relação à quantidade de atividades recebidas, ou seja, ao tamanho da sequência de ações. Por fim, apresentamos um exemplo de uma sequência de atividades recomendadas, conforme exemplo dado na Figura 4c.

1. T1 - Buscar conceitos básicos na Web ou redes sociais.
2. T2 - Ler *e-book*.
3. T4 - Postar conteúdo estudado em *blogs* ou redes sociais.
4. T5 - Realizar busca avançada na Web ou em bases específicas.
5. T6 - Resumir ou destacar trechos em documento digital.
6. T7 - Esquematizar de ideias, usando *Prezi*, *Power Point*, etc.
7. T8 - Realizar gravação de vídeo ou áudio sobre o conteúdo.
8. T15 - Redigir relatórios com gráficos e/ou planilhas.

9. T17 - Participar de discussões, usando ferramentas na Web.
10. T18 - Interagir com rede de contatos, usando ferramentas Web.
11. T19 - Revisar atividades realizadas em grupo usando ferramentas Web.
12. T20 - Avaliar conteúdo ou moderar publicações e comentários de redes sociais.
13. T22 - Publicar conteúdo na Web.
14. T24 - Criar mídia digital, como, por exemplo, jogo, vídeo, áudio ou imagem.

Conforme modelo proposto, a eleição das atividades digitais que comporão a recomendação pedagógica para o estudante é realizada segundo as ações sequenciadas para o estudante, seja pelo AG mono-objetivo, ou pelo AG multi objetivo. A diferença principal entre às duas técnicas utilizadas é a quantidade ações, em média, recomendada ao estudante. Na primeira, a quantidade média é de cerca de 15 atividades por estudante, na segunda é em torno de 11 atividades.

Um fluxograma para o AG proposto é definido na Figura 5. Utilizamos em sua implementação os parâmetros definidos em Engelbrecht Andries (2007) com a seguinte estrutura: Geração da população inicial (1); Avaliação de aptidão (2) Verificação dos critérios de parada (3); iv) Se a verificação no passo (3) obtiver resposta positiva, a solução é retornada e a execução do algoritmo é interrompida; caso contrário são realizados os passos seleção (4), *crossover* (5), mutação (6) e a execução do algoritmo retorna ao passo 2.




Figura 5 – Fluxograma do Algoritmo Genético.

Após a realização de testes afim de identificar os valores dos parâmetros que que melhor se ajustam ao AG, concluiu-se que os melhores resultados são obtidos utilizando os valores descritos a seguir. No passo (1) do AG, a população inicial tem tamanho de $MAX_I = 1000$ indivíduos. No passo (2) é realizada a avaliação da(s) função(ões) de aptidão, no caso do AG mono-objetivo, a função é dada pela Eq. 7 (FO_1). No caso do AG multiobjetivo utiliza também a Eq. 10 (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 no passo (4). 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* no passo (5) 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.

3.3 Visão Geral da Arquitetura

A presente proposta visa sequenciar ações pedagógicas através do planejamento automatizado usando algoritmo genético multi objetivo, de modo a possibilitar a recomendação de atividades digitais com base nesse sequenciamento. Tanto as ações pedagógicas quanto

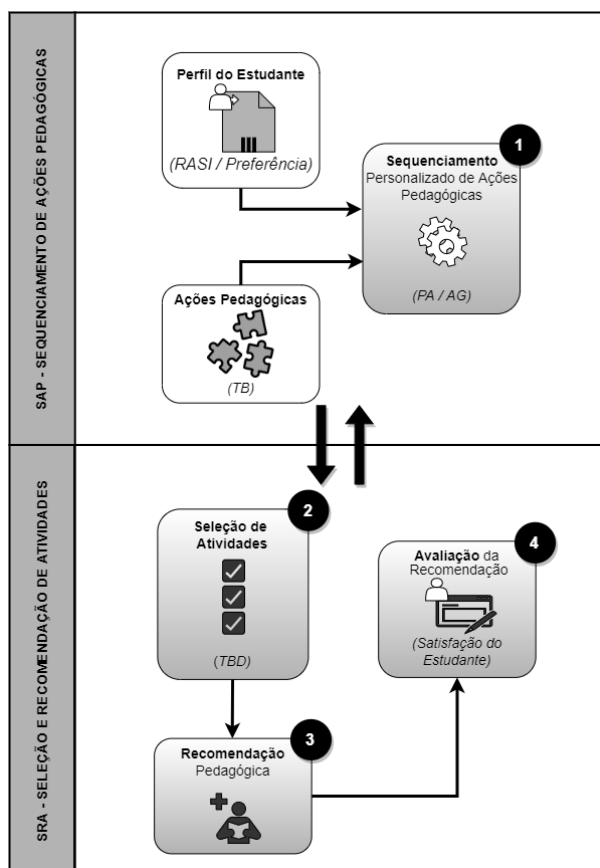


Figura 6 – Modelo de recomendação para ações pedagógicas.

as atividades digitais são baseadas na Taxonomia de Bloom. A personalização do sequen-

ciamento é realizado com base perfil RASI do estudante e numa medida de satisfação em relação à quantidade média de atividades preferida pelo estudante. Na Figura 6 é apresentada uma visão geral da arquitetura proposta.

Na Figura 6, a recomendação pedagógica é composta por dois módulos: Sequenciamento de Ações Pedagógicas (SAP) e Seleção e Recomendação de Atividades (SRA). O primeiro módulo é responsável pelo sequenciamento personalizado das ações pedagógicas. O segundo é responsável por selecionar as atividades, recomendá-las ao estudante, além de obter a avaliação dada pelo estudante em relação à recomendação recebida.

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, conforme exibido na Figura 2. 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.

A partir da arquitetura proposta, foram elaborados experimentos com estudantes, que consistiram em: aplicar o questionário RASI; sequenciar ações pedagógicas de forma personalizada, utilizando algoritmo genético; definir e recomendar atividades aos estudantes; e aplicar um questionário para identificar a percepção dos estudantes acerca da recomendação pedagógica recebida. Tais experimentos, bem como a discussão acerca das hipóteses e das questões de pesquisa são detalhados no Capítulo 4.

Experimentos e Análise dos Resultados

No Capítulo 3, foi apresentado o desenvolvimento da proposta para o sequenciamento automatizado de ações pedagógicas baseadas na Taxonomia de Bloom, personalizadas conforme o perfil RASI do estudante e sua preferência em relação à quantidade de atividades. Em seguida, foi realizada a seleção de atividades digitais, correspondentes às ações sequenciadas, de modo que estas pudessem ser recomendadas a um estudante. Tal proposta foi instigada a partir das questões de pesquisa definidas na Subseção 1.3.

Além disso, com o intuito de testar as hipóteses definidas na Seção 1.3, o desenvolvimento do sequenciador de ações pedagógicas ocorreu em dois estágios. No primeiro, foi realizado o sequenciamento personalizado por AG mono-objetivo utilizando como objetivo a similaridade da sequência de ações pedagógicas ao perfil RASI do estudante. No segundo, foi utilizado um AG multiobjetivo, cujo segundo objetivo acrescentado foi a quantidade de atividades adequada conforme o perfil do estudante. Em cada um dos algoritmos, os experimentos foram divididos em três etapas, visando averiguar a eficácia dos métodos propostos. São elas:

- **Etapa 1 — Perfil do estudante:** Nessa etapa foi aplicado o questionário RASI¹, traduzido livremente para o português e disponibilizado no Apêndice A, aos estudantes para formar uma base de perfis utilizados como objetivo para o sequenciamento de ações pedagógicas.
 - AG mono-objetivo: foi utilizado o questionário RASI completo (52 questões).
 - AG multiobjetivo: utilizou-se o questionário RASI na versão curta (18 questões).

- **Etapa 2 — Sequenciamento de ações e atribuição de atividades:** nessa etapa foi realizado o sequenciamento de ações pedagógicas utilizando cada método proposto, com o intuito de aproximá-las ao perfil do estudante, considerando os parâmetros propostos para os perfis coletados na Etapa 1. Além disso, nessa etapa

¹ Disponível em Entwistle e Tait (2013).

ocorreu a atribuição de atividades, conforme mapeamento realizado a partir da TBD.

- AG mono-objetivo: nesse algoritmo a otimização foi baseada na aproximação da sequência ao perfil do estudante, considerando o mapeamento proposto entre TB e RASI.
- AG multiobjetivo: nesse algoritmo, além do objetivo usado para o AG mono-objetivo, foi otimizada também a quantidade de atividades segundo o perfil do estudante.

□ **Etapa 3 — Recomendação de atividades:** nessa etapa foi recomendada a sequência de atividades digitais baseadas na TBD, conforme o sequenciamento realizado na Etapa 2.

- Em ambos os algoritmos, os estudantes receberam uma lista de atividades sequenciadas de maneira personalizada, segundo os parâmetros dos respectivos algoritmos e responderam a um questionário de satisfação acerca da recomendação recebida.

Os experimentos deste trabalho, por envolverem pesquisa com seres humanos, foram submetidos à avaliação dos seguintes Comitês de Ética em Pesquisa (CEPs):

- Universidade Federal de Uberlândia, sob o Certificado de Apresentação de Apreciação Ética (CAAE) N^o 16348719.5.0000.5152, conforme pareceres de aprovação N^o 3.742.577 de 03/12/2019 e N^o 4.265.022 de 02/09/2020.
- Instituto Federal de Educação, Ciência e Tecnologia Goiano, sob o CAAE N^o 16348719.5.3005.0036, conforme parecer de aprovação N^o 4.379.131 de 04/11/2020.
- Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro, sob o CAAE N^o 16348719.5.3002.5154, conforme parecer de aprovação N^o 4.563.341 de 26/02/2021.

Em suma, os experimentos foram realizados para verificar se o sequenciamento automático de ações pedagógicas apresenta índices RASI conforme o perfil do estudante, além de aferir o grau de satisfação dos estudantes a partir da recomendação pedagógica ofertada. Na Seção 4.1, são descritos os experimentos e resultados em relação ao AG mono-objetivo e na Seção 4.2 relativos ao AG multiobjetivo.

4.1 AG Mono-objetivo: Experimentos e Resultados

Nesta seção, são descritos os experimentos realizados com AG mono-objetivo em cada uma das três etapas dos experimentos (Etapa 1 — Perfil do estudante; Etapa 2 — Sequen-

ciamento de ações e atribuição de atividades; Etapa 3 — Recomendação de atividades), bem como seus respectivos resultados e discussão.

4.1.1 Etapa 1 - Perfil do Estudante

Na Etapa 1, executada nos meses de novembro e dezembro de 2020, foram convidados estudantes de nível superior em duas instituições de ensino, Instituto Federal de Educação, Ciência e Tecnologia Goiano (IF Goiano) e Universidade Federal de Uberlândia (UFU). Ao todo, foram convidados 402 estudantes no IF Goiano e 63 participantes no UFU. Desses, 41 participantes responderam o questionário RASI. Os participantes estavam regularmente matriculados nos cursos relacionados a seguir:

□ IF Goiano (35 participantes):

- Bacharelado em Agronomia (modalidade Presencial)
- Licenciatura em Química (modalidade Presencial)
- Tecnologia em Agronegócio (modalidade Presencial)
- Tecnologia em Análise e Desenvolvimento de Sistemas (modalidade Presencial)

□ UFU (6 participantes):

- Bacharelado em Ciência da Computação (modalidade Presencial)

Na Figura 7 são exibidos os percentuais de participantes segundo o eixo RASI predominante, obtidos a partir do questionário completo (52 questões). Observou-se que a maioria dos participantes apresenta o eixo *Deep* predominante em relação aos demais (44% = 18 participantes). Além disso, o eixo *Surface* predomina na menor parte dos participantes (15% = 6 participantes). Já no eixo *Strategic*, o percentual foi de 37% (14 participantes).




Figura 7 – Taxa de participantes por perfil RASI - AG Mono-objetivo.

A avaliação da Etapa 1 descreveu a percepção dos estudantes sobre a aferição das respectivas preferências a partir de uma avaliação qualitativa. Assim, após a aplicação

do questionário RASI, foram apresentados os resultados a cada um dos 41 participantes, considerando os percentuais obtidos para os eixos RASI *Surface*, *Strategic* e *Deep* constituintes de cada perfil, bem como o significado desses resultados. A partir disso, foi utilizado um questionário composto por três questões, com a intenção de avaliar o grau de concordância dos participantes sobre tais resultados advindos do questionário RASI. As opções de resposta para cada respostas foram estruturadas numa escala Likert, com 5 níveis. As questões são exibidas na Tabela 8:

Tabela 8 – Questões referentes à percepção dos participantes sobre os índices RASI obtidos.

Questão	GR*
QA1. Considero que o percentual que me foi atribuído ao eixo <i>Surface</i> deveria ser:	GRA1
QA2. Considero que o percentual que me foi atribuído ao eixo <i>Strategic</i> deveria ser:	GRA1
QA3. Considero que o percentual que me foi atribuído ao eixo <i>Deep</i> deveria ser:	GRA1

Legenda: * Grupo de Respostas (AG mono-objetivo).

Para cada uma das questões descritas na Tabela 8, foram associadas opções de resposta conforme apresentado na Tabela 9. A definição dos valores percentuais para cada opção de resposta consideraram o impacto na variação que tais valores representam para os índices de cada categoria RASI.

Tabela 9 – Grupos de respostas para as questões QA1, QA2, QA3, QA4, QA5 e QA6.

OP*	Resposta	GR**
RA1	Muito Maior (a partir de 7 pontos percentuais a mais)	
RA2	Maior (de 3 a 6 pontos percentuais a mais)	
RA3	Igual (até 2 pontos percentuais a mais ou a menos)	GR1
RA4	Menor (de 3 a 6 pontos percentuais a menos)	
RA5	Muito Menor (a partir de 7 pontos percentuais a menos)	

Legenda: * Opção de Resposta (AG mono-objetivo); ** Grupo de Respostas (AG mono-objetivo).

Na Figura 8 foram sintetizadas as respostas para as questões QA1, QA2 e QA3. Ao todo, 24 participantes responderam voluntariamente qual o seu grau de concordância com o perfil RASI obtido.

Como mostrado na Figura 8, a maior parte das respostas reflete grau satisfatório (*Menor*, *Igual*, *Maior*) de concordância dos estudantes em relação aos respectivos perfis cognitivos. Observa-se que para o eixo *Surface* (QA1), 8% dos participantes consideraram que esse índice deveria ser muito menor. Para os eixos *Strategic* (QA2) e *Deep* (QA3), 8% e 21% respectivamente, julgam que tal índice deveria ser *Muito Maior*.




Figura 8 – Percepção dos estudantes sobre o perfil RASI.

4.1.2 Etapa 2 — Sequenciamento de Ações e Atribuição de Atividades

Na Etapa 2, foi utilizado o método proposto no Capítulo 3 para sequenciar ações pedagógicas adequadas a cada um dos perfis coletados a partir da Etapa 1. Os parâmetros do AG foram definidos a partir de testes exploratórios. Desse modo, o tamanho da população $max_i = 1000$ e o número de gerações $max_g = 100$. Na seleção de indivíduos por torneio, a probabilidade k_t foi de 60% e a probabilidade de mutação k_m , foi de 10%. Nos testes exploratórios, notou-se que outras combinações de valores para esses parâmetros não produziram alterações significativas em alguns casos e em outros, pioraram os resultados. Para cada um dos perfis dos estudantes, o AG foi executado 30 vezes. O produto dessa etapa foi o sequenciamento automatizado e personalizado de ações pedagógicas adequadas ao perfil do estudante conforme o RASI.

O AG foi executado para os 41 perfis de estudantes identificados na Etapa 1. Com isso, para cada perfil o AG realizou o sequenciamento de ações que melhor se ajustavam aos perfis. Os índices de similaridade entre cada perfil e a respectiva sequência de ações foram obtidos por meio do resultado da função de aptidão *fitness*, definida na Eq. 7. A partir desses índices foi calculada a taxa de similaridade entre cada perfil de estudante e a respectiva sequência de ações. Essa taxa foi normalizada considerando o maior valor *fitness* que pode ser obtido. Os resultados obtidos são apresentados na Figura 9.

Nos resultados apresentados na Figura 9, é possível observar que 16 sequências de ações (39,02%) tiveram a taxa de similaridade maior ou igual a 99%, sendo que dessas, uma teve a taxa de 100%. A maior parte das sequências, totalizando 22 (53,66%) apresentaram taxa de compatibilidade entre 92% e 98%. No outro extremo dos resultados, nota-se que 3 sequências (7,32%) apresentaram essa taxa menor que 90%, sendo que a pior foi de 88% para 1 sequência. Esses resultados apresentaram-se promissores do ponto de vista

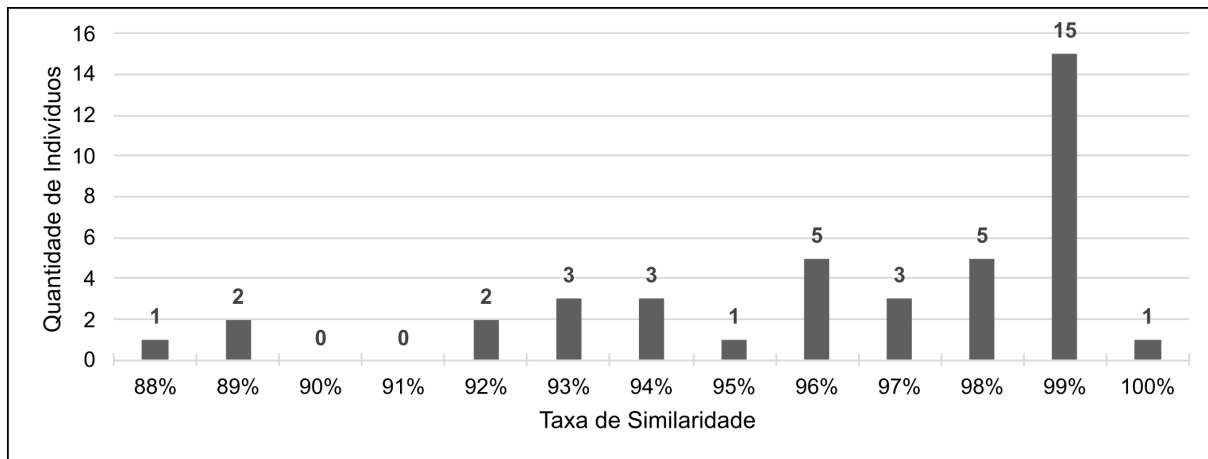


Figura 9 – Taxas de similaridade entre as sequências de ações e os perfis cognitivos dos estudantes

da função de aptidão.

Outra medida de avaliação quantitativa da sequência pedagógica produzida foi conduzida a partir da estratificação das ações sequenciadas para cada perfil em relação ao grau de relevância, considerando o mapeamento entre a TB e o RASI, conforme definido na Figura 3. Desse modo, os graus de relevância foram divididos em três níveis (*baixo*, *moderado* e *alto*). A partir dessa análise, temos a organização apresentada na Tabela 10.

Tabela 10 – Grau de relevância entre as categorias RASI e os estados cognitivos da TB.

Categorias RASI	Graus de Relevância		
	Baixo	Moderado	Alto
<i>Surface</i>	Aplicar, Avaliar	Compreender, Analisar, Criar	Lembrar
<i>Strategic</i>	Lembrar, Criar	Compreender, Aplicar	Analisar, Avaliar
<i>Deep</i>	Lembrar, Aplicar	Compreender, Criar	Analisar, Avaliar

O mapeamento apresentado na Figura 3 distingue a taxa de relevância de cada categoria da DPC em relação a cada eixo do RASI. A estratificação dessa relação em graus de relevância produziu o resultado apresentado na Tabela 10, em que para cada eixo do RASI foram ranqueadas as categorias da DPC consoante o valor da taxa de relevância. Essas categorias foram classificadas duas a duas com grau de relevância *baixo*, *moderado* ou *alto*, seguindo a ordem de ranqueamento. Esse padrão não foi possível ser seguido para o eixo *Surface*, pois existem três categorias da DPC com taxas de relevância iguais. Os resultados são apresentados na Tabela 11.

A Tabela 11 mostra a taxa de recomendação de atividades conforme os graus de relevância presentes na Tabela 10. Nessa tabela, observa-se que a taxa média geral de recomendação de atividades é maior e o desvio padrão é menor para o grau de relevância *Alto*. Tal resultado é satisfatório, pois corrobora a eficácia da função de adaptação do

Tabela 11 – Grau de relevância entre as categorias *RASI* e os estados cognitivos da TB.

Categoria	Medida	Graus de Relevância		
		Baixo	Moderado	Alto
Geral	Média	69.27%	61.46%	85.42%
	Desvio Padrão	0.276	0.250	0.150
<i>Surface</i>	Média	75.69%	50.00%	90.28%
	Desvio Padrão	0.289	0.167	0.125
<i>Strategic</i>	Média	50.74%	89.71%	62.50%
	Desvio Padrão	0.093	0.173	0.133
<i>Deep</i>	Média	33.33%	66.67%	68.75%
	Desvio Padrão	0.171	0.219	0.068

AG, visto que na média geral, o sequenciamento de atividades prioriza aquelas com grau de relevância maior para os perfis cognitivos.

Ainda na Tabela 11, ao observar os índices estratificados por categoria RASI, a *Strategic* apresenta maior taxa de recomendação para o grau *Moderado*. Tal situação é previsível, dado que considerando a definição da categoria *Strategic*, esta se figura como uma transição da categoria *Surface* para a *Deep*, podendo apresentar situações de sobreposição às demais categorias.

4.1.3 Etapa 3 — Recomendação de Atividades

Na Etapa 3, o público-alvo é composto pelos estudantes que participaram da Etapa 1, sendo que dos 41 participantes que receberam as respectivas recomendações pedagógicas, 24 avaliaram o grau de satisfação em relação à sequência de atividades recebida.

O grau de satisfação do estudante em relação à recomendação pedagógica foi avaliado considerando os seguintes itens: i) quantidade de atividades propostas; ii) conforto na realização das atividades; iii) probabilidade de realizar todas as atividades da sequência; iv) aceitação das atividades propostas. As questões relativas a esses itens são apresentadas na Tabela 12.

As opções de respostas para as questões expressas na Tabela 12 são apresentadas na Tabela 13. A definição dos valores relativos ao grupo de respostas GRA2, que diz respeito à QA4 (quantidade de atividades) considerou a quantidade máxima de atividades possível de ser recomendada (24), nesse caso, consideramos uma variação muito alta ou muito baixa a partir de 1/4 desse total de atividades possíveis, ou seja, uma variação a partir de 6 atividades. Com base nisso, consideramos razões desse valor para as demais escalas.

Relativo ao grupo de respostas GRA3, que trata da percepção de conforto do estudante ao realizar a sequência de atividades, as opções consideraram uma escala Likert de 5 níveis. Já para o grupo GRA4, que diz respeito à probabilidade do estudante realizar todas as atividades, as de resposta consideraram uma escala realizada a partir da divisão em 5 faixas de valores percentuais, num intervalo entre 0 e 100. Tanto para o grupo GRA6

Tabela 12 – Questionário sobre a satisfação da recomendação pedagógica relativa ao AG mono-objetivo

Questão	GR*
QA4. Você acredita que a quantidade de atividades é:	GRA2
QA5. A sequência de atividades é confortável para lhe conduzir no aprendizado de um novo conteúdo ou disciplina.	GRA3
QA6. Qual a possibilidade de você realizar todas as atividades dessa sequência?	GRA4
QA7. Caso você não realize todas as atividades, cite apenas o(s) número(s) da(s) atividade(s) que você não faria.	GRA6
QA8. Caso tenha qualquer comentário sobre a sequência de atividades, informe aqui.	GRA7

Legenda: * Grupo de Respostas (AG mono-objetivo).

quanto o GRA7, as respostas foram feitas de forma textual pelos participantes.

Tabela 13 – Grupos de respostas para as questões QA4, QA5, QA6, QA7 e QA8.

OP*	Resposta	GR**
RA6	Muito Alta (tem pelo menos 6 atividades a mais do que considera ideal)	
RA7	Alta (tem entre 3 e 5 atividades a mais do que considera ideal)	
RA8	Suficiente (tem até 2 atividades a mais ou a menos do que considera ideal)	GRA2
RA9	Baixa (tem entre 3 e 5 atividades a menos do que considera ideal)	
RA10	Muito Baixa (tem pelo menos 6 atividades a menos do que considera ideal)	
RA11	Concordo	
RA12	Concordo Parcialmente	
RA13	Indiferente	GRA3
RA14	Discordo Parcialmente	
RA15	Discordo	
RA16	Muito Alta (acima de 80%)	
RA17	Alta (entre 61% e 80%)	
RA18	Moderada (entre 41% e 60%)	GRA4
RA19	Baixa (entre 20% e 40%)	
RA20	Muito Baixa (abaixo de 20%)	
RA21	Resposta aberta (código ou nome/descrição das atividades)	GRA5
RA22	Resposta aberta (texto livre)	GRA6

Legenda: * Opção de Resposta (AG mono-objetivo); ** Grupo de Respostas (AG mono-objetivo).

A partir do sequenciamento de ações pedagógicas, foram recomendadas sequências de atividades para os estudantes, com base em seu perfil RASI. Ao todo foram realizadas recomendações pedagógicas para os 41 estudantes que participaram da Etapa 1 dos experimentos. Desses, 24 responderam o questionário a respeito da satisfação da respectiva sequência pedagógica recebida. Os resultados são apresentados na Figura 10.




Figura 10 – Satisfação dos estudantes em relação à recomendação das atividades sequenciadas.

Na Figura 10a, são apresentadas as taxas referentes à questão QA4. Essa, diz respeito à opinião dos estudantes em relação à quantidade de atividades recebida. Note que a maioria dos estudantes (92%) respondeu que a quantidade de atividades é *Alta*, ou *Muito Alta*, ou seja, consideram que deveria ser reduzidas em pelo menos três. Segundo a modelagem proposta, a quantidade máxima de atividades possível é 24. Em média foram recomendadas 15 atividades para cada estudante. Esse valor representa quase $\frac{2}{3}$ da quantidade máxima de atividades que pode ser recomendada. Entendemos esse resultado como um parâmetro a ser observado para realização de ajustes no AG, de modo a adequar essa quantidade aos perfis cognitivos dos estudantes em trabalhos futuros.

As taxas das respostas referente à questão QA5 são apresentadas na Figura 10b. Tal inquérito objetivou analisar a percepção do estudante em relação à agradabilidade da sequência de atividades na condução da aprendizagem de um novo conteúdo. É possível observar que 79% dos estudantes respondeu *Concordo* ou *Concordo Fortemente* que a sequência de atividades confortável para conduzir-lhes no processo de aprendizagem de um novo conteúdo. Tal resultado sugere de que a TBD pode ser uma alternativa interessante na formulação de atividades digitais para estudante. Além disso, essa análise traz à luz o indicativo de que o mapeamento realizado neste trabalho entre as atividades digitais da TBD, distribuídas unidimensionalmente na DPC, e as ações pedagógicas propostas conforme a estrutura bidimensional da TB. Mesmo com os resultados satisfatórios, entendemos ser possível utilizar essa avaliação para personalizar a adequação da recomendação pedagógica ao estudante, em trabalhos futuros, dado que 4% discordam fortemente e 17% são indiferentes à sequência de atividades recebida.

Referente à questão QA6, as taxas das respostas coletadas são exibidas na Figura 10c, e dizem respeito à percepção dos estudantes no que tange a probabilidade destes de realizarem todas as atividades. Observou-se que 29% dos estudantes considera *Baixa* ou *Muito baixa* a possibilidade de realizar todas as atividades pedagógicas recomendadas, ou seja, este grupo tem 40% ou menos de chance de cumprir todas as atividades. Esse é o mesmo percentual de estudantes que considerou *Alta* ou *Muito Alta* a probabilidade

de completarem todas as atividades (acima de 60%). Além disso, 42% considerou essa probabilidade *Moderada* (entre 41% e 60%). Nota-se um equilíbrio nos extremos das respostas para esta questão, entretanto tal parâmetro pode ser usado para auxiliar no refinamento do sequenciamento de atividades.

Apesar das respostas na questão QA4 apontarem certo grau de insatisfação dos estudantes com a quantidade de atividades recomendada, as respostas na questão QA6 sugerem haver uma certa coerência nas respostas dos estudantes em relação à questão QA5, visto que a maioria considera a sequência confortável no favorecimento da aprendizagem. Nesse sentido, de modo geral, tais resultados são satisfatórios.

Outro fator analisado foi a taxa de aceitação de cada atividade pedagógica recomendada. Essa taxa foi calculada a partir das respostas dos estudantes à questão QA7, em que explicitaram quais atividades eles não gostariam de realizar. Na avaliação da sequência de atividades, essa questão foi opcional para os estudantes, portanto se nota a possibilidade dessas respostas terem melhor qualidade. Essa análise pode ser observada na Figura 11.

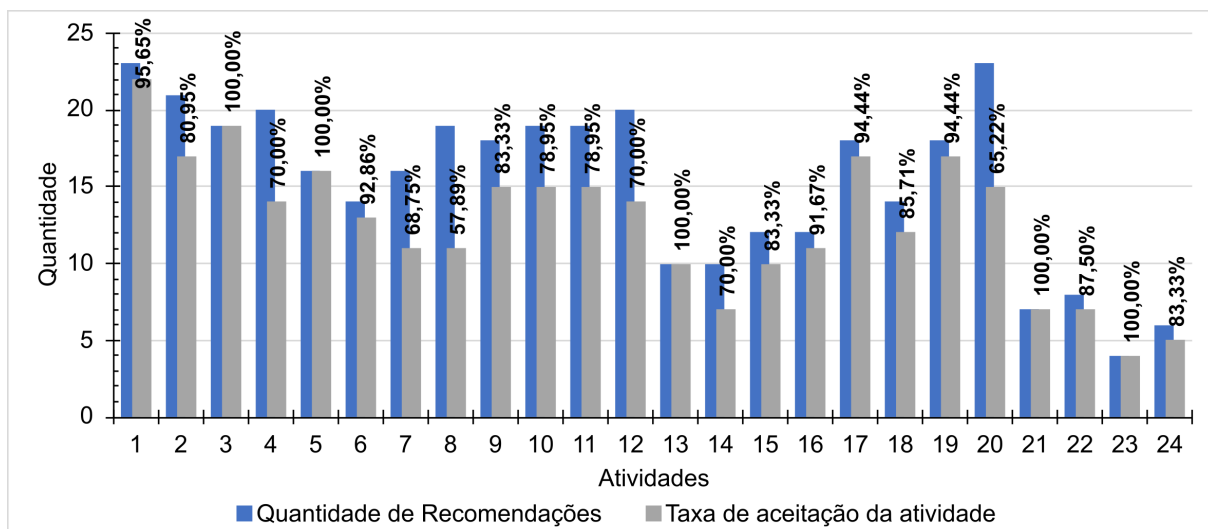


Figura 11 – Taxa de aceitação por atividade recomendada.

As atividades foram recomendadas respeitando a ordem da mais concreta (*Atividade 1*), para a mais abstrata (*Atividade 24*). Na Figura 11, as atividades 1 e 20 foram as mais recomendadas (23 vezes), sendo elas:

- ☐ Atividade 1 — Buscar conceitos básicos na Web ou redes sociais.
- ☐ Atividade 20 — Apresentar conteúdo, usando ferramentas digitais.

A Atividade 1 teve taxa de aceitação maior (95.65%), já na Atividade 20 essa taxa foi de 65.22% por parte dos estudantes. Apesar disso, é possível notar uma leve predileção dos participantes pelas atividades mais abstratas em detrimento das menos abstratas,

dados que a média da taxa de aceitação das 12 primeiras atividades foi de 81.44% e a das 12 últimas atividades foi de 87.97%.

A estratificação dos resultados dos perfis dos 24 estudantes participantes desta etapa por categoria RASI predominante, revelou os seguintes quantitativos: 11 *Surface*; 9 *Strategic* e 4 *Deep*. A taxa de rejeição das atividades, considerando o agrupamento definido na Tabela 10, mostra que, em geral, a maioria dos estudantes sinalizou que não gostaria de realizar atividades com grau de relevância baixo ou moderado para o respectivo perfil cognitivo predominante, conforme apresentado na Figura 12.




Figura 12 – Taxa de rejeição de atividades por categoria RASI predominante do estudante.

Na Figura 12, observa-se que a taxa de rejeição média das atividades conforme a relevância para a categoria predominante do perfil RASI foi: alta — 10.56%; moderada — 17.95%; baixa — 19.64%. Isso mostra que, em geral, a recomendação do AG prioriza atividades mais próximas às especificidades do perfil do estudante e que as atividades mais relevantes aos perfis são preferidas em detrimento de atividades menos relevantes. Ainda na categoria *Deep*, o índice de rejeição foi zero para atividades de baixa relevância.

Tabela 14 – Média dos índices RASI para os perfis dos 24 estudantes participantes da Etapa 3 dos experimentos (AG mono-objetivo).

Categoria Predominante	Média por Categoria RASI		
	<i>Surface</i>	<i>Strategic</i>	<i>Deep</i>
<i>Surface</i>	0.7852	0.6918	0.5199
<i>Strategic</i>	0.7417	0.8090	0.4809
<i>Deep</i>	0.5875	0.4766	0.6797

Segundo a Tabela 14, é possível notar que grupo o de estudantes cujo eixo predominante é o (*Deep*), está menos definido em relação aos demais grupos. Além disso, nesse mesmo grupo, 2 participantes apresentaram índices *Surface* quase similares aos índices *Deep*.

Note que para perfis cujo índice *Surface* é elevado, certas atividades com relevância alta, apresentam relevância baixa para o perfil *Deep*. Deste modo os resultados apresentados na Figura 12 estão coerentes com a teoria que descreve tais características.

Diante disso, tais resultados corroboram o grau de coesão no mapeamento realizado entre a Taxonomia de Bloom e o RASI, proposto neste trabalho. Outro achado, a partir desses resultados, foi a confirmação do nexos existente na categorização das atividades digitais propostas pela Taxonomia Digital de Bloom e a análise bidimensional da Taxonomia de Bloom. Destaca-se ainda que tais resultados são preliminares, porém promissores e podem subsidiar melhorias tanto no mapeamento quanto na categorização propostos.

4.2 AG Multiobjetivo: Experimentos e Resultados

A implementação e utilização de um AG multiobjetivo se deu pelo fato de buscar maior satisfação dos estudantes a partir da recomendação pedagógica oferecida. Sendo assim, além do primeiro objetivo relativo à aproximação da sequência de ações pedagógicas ao perfil RASI do estudante, foi incluído um segundo objetivo, relacionado à quantidade de ações mais adequada ao perfil. A definição da quantidade de ações segundo o eixo RASI predominante do estudante foi realizada conforme respostas nos experimentos como o AG mono-objetivo, onde se chegou à:

- ❑ *Surface*: 9 atividades
- ❑ *Strategic*: 13 atividades
- ❑ *Deep*: 11 atividades

Além disso, outra alteração na metodologia, em comparação aos experimentos com o AG mono-objetivo, foi a utilização do questionário RASI na versão curta², traduzido livremente para o português e disponibilizado no Apêndice A. Tal decisão impossibilitou a comparação direta entre os algoritmos genéticos, visto que o método de coleta dos dados utilizados como entrada para os algoritmos mudou.

Sendo assim, nesta seção, são descritos os experimentos realizados com AG multi-objetivo em cada uma das três etapas dos experimentos (Etapa 1 — Perfil do estudante. Etapa 2 — Sequenciamento de ações e atribuição de atividades. Etapa 3 — Recomendação de atividades.), bem como seus respectivos resultados e discussão.

4.2.1 Etapa 1 — Perfil RASI

Na Etapa 1 foram convidados estudantes de nível superior em duas instituições de ensino, IF Goiano e UFU, regularmente matriculados nos cursos relacionados a seguir:

² Disponível em Entwistle e Tait (2013).

□ IF Goiano:

- Licenciatura em Pedagogia (modalidade Educação a Distância (EaD))
- Bacharelado em Agronomia (modalidade Presencial)
- Bacharelado em Ciência da Computação (modalidade Presencial)
- Licenciatura em Química (modalidade Presencial)
- Tecnologia em Agronegócio (modalidade Presencial)
- Tecnologia em Análise e Desenvolvimento de Sistemas (modalidade Presencial)

□ UFU:

- Bacharelado em Administração Pública (modalidade EaD)
- Licenciatura em Pedagogia (modalidade EaD)

No total, foram convidados 513 estudantes dos cursos presenciais e 304 estudantes do curso EaD no IF Goiano. Na UFU, foram convidados 394 estudantes dos cursos EaD. No IF Goiano 78 estudantes dos cursos presenciais e 46 estudantes do curso EaD responderam o questionário RASI. Na UFU, 58 estudantes dos cursos EaD responderam o questionário RASI. Desse total de estudantes em ambas as instituições, 65 optaram por participar dos experimentos, respondendo ao questionário de satisfação acerca da recomendação pedagógica recebida. Na Figura 13 é apresentada a distribuição dos participantes a partir do eixo predominante do perfil RASI.

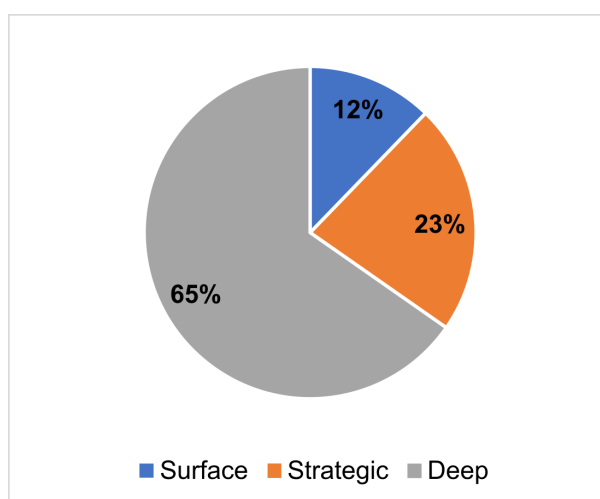


Figura 13 – Quantidade de participantes por perfil RASI.

Na Figura 13 os resultados foram obtidos a partir do questionário RASI — versão curta. Nota-se que a maioria dos participantes (65%) apresentam o eixo *Deep* predominante. Além disso, o menor grupo de participantes estratificado por eixo predominante é o *Surface* (12%). Com o objetivo averiguar a compreensão dos participantes em relação aos conceitos

envolvidos no perfil RASI, foram feitas afirmações acerca dos índices obtidos por esses a partir do primeiro questionário e 36 participantes responderam este segundo.

Nesse segundo questionário foram apresentadas duas afirmações para cada eixo RASI aos participantes. Tais afirmações buscaram verificar o nível de atenção dos participantes ao questionário, considerando os parâmetros definidos em Huang et al. (2012). Em consonância com orientações do Comitê de Ética em Pesquisa (CEP)/UFU, a participação em todas as etapas dos experimentos foi voluntária e as respostas a cada questão foram opcionais. Por esse motivo, torna-se inviável realizar uma análise correlacionada dessas respostas com outras etapas dos experimentos, dado que participantes que não responderam esse questionário, puderam participar das outras etapas dos experimentos. Entretanto, a análise global desses dados pode apresentar parâmetros para melhor compreensão da qualidade das respostas fornecidas pelos participantes. Na Figura 14, foram sintetizadas as respostas para as afirmações na Tabela 15.

Tabela 15 – Questões referentes à percepção dos participantes sobre os índices RASI obtidos.

Questão	GR*
QB1. Considero que o percentual que me foi atribuído ao eixo <i>Surface</i> deveria ser:	GR1
QB2. Considero que o percentual que me foi atribuído ao eixo <i>Strategic</i> deveria ser:	GR1
QB3. Considero que o percentual que me foi atribuído ao eixo <i>Deep</i> deveria ser:	GR1
QB4. Considero que o percentual que me foi atribuído ao eixo <i>Surface</i> , corresponde ao meu perfil de aprendizado.	GR2
QB5. Considero que o percentual que me foi atribuído ao eixo <i>Strategic</i> , corresponde ao meu perfil de aprendizado.	GR2
QB6. Considero que o percentual que me foi atribuído ao eixo <i>Deep</i> , corresponde ao meu perfil de aprendizado.	GR2

Legenda: * Grupo de Respostas (AG multiobjetivo).

Cada uma das questões na Tabela 15 apresentaram as opções de resposta conforme os grupos de respostas na Tabela 16.

As respostas da Tabela 15 foram estruturadas na escala Likert de 5 pontos, conforme apresentadas na Tabela 16. Os resultados são apresentados na Figura 14.

Na Figura 14a, a opção de resposta “*Igual*” (RB3) representa a concordância dos participantes com os índices RASI obtidos. Para cada um dos três eixos, pelo menos 56%, no caso da questão Q1, dos participantes mostraram concordar com os índices RASI obtidos. Outra observação favorável foi que a soma das respostas “*Muito Maior*” (RB1) e “*Muito Menor*” (RB5) foi de no máximo 14% (Q3).

Na Figura 14b foram feitas perguntas similares as da Figura 14a, de modo a verificar a atenção dos estudantes na resposta ao questionário. Na Figura 14b, a resposta que expressa maior concordância do estudante com cada índice RASI é “*Concordo*” e seu

Tabela 16 – Grupos de respostas para as questões QB1, QB2, QB3, QB4, QB5 e QB6.

OP*	Resposta	GR**
RB1	Muito Maior (a partir de 7 pontos percentuais a mais)	
RB2	Maior (de 3 a 6 pontos percentuais a mais)	
RB3	Igual (até 2 pontos percentuais a mais ou a menos)	GR1
RB4	Menor (de 3 a 6 pontos percentuais a menos)	
RB5	Muito Menor (a partir de 7 pontos percentuais a menos)	
RB6	Concordo	
RB7	Concordo Parcialmente	
RB8	Indiferente	GR2
RB9	Discordo Parcialmente	
RB10	Discordo	

Legenda: * Opção de Resposta (AG multiobjetivo); ** Grupo de Respostas (AG multiobjetivo).

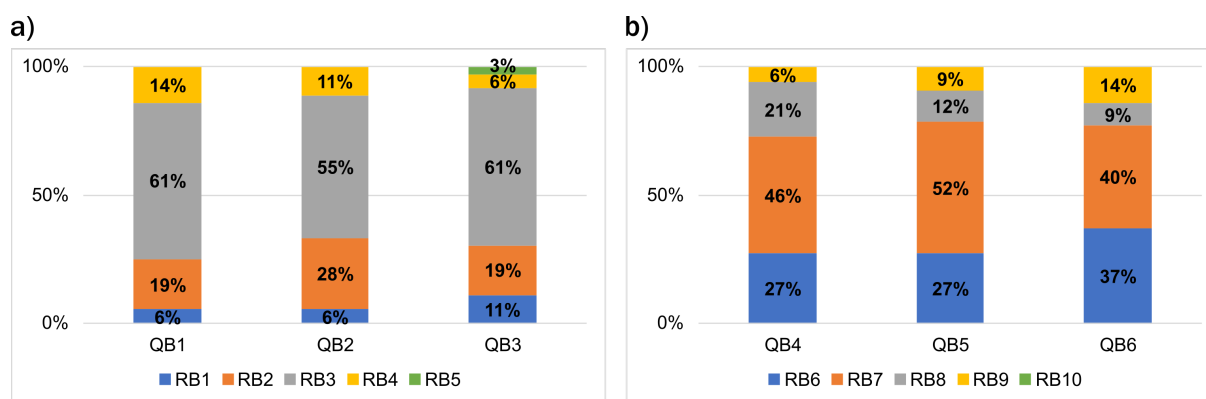


Figura 14 – Percepção dos estudantes sobre o perfil RASI:

- a) QB1, QB2 e QB3: em que grau os percentuais RASI deveriam ser diferentes.
b) QB4, QB5 e QB6: o quão concorda com o percentual atribuído ao perfil.

Tabela 17 – Comparação agrupada entre as respostas das questões Q1-Q4, Q2-Q5, Q3-Q6.

Afirmações	QB1	QB4	QB2	QB5	QB3	QB6
Respostas agrupadas	94%	94%	94%	91%	86%	86%

oposto é “Discordo”. Na comparação par a par das afirmações Q1-Q4, Q2-Q5 e Q3-Q6, que correspondem aos eixos *Surface*, *Strategic* e *Deep* respectivamente, observa-se que a soma dos percentuais para as respostas com mesmo significado são aproximadas, conforme Tabela 17.

Na Tabela 17, para as questões QB1, QB2 e QB3, as respostas agrupadas foram “Maior” (RB2), “Igual” (RB3) e “Menor” (RB4). Para as questões QB4, QB5 e QB6, foram agrupadas as respostas “Concordo” (RB6), “Concordo Parcialmente” (RB7) e “Indiferente” (RB8). Observe que os percentuais de respostas são idênticos para os pares QB1-QB4 e QB3-QB6 e muito próximos para o par QB2-QB5, com 3 pontos percentuais

de diferença. Tais resultados reforçam nossa confiança na qualidade das respostas dos participantes acerca do questionário RASI e em como a maior parte destes compreendeu os conceitos envolvidos nas definições dos eixos RASI. A partir dos perfis obtidos por meio do questionário RASI foi realizado o sequenciamento de ações pedagógicas por meio do AG multiobjetivo desenvolvido neste trabalho, além da recomendação de atividades digitais aos estudantes, conforme descrito nas próximas etapas dos experimentos.

4.2.2 Etapa 2 — Sequenciamento de Ações

Na Etapa 1 dos experimentos, foram identificados os perfis RASI de 182 estudantes. Desses, 49 participantes se voluntariam a participar da etapa de recomendação de atividades (Etapa 3). Para esses participantes, foram geradas sequências de ações pedagógicas conforme o AG multiobjetivo proposto na Seção 3.2. Na Figura 15 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 expressos na 3. 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.

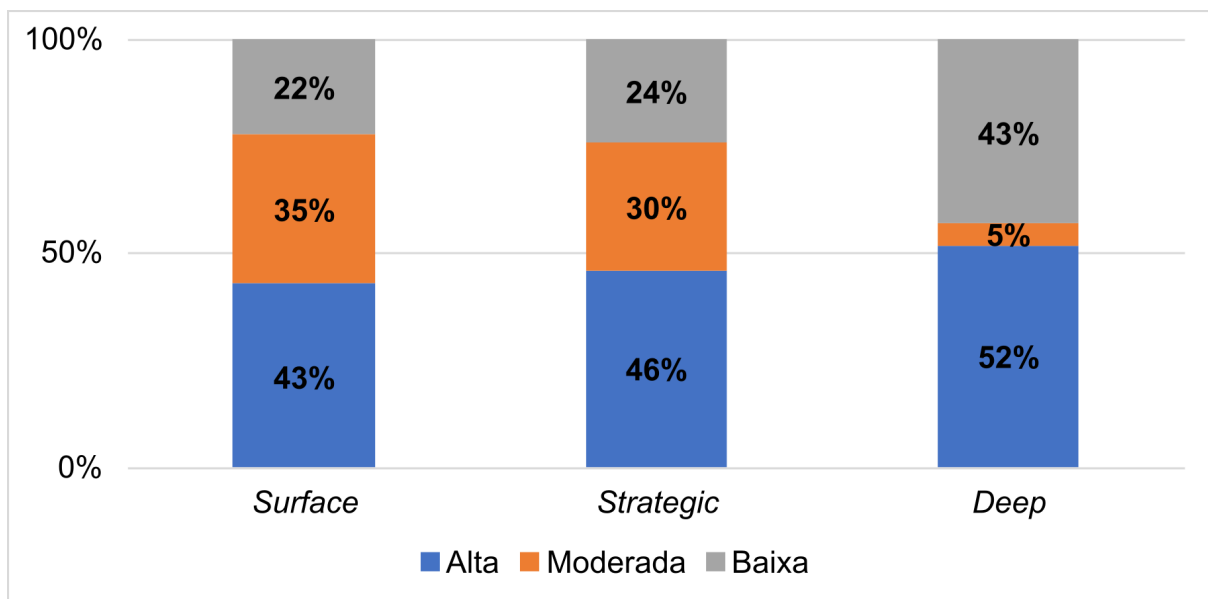


Figura 15 – Taxa de recomendação por perfil, conforme o grau de relevância (valores normalizados)

Conforme observado na Figura 15, 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 ponto percentual dos demais perfis. No perfil *Strategic* não há ocorrência dessa condição e no perfil *Surface*, esse padrão se repetiu para 1 participante.

Na implementação do AG, quando um ou mais índices dos eixos se reparam, optou-se por tratar o sequenciamento de ações considerando o eixo mais abstrato. Por exemplo, quando o índice *Deep* é igual ao *Strategic* e/ou *Surface*, aquele perfil é tratado como *Deep* pelo AG. Esta decisão foi tomada no sentido de que o objetivo da recomendação pedagógica é criar um ambiente propício ao desenvolvimento do estudante rumo a HOCS. Apesar disso, o sequenciamento é influenciado também pelos índices dos demais perfis. Desse modo, tal característica do AG proposto pode ter causado a distorção observada na Figura 15 para os perfis *Deep*. Esse resultado sugere a necessidade de investigação desse aspecto, além da melhoria do AG em trabalhos futuros.

A partir de experimentos anteriores, conforme relatado na Seção 3.2, 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 16 é observada a quantidade média de atividades recomendada por eixo RASI predominante.




Figura 16 – Comparação da quantidade média de atividades recomendadas com os valores de referência para cada perfil RASI.

A análise dos resultados presentes na Figura 16 dizem 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. O sequenciamento de ações proposto adéqua a quantidade de ações considerando apenas o eixo RASI predominante do estudante. Na média, a quantidade ideal de ações para o eixo *Strategic* foi atingida. Para eixo *Surface*, na média foram recomendadas duas atividades a menos e para o eixo *Deep* uma atividade a mais. 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.

Para a execução dos experimentos na Etapa 3 foram realizadas recomendações a partir dois métodos de sequenciamento de ações. No primeiro método, as ações foram sequenciadas utilizando AG multiobjetivo, conforme descrito na Seção 3.2 e no segundo, de maneira aleatória. No sequenciamento aleatório, a quantidade mínima foi de 6 e a máxima de 24 ações sequenciadas. Optamos por essa quantidade mínima para oportunizar o sequenciamento de pelo menos uma ação de cada categoria da DPC na TB, conforme hierarquia descrita na Subseção 3.1.1. A quantidade máxima de ações também segue a máxima possível segundo tal hierarquia. Na Tabela 18 é possível observar a comparação descritiva das recomendações sequenciadas por AG multiobjetivo e aleatoriamente para 49 e 16 perfis RASI, respectivamente.

Tabela 18 – Análise descritiva da quantidade de ações sequenciadas conforme o método usado.

Descritor	Sequenciamento por AG	Sequenciamento Aleatório
N	49	16
Menor	9	6
Maior	13	20
Média	10,4	13,8
Desvio Padrão	1,7	4,3

Na Tabela 18, a média geral de atividades sequenciadas por participante pelo AG multiobjetivo foi 10,4 e aleatoriamente foi 13,8. Além disso, o desvio padrão da quantidade de atividades foi maior no sequenciamento aleatório. Tais resultados mostram que de maneira geral, a quantidade de ações sequenciadas por AG multiobjetivo segue uma tendência mais homogênea do que as recomendações aleatórias no que diz respeito à quantidade de ações.

4.2.3 Etapa 3 — Recomendação de Atividades

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 a partir do sequenciamento de ações por dois métodos distintos. O primeiro método é o sequenciamento de ações por AG multiobjetivo, usado na recomendação pedagógica aos participantes do grupo *experimento*. A segunda consiste em ações

selecionadas aleatoriamente para gerar a recomendação pedagógica aos participantes do grupo *controle*.




Figura 17 – Participantes por grupo (experimento x controle).

A adesão de estudantes para participarem dessa etapa dos experimentos se deu a partir do convite dos 182 participantes que responderam o questionário RASI em momento anterior. Desses, cerca de 1/3 (61 participantes) receberam uma sequência de atividades digitais selecionadas a partir do sequenciamento aleatório de ações e cerca de 2/3 (121 participantes) receberam uma sequência de atividades a partir do sequenciamento por AG multiobjetivo. A divisão dos grupos de participantes se deu de maneira aleatória. A partir do convite realizado aos participantes, na Figura 17, é possível notar haver cerca de 25% e 75% de participantes nos grupos *controle* e *experimento*, respectivamente.

Uma recomendação apresentada ao estudante consiste numa lista de atividades digitais da Taxonomia Digital de Bloom, conforme detalhamento na Figura 2. As atividades

Tabela 19 – Questões sobre a satisfação dos participantes em relação à recomendação pedagógica (AG multiobjetivo)

Questão	GR*
QB7. Você acredita que a quantidade de atividades é:	GRB3
QB8. O número total de atividades recomendadas é muito elevado.	GRB4
QB9. A sequência de atividades é confortável para lhe conduzir no aprendizado de um novo conteúdo ou disciplina.	GRB4
QB10. Qual a possibilidade de você realizar todas as atividades dessa sequência?	GRB5
QB11. Dentre as atividades recomendadas, informe três que mais prefere.	GRB6
QB12. Dentre as atividades recomendadas, informe três que menos prefere.	GRB6
QB13. Caso tenha qualquer comentário sobre a sequência de atividades, informe aqui.	GRB7

Legenda: * Grupo de Respostas (AG multiobjetivo).

dessa tabela são selecionadas a partir do sequenciamento personalizado de ações pedagógicas gerado pelo AG multiobjetivo, no caso dos participantes do grupo *experimento* e

aleatoriamente, no caso dos participantes do grupo *controle*. Para cada recomendação foi apresentado um questionário ao participante, com o intuito de avaliar a satisfação desse em relação às atividades recebidas. As perguntas relativas à satisfação do estudante são listadas na Tabela 19.

As opções de resposta das questões na Tabela 19 são exibidas na Tabela 20 conforme os grupos de respostas. Os grupo GRB3, GRB4 e GRB5 foram estruturados considerando a escala Likert de 5 níveis. Os grupos GRB6 e GRB7 foram definidos em forma de respostas abertas.

Tabela 20 – Grupos de respostas para as questões QB7, QB8, QB9, QB10.

OP*	Resposta	GR**
RB11	Muito Alta (tem pelo menos 6 atividades a mais do que considera ideal)	
RB12	Alta (tem entre 3 e 5 atividades a mais do que considera ideal)	
RB13	Suficiente (tem até 2 atividades a mais ou a menos do que considera ideal)	GRB3
RB14	Baixa (tem entre 3 e 5 atividades a menos do que considera ideal)	
RB15	Muito Baixa (tem pelo menos 6 atividades a menos do que considera ideal)	
RB16	Concordo	
RB17	Concordo Parcialmente	
RB18	Indiferente	GRB4
RB19	Discordo Parcialmente	
RB20	Discordo	
RB21	Muito Alta (acima de 80%)	
RB22	Alta (entre 61% e 80%)	
RB23	Moderada (entre 41% e 60%)	GRB5
RB24	Baixa (entre 20% e 40%)	
RB25	Muito Baixa (abaixo de 20%)	
RB26	Resposta aberta (código ou nome/descrição das atividades)	GRB6
RB27	Resposta aberta (texto livre)	GRB7

Legenda: * Opção de Resposta (AG multiobjetivo); ** Grupo de Respostas (AG multiobjetivo).

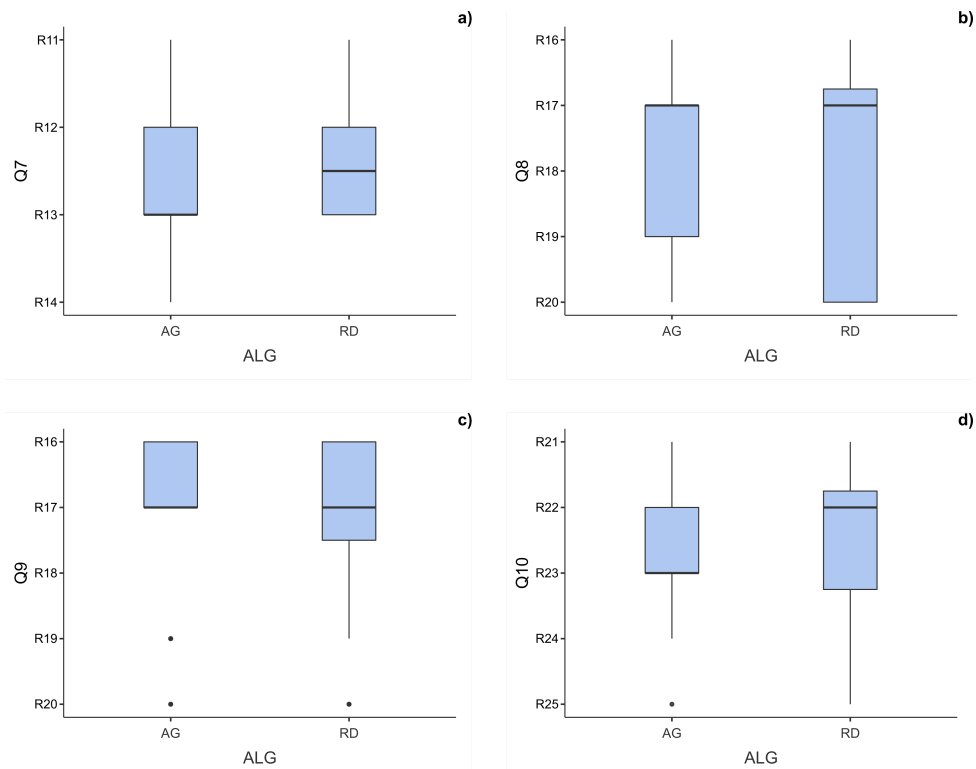
Na Tabela 21 são apresentados os descritores estatísticos relativos às respostas dos participantes para QB7, QB8, QB9 e QB10, considerando sequenciamento por AG multiobjetivo e aleatório.

As respostas obtidas nas questões QB7, QB8, QB9 e QB10 pertencem aos grupos de respostas GRB3, GRB4 e GRB5. Essas foram estruturadas a partir de uma escala Likert de 5 níveis, logo se tratam de variáveis qualitativas ordinais. Por este motivo, usamos a mediana como medida de tendência central e o intervalo interquartil como medida de variabilidade para descrever o conjunto de dados. Ao todo, tivemos 49 respostas decorrentes da recomendação originada pelo sequenciamento por AG multiobjetivo e 16 respostas para a recomendação gerada a partir do sequenciamento aleatório. Na Figura 18 é apresentado o *boxplot* gerado a partir dos dados da Tabela 21.

Na Figura 18 são comparadas as respostas (QB7, QB8, QB9 e QB10) fornecidas pelos participantes que receberam recomendação pedagógica a partir do sequenciamento por AG

Tabela 21 – Descritores estatísticos relativos às respostas para QB7, QB8, QB9 e QB10.

Descritor	Sequenciamento de Ações	QB7	QB8	QB9	QB10
N	Por AG Multiobjetivo	49	49	49	49
	Aleatório	16	16	16	16
Mínimo	Por AG Multiobjetivo	2	1	2	1
	Aleatório	3	1	2	1
Máximo	Por AG Multiobjetivo	5	5	5	5
	Aleatório	5	5	5	5
Mediana	Por AG Multiobjetivo	3	4	4	3
	Aleatório	3,5	4	4	4
1º quartil	Por AG Multiobjetivo	3	3	4	3
	Aleatório	3	3	3,75	2,75
2º quartil	Por AG Multiobjetivo	3	4	4	3
	Aleatório	3,5	4	4	4
3º quartil	Por AG Multiobjetivo	4	4	5	4
	Aleatório	4	4,25	5	4,25

Figura 18 – *Boxplot* para as questões QB7, QB8, QB9 e QB10.

multiobjetivo e os que receberam recomendação a partir do sequenciamento aleatório. A Figura 18a diz respeito à questão QB7 (quantidade de atividades recomendadas) e mostra, a partir da mediana, uma tendência de concentração das respostas em R13 (“*Suficiente*”) para o sequenciamento por AG multiobjetivo e entre RB13 “*Suficiente*” e RB12 “*Alta*” para o sequenciamento aleatório.

A Figura 18b sumariza as respostas para a questão QB8 relativa à concordância dos estudantes sobre a quantidade elevada de atividades recomendadas. Tanto para o sequenciamento por AG multiobjetivo quanto para o sequenciamento aleatório, a mediana está em RB17 (“*Concordo Parcialmente*”), entretanto, há maior variabilidade nas respostas do sequenciamento por AG.

Na Figura 18c (QB9 — indaga sobre a sequência ser confortável), a mediana das respostas para ambos os métodos ficou em RB17 (“*Concordo Parcialmente*”), porém a maior variabilidade para o sequenciamento aleatório indica uma tendência de maior satisfação dos estudantes nesse quesito, em relação ao sequenciamento por AG.

Na Figura 18d, que sintetiza as respostas para QB10 (possibilidade de realizar todas as atividades). Em relação ao sequenciamento por AG multiobjetivo, a mediana ficou em RB23 (“*Moderada*”) e para o aleatório, a mediana ficou em RB22 (“*Alta*”). Além disso, a maior variabilidade apresentada nas respostas para o sequenciamento aleatório não nos permite afirmar que a satisfação do estudante é melhor que com o AG.

A partir dos dados obtidos para as questões QB7, QB8, QB9 e QB10, foi realizado o teste estatístico de Kruskal-Wallis³ para verificar se há significância estatística entre as respostas dadas pelos estudantes em relação aos dois métodos de sequenciamento utilizados.

Tabela 22 – Teste de Kruskal-Wallis para QB7, QB8, QB9 e QB10.

Questão	χ^2	df	p
QB7	10,468	1	0,306
QB8	0,0799	1	0,777
QB9	0,1771	1	0,674
QB10	0,1789	1	0,672

Os resultados na Tabela 22 revelam que não há significância estatística entre as respostas dos estudantes para o sequenciamento por AG multiobjetivo e aleatório, dado que em nenhuma das questões o índice p está abaixo de 0,05. A seguir, são detalhadas as respostas para as questões QB7, QB8, QB9 e QB10, comparando as respostas entre os grupos de participantes *experimento* (sequenciamento por AG multiobjetivo) e *controle* (sequenciamento aleatório), quando pertinente. Nas figuras 19, 20, 21 e 22, além da comparação por grupos de experimento, é exibida a comparação geral dos participantes e separada por eixo RASI predominante do perfil do estudante.

³ Kruskal, W. H., & Wallis, W. A. (1952). Use of ranks in one-criterion variance analysis. *Journal of the American statistical Association*, Vol. 47, N. 260, pp. 583–621.

As figuras 19 e 20 condizem às questões QB7 e QB8 respectivamente. A intenção dessas questões é verificar quais as impressões dos participantes acerca da quantidade de atividades recebida. Esse quesito está diretamente relacionado à eficácia da função objetivo FO_2 do AG, dado que busca-se ajustar a quantidade de ações sequenciadas conforme o perfil do estudante.

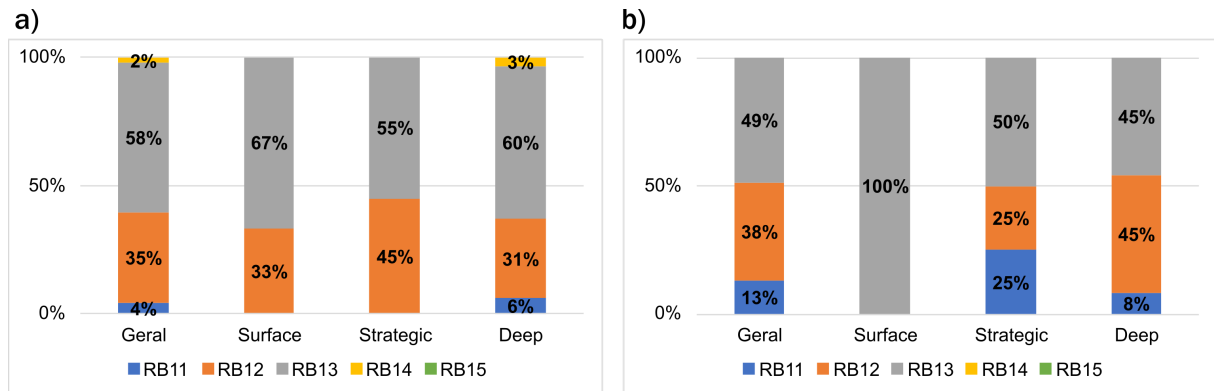


Figura 19 – Respostas para a questão “Você acredita que a quantidade de atividades é:”
a) sequenciamento por AG multiobjetivo | b) sequenciamento aleatório

Na Figura 19, a resposta “*Suficiente*” (RB13) representa satisfação máxima do participante em relação à quantidade de atividades recomendada. As respostas que mais contrariam essa sensação de satisfação são “*Muito Alta*” (RB11) e “*Muito Baixa*” (RB15). Na comparação entre as figuras 19a (sequenciamento por AG multiobjetivo) e Figura 19b (sequenciamento aleatório), é possível notar que a primeira apresenta melhores resultados que a segunda, visto que mais participantes responderam “*Suficiente*” na Figura 19a do que na Figura 19b em quase todos os grupos. Esse resultado não se sustentou apenas em relação ao grupo “*Surface*”, pois na Figura 19b, que apresentou melhor resultado, houve apenas um participante com o perfil “*Surface*” que respondeu ao questionário de satisfação sobre a sequência aleatória recebida e essa baixa quantidade de participantes pode gerar distorções nas análises.

Também na Figura 19, é possível observar uma tendência de menos respostas “*Muito Alta*” (RB11) e “*Muito Baixa*” (RB15) na recomendação de atividades sequenciadas por AG (Figura 19a) do que na recomendação por sequenciamento aleatório (Figura 19b). Esses resultados sugerem a predileção dos participantes pela recomendação proposta pelo AG multiobjetivo, em relação à quantidade de atividades recomendada. Com o intuito de auxiliar na verificação da qualidade das respostas aos questionários, foi realizada uma segunda pergunta (QB8) relativa à percepção dos participantes acerca da quantidade de atividades recomendada. Os resultados das respostas é apresentado na Figura 20.

Em relação à questão QB8, as respostas que refletem maior insatisfação dos participantes com relação à recomendação recebida são “*Concordo*” (RB16) e “*Discordo*” (RB20).

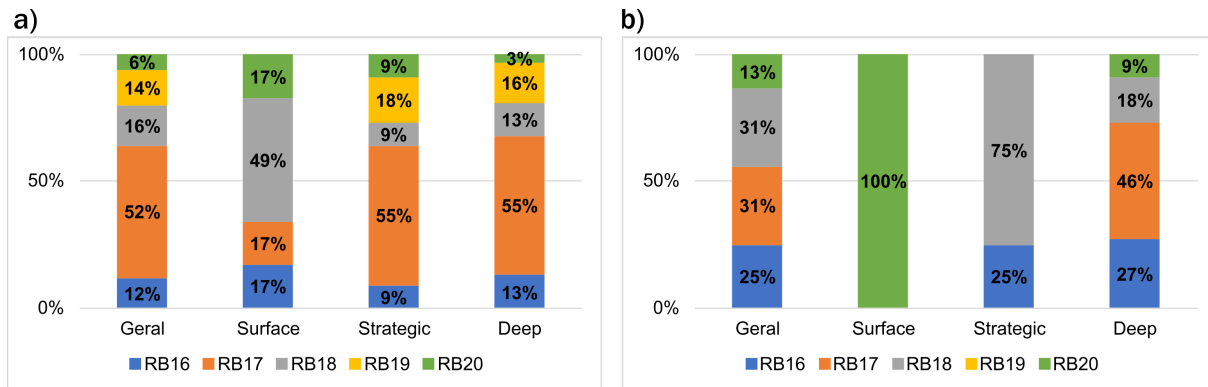


Figura 20 – Respostas para a questão "O número total de atividades recomendadas é muito elevado."

a) sequenciamento por AG multiobjetivo | b) sequenciamento aleatório

Sob essa perspectiva, é possível notar que na recomendação gerada a partir do sequenciamento por AG multiobjetivo, a insatisfação dos participantes é menor que na recomendação gerada pelo sequenciamento aleatório. Esse resultado confirma os resultados obtidos nas respostas da questão QB7 e reafirmam a melhor eficácia do AG em relação à quantidade de ações sequenciadas para o estudante.

Na Figura 21, foram compiladas as respostas para a questão QB9 que trata do quão confortável os estudantes consideram as atividades para lhes conduzir na aprendizagem. Tal questão está diretamente relacionada com a eficácia do objetivo 1 (FO_1) do AG, visto que esse personaliza o sequenciamento de ações pedagógicas de acordo com perfil RASI do estudante.




Figura 21 – Respostas para a questão "A sequência de atividades é confortável para lhe conduzir no aprendizado de um novo conteúdo ou disciplina."

a) sequenciamento por AG multiobjetivo | b) sequenciamento aleatório

Na Figura 21, as respostas que indicam o melhor e o pior grau de satisfação do participante são "Concordo" (RB16) e "Discordo" (RB20), respectivamente. Comparando as respostas "Concordo" (RB16) entre as figuras 21a (sequenciamento por AG multiobjetivo)

e 21b (sequenciamento aleatório), é possível notar que os percentuais são maiores para o sequenciamento aleatório. Entretanto, ao agrupar essas respostas em “*Concordo*” (RB16) e “*Concordo Parcialmente*” (RB17), é notória a maior predileção dos participantes pela recomendação sequenciada a partir do AG multiobjetivo. Observa-se ainda que não é possível considerar essa comparação entre os dados agrupados por “*Surface*”, dado que no grupo *controle* (Figura 21b), houve apenas um participante com esse eixo predominante.

Na Figura 22 são sintetizadas as respostas para a questão QB10, que trata da probabilidade dos participantes realizarem todas as atividades recomendadas. Essa questão avalia tanto o primeiro quanto o segundo objetivo (FO_1 e FO_2 , respectivamente) do AG, pois de maneira indireta, esta intenção em realizar todas as atividades está relacionada à adequação da recomendação ao perfil do estudante e também à quantidade de atividades que lhe é oferecida.

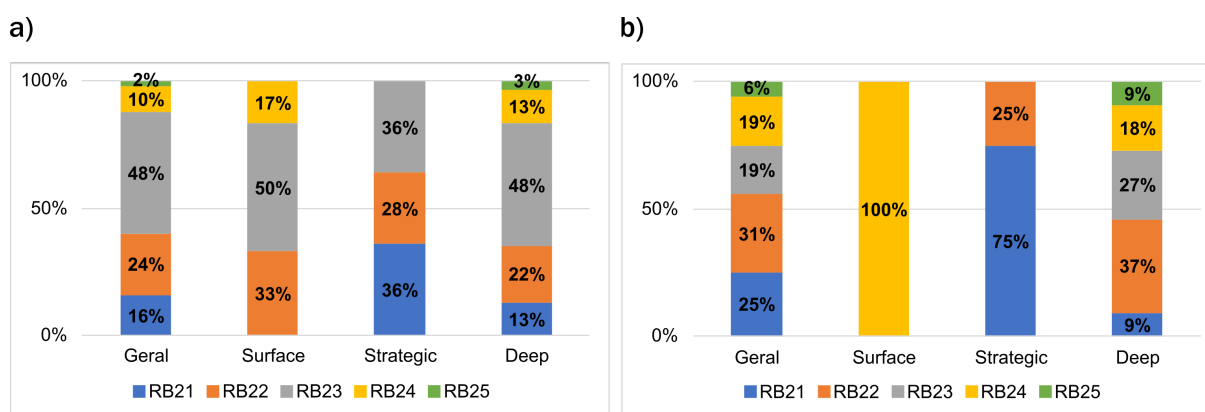


Figura 22 – Respostas para a questão “Qual a chance de você realizar todas as atividades dessa sequência?”

a) sequenciamento por AG multiobjetivo | b) sequenciamento aleatório

As respostas que refletem o melhor grau de satisfação dos participantes com a sequência apresentada na Figura 22, são “*Muito Alta*” (RB21), “*Alta*” (RB22) e “*Moderada*” (RB23). Na maioria dos agrupamentos a soma dos percentuais dessas respostas são melhores na Figura 22a (sequenciamento por AG multiobjetivo) do que na Figura 22b (sequenciamento aleatório). No agrupamento pelo perfil *Surface* não é possível fazer tal comparação, dado que houve apenas uma resposta na Figura 22b e no agrupamento pelo perfil *Strategic* os percentuais para as respostas “*Muito Alta*” (RB21), “*Alta*” (RB22) são maiores para o sequenciamento aleatório (Figura 22b). Tal resultado sugere a necessidade de revisar o AG multiobjetivo proposto em trabalhos futuros, com especial atenção para o perfil *Strategic*.

Nas figuras 23 e 24 são apresentadas as taxas de maior e menor preferência das atividades, conforme dados coletados a partir das questões QB11 e QB12. Em cada uma das questões, os estudantes foram convidados a listar três atividades que mais e três que

menos preferem. Na Figura 23, as respostas estão separadas entre os participantes que receberam a recomendação originada a partir do sequenciamento por AG multiobjetivo e do aleatório.




Figura 23 – Taxa de preferência das atividades por método de sequenciamento.
a) sequenciamento por AG multiobjetivo | b) sequenciamento aleatório.

Na Figura 23a (AG multiobjetivo), há 9 ocorrências onde a taxa de atividade mais preferida supera a de menos preferida. Já na Figura 23b (aleatório), a ocorrência foi de 10 vezes. Além disso, na comparação entre as figuras 23a e 23b, 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.

Na Figura 24, as respostas sobre a preferência dos estudantes em relação às atividades recebidas estão separadas entre os participantes nas modalidades de ensino EaD e presen-

cial para a recomendação de atividades a partir do sequenciamento de ações pedagógicas por AG multiobjetivo. Dentre os 48 participantes que receberam a recomendação baseada no AG e responderam às perguntas QB11 e QB12, 24 são da modalidade EaD e 24 são da modalidade presencial. Cabe também ressaltar que devido à pandemia de COVID-19, os participantes da modalidade presencial estavam em regime remoto de atividades (MANCEBO, 2020).

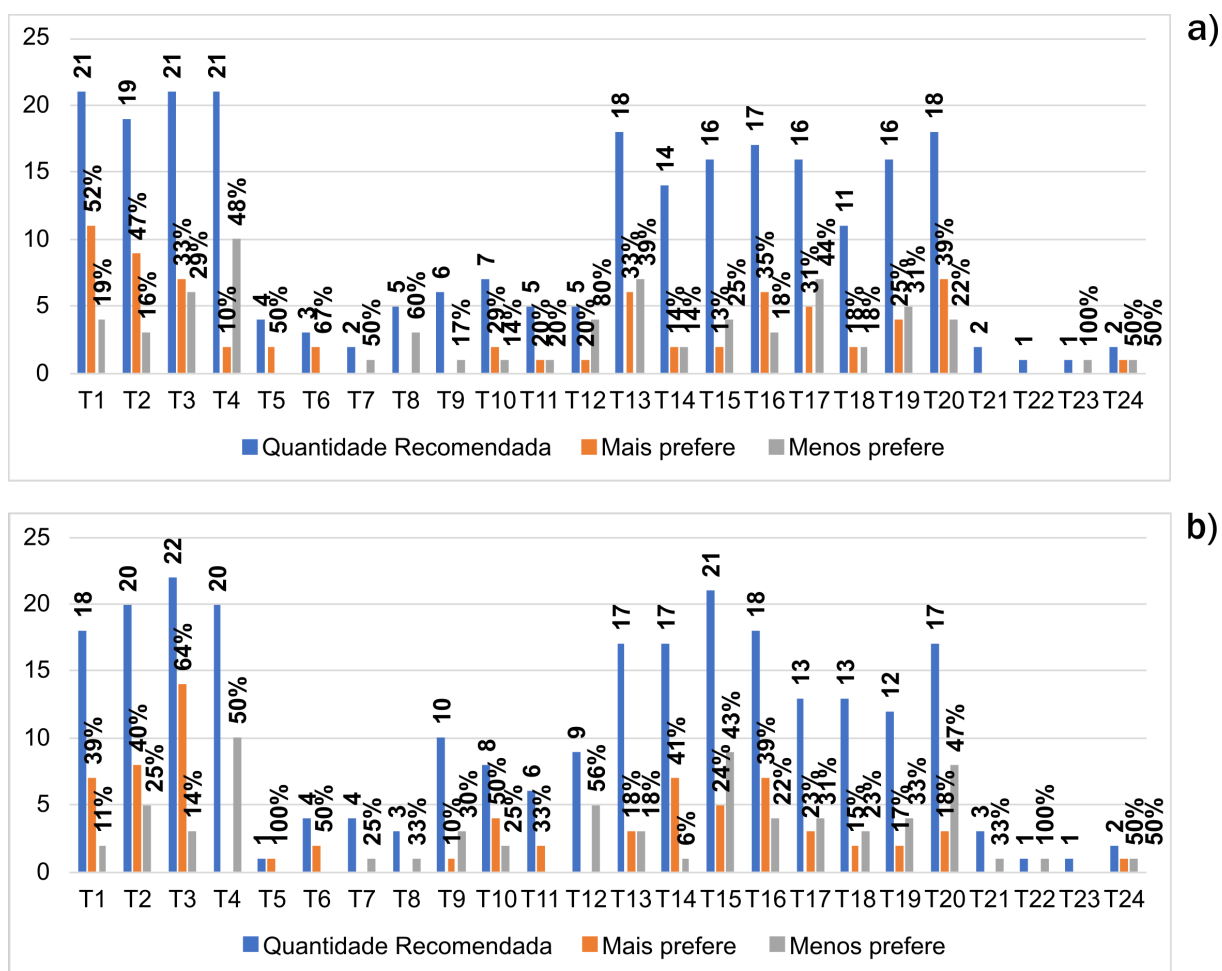


Figura 24 – Taxa de preferência das atividades por modalidade de ensino (EaD; presencial/remoto).

Na comparação entre as figuras 24a (EaD) e 24b (presencial), a taxa de atividades mais preferidas para o EaD supera o presencial em 8 vezes e o contrário ocorre 10 vezes. Além disso, na Figura 24a, a taxa de atividades mais preferidas supera a taxa de atividades menos preferidas em 8 ocorrências. Já na Figura 24b, este comportamento se repete 9 vezes. A pouca diferença entre os índices, não permite afirmar haver maior ou menor predileção da recomendação atividades digitais por estudantes de modalidades distintas de ensino (EaD / presencial).

Foi conduzida uma análise correlacional entre respostas sobre a percepção do estudante em relação à necessidade de variação nas categorias RASI (QB1, QB2, QB3, QB4, QB5

e QB6) e a satisfação sobre a recomendação gerada a partir sequenciamento por AG multiobjetivo (QB7, QB8, QB9 e QB10). Ao todo, 36 participantes responderam ambos os grupos de perguntas. Nessa análise, foram retornadas correlações estatisticamente significativas apenas entre o primeiro grupo de questões (QB1, ..., QB6), conforme Tabela 23. Neste trabalho, a interpretação dos índices de correlação (coeficiente ρ) dados pela Tabela 23 segue os parâmetros definidos em Baba, Vaz e Costa (2014). Além disso, foram observadas as correlações estatisticamente significativas, ou seja, cujo p -valor seja menor que 0.05.

Tabela 23 – Análise correlacional entre as questões QB1, QB2, QB3, QB4, QB5 e QB6.

		Q1	Q2	Q3	Q4	Q5	Q6
QB1	Coeficiente ρ	—					
	p -valor	—					
QB2	Coeficiente ρ	0.075	—				
	p -valor	0.664	—				
QB3	Coeficiente ρ	-0.196	0.545	—			
	p -valor	0.253	<.001	—			
QB4	Coeficiente ρ	0.159	0.023	0.076	—		
	p -valor	0.355	0.895	0.660	—		
QB5	Coeficiente ρ	0.010	0.046	0.157	0.657	—	
	p -valor	0.953	0.791	0.360	<.001	—	
QB6	Coeficiente ρ	-0.215	0.048	0.301	0.333	0.704	—
	p -valor	0.209	0.782	0.074	0.047	<.001	—

Na comparação entre QB2 e QB3, ocorreu uma correlação positiva moderada, ou seja, há uma tendência de que o estudante considere que os índices para os eixos *Strategic* e *Deep* devem variar em conjunto, para mais ou para menos. Uma interpretação possível para tal situação é do estudante estar num processo de evolução cognitiva, onde há uma transição do perfil *Strategic* (menos abstrato), para o perfil *Deep* (mais abstrato). Outro fator que reforça tal suspeita é que quantitativamente 36,1% dos participantes apresenta variação de até 5 pontos percentuais entre os índices *Strategic* e *Deep*. Além disso, a análise entre QB5 e QB6, complementares à QB2 e QB3, apresentou uma correlação positiva forte, enfatizando mais uma vez a tal interpretação.

Na análise entre QB4 e QB5, há uma correlação positiva moderada. Essas perguntas dizem respeito aos estudantes concordarem ou não com os índices *Surface* e *Strategic*, respectivamente. Nesse caso, a observação é de que há uma tendência de que o estudante concorde/discorde desses dois índices simultaneamente. Tal observação também sugerem uma situação de transição entre perfis RASI e 1/3 dos participantes apresentam variação de até 5 pontos percentuais para os índices *Surface* e *Strategic*.

Ainda na Tabela 23, a comparação entre QB4 e QB6 revela uma correlação positiva fraca. Nesse caso, a tendência é de que os participantes da pesquisa tendem concordar/discordar dos índices *Surface* e *Deep*, simultaneamente, porém em menor grau do que

nas comparações anteriores. Isso revela uma maior definição do perfil RASI por parte do estudante entre os eixos *Surface* e *Deep*.

A segunda análise correlacional foi realizada entre as respostas QB7, ..., QB10, considerando os 49 participantes que responderam o questionário de satisfação acerca da recomendação recebida a partir do sequenciamento por AG multiobjetivo, conforme Tabela 24.

Tabela 24 – Análise correlacional entre as questões QB7, QB8, QB9 e QB10, para o sequenciamento por AG multiobjetivo.

		QB7	QB8	QB9	QB10
QB7	Coefficiente ρ	—			
	<i>p</i> -valor	—			
QB8	Coefficiente ρ	-0.275	—		
	<i>p</i> -valor	0.056	—		
QB9	Coefficiente ρ	-0.040	-0.011	—	
	<i>p</i> -valor	0.787	0.939	—	
QB10	Coefficiente ρ	0.093	-0.287	0.371	—
	<i>p</i> -valor	0.524	0.045	0.009	—

Na Tabela 24, a correlação entre QB8 e QB10 é negativa fraca. Nesse aspecto, observamos que na percepção do estudante, quanto maior a quantidade de atividades, menor a possibilidade deste realizar todas as atividades da sequência. Essa correlação ressalta a necessidade de refinar o mecanismo de ajuste da quantidade de ações sequenciadas (FO_2 no AG). Já a correlação observada entre QB9 e QB10 é positiva fraca, ou seja, quanto mais/menos confortável o estudante considera a sequência de atividades, maior/menor a possibilidade deste realizar todas as atividades. Este aspecto ressalta a importância do objetivo 1 do AG, que ajusta a sequência de ações consoante o perfil RASI do estudante.

Uma terceira análise correlacional foi conduzida, semelhante à segunda, porém utilizando apenas as respostas do questionário de satisfação do estudante, relacionadas ao sequenciamento aleatório de ações pedagógicas. Tais resultados são apresentados na Tabela 25.

Tabela 25 – Análise correlacional entre as questões QB7, QB8, QB9 e QB10, para o sequenciamento aleatório.

		QB7	QB8	QB9	QB10
QB7	Coefficiente ρ	—			
	<i>p</i> -valor	—			
QB8	Coefficiente ρ	0.751	—		
	<i>p</i> -valor	<0.001	—		
QB9	Coefficiente ρ	-0.207	-0.062	—	
	<i>p</i> -valor	0.442	0.820	—	
QB10	Coefficiente ρ	-0.332	-0.217	0.371	—
	<i>p</i> -valor	0.209	0.419	0.158	—

Na Tabela 25, há uma correlação positiva forte entre QB7 e QB8. Nesse sentido a quantidade de ações é um fator que chamou a atenção do estudante, visto que no sequenciamento aleatório a quantidade mínima de atividades recomendadas foi 6, a máxima foi 17 e a média foi 14. Se compararmos esses valores com o sequenciamento por AG multiobjetivo, temos a quantidade mínima de 9, a máxima de 13 e a média de 10 atividades por estudante. Tal comparação revela que o ajuste da quantidade de ações sequenciadas promovido pelo AG multiobjetivo tem impacto positivo na percepção do estudante sobre a sequência de atividades.

Também foi realizada uma quarta análise correlacional entre as questões QB1, ..., QB10, porém apenas para os estudantes com eixo *Deep* predominante no perfil RASI, conforme descrito na Tabela 26. Optou-se por realizar uma análise específica para o eixo *Deep*, pois há mais participantes (25) nesse grupo.

Tabela 26 – Análise correlacional entre as questões QB1, QB2, QB3, QB4, QB5, QB6, QB7, QB8, QB9 e QB10 entre os participantes com perfil *Deep*.

		QB1	QB2	QB3	QB4	QB5	QB6	QB7	QB8	QB9	QB10
QB1	ρ^*	—									
	p^{**}	—									
QB2	ρ^*	0.121	—								
	p^{**}	0.565	—								
QB3	ρ^*	-0.261	0.318	—							
	p^{**}	0.208	0.122	—							
QB4	ρ^*	0.006	-0.057	0.146	—						
	p^{**}	0.977	0.788	0.486	—						
QB5	ρ^*	-0.125	-0.166	0.181	0.719	—					
	p^{**}	0.551	0.427	0.387	<.001	—					
QB6	ρ^*	-0.309	-0.132	0.359	0.415	0.610	—				
	p^{**}	0.133	0.528	0.078	0.039	0.001	—				
QB7	ρ^*	0.122	0.187	0.066	-0.099	-0.210	-0.190	—			
	p^{**}	0.561	0.371	0.755	0.639	0.314	0.363	—			
QB8	ρ^*	-0.106	-0.319	-0.182	-0.112	-0.136	-0.406	0.249	—		
	p^{**}	0.614	0.120	0.384	0.593	0.516	0.044	0.229	—		
QB9	ρ^*	-0.202	-0.062	0.227	-0.139	0.085	0.144	-0.175	0.150	—	
	p^{**}	0.333	0.769	0.276	0.508	0.686	0.493	0.402	0.475	—	
QB10	ρ^*	0.101	0.294	0.320	-0.074	-0.020	0.271	-0.098	-0.304	0.466	—
	p^{**}	0.630	0.154	0.119	0.724	0.925	0.190	0.640	0.139	0.019	—

Legenda: * Coeficiente ρ ; ** p -valor.

Conforme Tabela 26, a correlação entre QB4 e QB5 é positiva forte e diz respeito à percepção do estudante acerca dos índices obtidos para os perfis *Surface* e *Strategic*, evidenciando, como dito anteriormente, o cenário de estudantes que estejam numa situação de transição entre os perfis. A correlação entre Q4 e Q6 é positiva moderada e diz respeito à percepção dos estudantes sobre os índices obtidos para os eixos *Surface* e *Deep*. Já a

correlação entre QB5 e QB6, como dito anteriormente, pode caracterizar uma situação onde o estudante esteja na transição do perfil *Strategic* para o *Deep*.

Ainda na Tabela 26, a correlação entre QB6 e QB8 é negativa moderada e sugere que quanto maior o grau de aprovação com o índice obtido para o eixo *Deep*, menor a insatisfação com a quantidade de atividades recomendada, no que lhe concerne, a maior discordância com o índice *Deep* condiz com maior insatisfação com a quantidade de atividades. Por fim, a correlação entre QB9 e QB10 é positiva moderada, indicando que o maior/menor conforto do estudante com a sequência de atividades, traduz em maior/menor possibilidade de realizar todas as atividades.

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. Realmente o AG é benéfico para o processo de recomendação pedagógica e aproxima a quantidade de ações dos valores referenciais de tamanho para a sequência. Diante de tais constatações, é possível aceitar a hipótese H1 e rejeitar H0, ou seja, “*O sequenciamento de ações pedagógicas baseadas na Taxonomia de Bloom, automatizado por Algoritmo Genético e personalizado segundo o perfil RASI produz satisfação ao estudante*”.

Tal constatação acerca das hipóteses foi possível a partir das respostas às questões de pesquisa. Em relação à QPA1 (*É possível associar as teorias entre TB e RASI para sequenciar ações pedagógicas?*), a partir dos experimentos realizados nas etapas 1 e 2, tanto para o AG mono-objetivo quanto multiobjetivo, os resultados mostraram a viabilidade em associar o arcabouço teórico constituído por TB e RASI para produzir sequências de ações pedagógicas.

Relativo à QPA2 (*O sequenciamento de ações pedagógicas pode ser delineado como um problema de otimização por conseguinte, abordado com AG?*), o resultado dos algoritmos (mono-objetivo e multiobjetivo) mostram ser possível tratar tal problema sob o viés de otimização, onde há um estado inicial, sendo esse o perfil RASI do estudante, e há uma sequência de ações possíveis que conduzem o aprendizado do estudante a um estado desejável. Na maioria dos casos, foi possível produzir sequências que permeiam a ideia de evolução do estado cognitivo de LOCS para HOCS, respeitando o perfil cognitivo RASI do estudante.

A QPA3 (*Qual a percepção de estudantes sobre a recomendação pedagógica baseada na TB, personalizada segundo o perfil RASI e promovida a partir do sequenciamento automatizado por AG?*) também foi respondida, pois, na etapa 3 dos experimentos para ambos os algoritmos 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. Embora não

tenham conhecimento das teorias que guiaram esse processo, percebeu-se que as recomendações não trouxeram desconforto aos estudantes e muitos realizariam essas atividades recomendadas conforme a Taxonomia de Bloom e personalizadas segundo o perfil RASI.

Por fim, a questão de pesquisa QP (*É possível produzir recomendações pedagógicas independentes da estrutura curricular?*) também foi respondida, dado que todas as etapas dos experimentos não consideraram um conteúdo específico. Nota-se que a TB é uma descrição de um processo cognitivo que independe de conteúdo e estruturas curriculares. Sendo assim, tais recomendações não requereram informações acerca de conteúdo ou estrutura curricular.

Ademais, compreendemos os resultados descritos como positivos, dado que tanto os resultados do sequenciamento por AG, quanto o 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. Analisando o mapeamento estabelecido entre a TB e o RASI, o sequenciamento atende s necessidades dos perfis de estudantes em conforto, apesar de parte dos estudantes considerarem a quantidade de atividades elevada. Nesse aspecto, há necessidade de investigação e melhoria da proposta no que tange os parâmetros de otimização da quantidade de ações sequenciadas.

Tratar como um problema de otimização o sequenciamento de ações pedagógicas 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 sequência 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 pedagógicas desenvolvido neste trabalho.

Cabe evidenciar que os experimentos apresentados foram realizados no período em que a pandemia de COVID-19 afetou drasticamente a sociedade, em especial a educação. Logo, tais experimentos foram influenciados em menor grau, pois a comunicação com os participantes se fez parcialmente comprometida, devido às adaptações e limitações percebidas por estudantes nesse período no que tange os processos de ensino e de aprendizagem (CERQUEIRA, 2020). A participação em cada etapa dos experimentos deu-se de forma voluntária por parte dos estudantes, a partir de um convite enviado por correio eletrônico. Em consequência, lograr a adesão dos participantes em todas as etapas, tornou-se um desafio, dado que a forma de comunicação foi limitada ao prover motivação necessária.

Conclusões

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 Taxonomia de Bloom. O sequenciamento adotou uma abordagem de Planejamento Automatizado, implementado utilizando um Algoritmo Genético Multiobjetivo. As características que compuseram o modelo do estudante para personalização do sequenciamento foram o *Revised Approaches to Studying Inventory (RASI)* e as preferências do estudante. As atividades recomendadas a partir do sequenciamento foram aquelas dadas pela Taxonomia Digital de Bloom, possibilitando flexibilidade em relação a futuras implementações e plataformas de aprendizagem, como Ambientes Virtuais de Aprendizagem, por exemplo.

Esta proposta se figura como uma alternativa à recomendação pedagógica focada em conteúdo ou objetos de aprendizagem, pois é independente da estrutura curricular e considera o processo cognitivo do estudante como o foco principal na personalização do sequenciamento. Note ainda que tal ação é comumente realizada manualmente, tornando o processo demorado. Logo, nossa abordagem automatiza esse processo e pode contribuir para melhorias na aprendizagem do estudante.

A realização de experimentos, incluindo estudantes reais, forneceram subsídios para analisar as questões de pesquisa levantadas por este trabalho. Tais análises evidenciam que nossa abordagem promissora, ao prover um arcabouço capaz de fomentar a recomendação pedagógica com enfoque no processo cognitivo do estudante.

5.1 Contribuições

Conforme evidenciado em Costa et al. (2019), a maioria dos trabalhos relacionados à recomendação pedagógica personalizada, delineiam esse processo baseado na estrutura curricular de um curso ou em Objetos de Aprendizagem, por meio do sequenciamento curricular ou de rotas de aprendizagem. A partir desse aspecto, esta proposta investigou uma alternativa ao sequenciamento de ações pedagógicas pautadas pelo processo cognitivo

do estudante. Tal resposta foi encontrada na base teórica fornecida pela Taxonomia de Bloom, que delinea o processo cognitivo partindo de ações concretas (LOCS) para abstratas (HOCS).

A obtenção de características do estudante que pudessem estabelecer uma ponte com o processo cognitivo moldado pela Taxonomia de Bloom foi possível, graças ao RASI, que permite estruturar o perfil cognitivo do estudante sob três eixos que, assim como na Taxonomia de Bloom, apresenta evolução partindo de LOCS para HOCS. Nesse ponto, uma contribuição desse trabalho foi a realização do mapeamento entre a Taxonomia de Bloom e o RASI. Isso tornou possível estabelecer uma relação entre sequências de ações pedagógicas dadas pela Taxonomia de Bloom e o RASI, viabilizando então a automatização do processo de sequenciamento personalizado de ações pedagógicas.

A modelagem do sequenciador de ações seguiu a perspectiva do Planejamento Automatizado, considerando o perfil do estudante (RASI) como o estado inicial do meu problema e a partir das ações sequenciadas, o objetivo é proporcionar a evolução do estudante no espectro LOCS/HOCS. Para implementar o sequenciador, foi desenvolvido um Algoritmo Genético Multiobjetivo que tem como objetivos o perfil RASI do estudante e suas preferências em relação à quantidade de atividades. As funções-objetivo criadas para este AG também são duas contribuições diretas desse trabalho, uma vez que permitem mensurar de maneira automatizada uma sequência de ações pedagógicas em relação à adequação ao perfil RASI do estudante.

Para tornar viável a recomendação a partir do sequenciamento personalizado de ações pedagógicas, foi necessária a associação atividades digitais a essas ações. Buscamos na Taxonomia Bloom Digital um modelo flexível de atividades que permitiram tal recomendação. Para isso, como outra contribuição deste trabalho, refinamos o mapeamento das atividades propostas por Churches (2010), passando a listagem de atividades de uma para duas dimensões da Taxonomia de Bloom, ou seja, mapeamos tais atividades considerando as dimensões do processo cognitivo e do conhecimento.

De maneira geral, o desenvolvimento deste trabalho demonstrou a eficácia do relacionamento entre as teorias RASI e TB, com o propósito de realizar recomendações pedagógicas além da viabilidade das atividades digitais da TBD sob a ótica da análise bidimensional definida na TB. Tal arcabouço proporcionou realizar recomendações de atividades a partir do sequenciamento de ações pedagógicas, sendo uma alternativa às recomendações pedagógicas baseadas em restrições estruturais de currículos ou encadeamento de conteúdos. Nesse sentido, esta proposta realiza a recomendação pedagógica do ponto de vista do processo cognitivo do estudante e corrobora a possibilidade de realizar sequenciamento de ações pedagógicas estruturadas segundo a TB, por meio de PA apoiado por AG, de modo a contemplar o perfil RASI do estudante.

5.2 Contribuições em Produção Bibliográfica

Esta pesquisa se iniciou em março de 2018. O tema de pesquisa foi definido em março de 2019. Desde o início desta pesquisa, até a data da defesa, os seguintes trabalhos relacionados diretamente ao tema foram produzidos, com destaque para o trabalho Costa e Fernandes (2020), premiado como *best paper* na Trilha 4 do Simpósio Brasileiro de Informática na Educação (SBIE) no ano de 2020:

- ❑ **COSTA, N. T., DE ALMEIDA, D. J., OLIVEIRA, G. P., FERNANDES, M. A.** Customized Pedagogical Recommendation Using Automated Planning for Sequencing Based on Bloom's Taxonomy. *International Journal of Distance Education Technologies (IJDET)*. 2022 (Vol. 20, No. 1, p. 1-19). (COSTA et al., 2022)
- ❑ **DA COSTA, N. T., 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*. 2021 (Vol. 29, No. 1, p. 485-501). (COSTA; FERNANDES, 2021b)
- ❑ **DA COSTA, N. T., FERNANDES, M. A.** Sequenciamento de Ações Pedagógicas por Algoritmo Genético Utilizando Taxonomia de Bloom e ASSIST. In 2020 Anais do XXXI Simpósio Brasileiro de Informática na Educação - SBIE (vOL. 31, p. 1273-1282). SBC. (COSTA; FERNANDES, 2020)
- ❑ **COSTA, N., JÚNIOR, C. P., FERNANDES, M.** Recomendação de ações pedagógicas utilizando planejamento automático e taxonomia digital de Bloom. In 2019 Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE) (Vol. 30, No. 1, p. 1531). SBC. (COSTA; JÚNIOR; FERNANDES, 2019)
- ❑ **COSTA, N., JUNIOR, C. P., ARAUJO, R., FERNANDES, M.** Application of AI Planning in the Context of e-Learning. In 2019 IEEE 19th International Conference on Advanced Learning Technologies (ICALT) (Vol. 2161, pp. 57-59). IEEE. (COSTA et al., 2019)

Durante o período de doutorado, foram realizadas outras produções científicas que contribuíram de maneira indireta para esta pesquisa.

- ❑ **ALMEIDA, D.; FERNANDES, M.; TORREZÃO DA COSTA, N.** Sequencing and Recommending Pedagogical Activities from Bloom's Taxonomy using RASI and Multi-objective PSO. In *Proceedings of the 14th International Conference on Computer Supported Education* (Vol. 2, No. 1, p. 105-116). (ALMEIDA.; FERNANDES.; Torrezão da Costa., 2022).

- ❑ FERREIRA, J. P. B., de TORRES MASCHIO, P., DE SANTANA, T. S., **DA COSTA, N. T.**, JUNIOR, C. P. Análise de Vídeos como Recurso Educacional em Plataforma Não Formal de Aprendizagem. In Anais do XXXI Simpósio Brasileiro de Informática na Educação. 2020 p. 1733-1742. SBC. (FERREIRA et al., 2020)
- ❑ MASCHIO, P., VIEIRA, M. A., **COSTA, N.**, DE MELO, S., JÚNIOR, C. P. Um panorama acerca da mineração de dados educacionais no Brasil. In Brazilian Symposium on Computers in Education 2018 (Simpósio Brasileiro de Informática na Educação-SBIE) (Vol. 29, No. 1, p. 1936). SBC. (MASCHIO et al., 2018)

5.3 Trabalhos Futuros

Uma proposta de evolução deste trabalho é em relação às possibilidades de atividades digitais passíveis de associação às ações pedagógicas sequenciadas. Atualmente, uma limitação é haver uma correspondência de 1:1 em relação às ações pedagógicas e às atividades digitais. Em trabalhos futuros, espera-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.

Este trabalho modela o estudante considerando seu perfil RASI e sua preferência em relação à quantidade de atividades. O uso dessas características objetiva aumentar a satisfação do estudante e com isso seu maior engajamento com a sequência de atividades proposta. Em trabalhos futuros, o intuito é ampliar essas características do estudante, de modo a observar os impactos disso na satisfação do estudante. Além disso, o uso de outras técnicas de otimização multi-objetivo podem ser exploradas.

A arquitetura desta proposta permite sua implementação numa plataforma de aprendizagem, como um Ambiente Virtual de Aprendizagem, por exemplo. Como trabalho futuro, estima-se realizar tal implementação na plataforma Moodle, de modo a avaliar a eficácia desta proposta em circunstâncias reais de ensino-aprendizagem. Tal evolução deste trabalho, poderá contribuir inclusive com melhorias no processo de personalização, dado que nessas plataformas, há uma variedade de metadados do estudante, que podem ser utilizados nesse processo.

Referências

- AGBONIFO, O. C.; OLANREWaju, A. O. Genetic algorithm-based curriculum sequencing model for personalised e-learning system. **International Journal of Education and Management Engineering**, v. 5, n. 8, p. 27–35, 2018. <<https://doi.org/10.5815/ijmecs.2018.05.04>>.
- ALMEIDA., D.; FERNANDES., M.; Torrezão da Costa., N. Sequencing and recommending pedagogical activities from bloom's taxonomy using rasi and multi-objective pso. In: INSTICC. **Proceedings of the 14th International Conference on Computer Supported Education - Volume 2: CSEDU**,. [S.l.]: SciTePress, 2022. p. 105–116. ISBN 978-989-758-562-3. ISSN 2184-5026.
- ALONSO, C.; GALLEGO, D.; HONEY, P. **Los estilos de aprendizaje. Procedimientos de diagnóstico y mejora (4ta edición)**. Bilbao: Ediciones Mensajero. 1999.
- ARIYARATNE, M.; FERNANDO, T. A comparative study on nature inspired algorithms with firefly algorithm. **International Journal of Engineering and Technology**, Citeseer, v. 4, n. 10, p. 611–617, 2014.
- BABA, R. K.; VAZ, M. S. M. G.; COSTA, J. d. Correção de dados agrometeorológicos utilizando métodos estatísticos. **Revista Brasileira de Meteorologia**, SciELO Brasil, v. 29, n. 4, p. 515–526, 2014. <<https://doi.org/10.1590/0102-778620130611>>.
- BLOOM, B. et al. **Taxonomy of educational objectives: The classification of educational goals. Handbook 1: Cognitive domain**. 1st. ed. [S.l.]: David McKay, 1984.
- BROWN, S. et al. Approaches and study skills inventory for students (assist) in an introductory course in chemistry. **Journal of University Teaching & Learning Practice**, The University of Wollongong, 2015. <<https://doi.org/10.53761/1.12.3.6>>.
- CALLAGHAN-KORU, J. A.; AQIL, A. R. Theory-informed course design: Applications of bloom's taxonomy in undergraduate public health courses. **Pedagogy in Health Promotion**, SAGE Publications Sage CA: Los Angeles, CA, p. 2373379920979684, 2020. <<https://doi.org/10.1177/2373379920979684>>.
- CAMILLERI, A. F.; EHLERS, U. D.; PAWLOWSKI, J. **State of the art review of quality issues related to open educational resources (OER)**. [S.l.]: Luxembourg: Publications Office of the European Union, 2014.

- CAPUTI, V.; GARRIDO, A. Student-oriented planning of e-learning contents for moodle. **Journal of Network and Computer Applications**, v. 53, p. 115 – 127, 2015. ISSN 1084-8045. <<https://doi.org/10.1016/j.jnca.2015.04.001>>. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S108480451500065X>>.
- CERQUEIRA, B. R. S. de. Educação no ensino superior em tempos de pandemia. **Olhar de Professor**, Universidade Estadual de Ponta Grossa, v. 23, p. 1–5, 2020. <<https://doi.org/10.5212/OlharProfr.v.23.2020.16175.209209226867.0616>>.
- CHRISTUDAS, B. C. L.; KIRUBAKARAN, E.; THANGAIAH, P. R. J. An evolutionary approach for personalization of content delivery in e-learning systems based on learner behavior forcing compatibility of learning materials. **Telematics and Informatics**, Elsevier, v. 35, n. 3, p. 520–533, 2018. <<https://doi.org/10.1016/j.tele.2017.02.004>>.
- CHURCHES, A. **Bloom’s digital taxonomy**. [S.l.]: Australian School Library Association NSW Incorporated, 2010.
- CIMATTI, A.; PISTORE, M.; TRAVERSO, P. Automated planning. **Foundations of Artificial Intelligence**, Elsevier, v. 3, p. 841–867, 2008. <[https://doi.org/10.1016/S1574-6526\(07\)03022-2](https://doi.org/10.1016/S1574-6526(07)03022-2)>.
- CORDOVA, D. I.; LEPPER, M. R. Intrinsic motivation and the process of learning: Beneficial effects of contextualization, personalization, and choice. **Journal of Educational Psychology**, v. 88, n. 4, p. 715 – 730, 1996. ISSN 1939-2176. <<https://doi.org/10.1037/0022-0663.88.4.715>>. Disponível em: <<https://psycnet.apa.org/fulltext/1996-06736-008.html>>.
- COSTA, N.; FERNANDES, M. Sequenciamento de ações pedagógicas por algoritmo genético utilizando taxonomia de bloom e assist. In: **Anais do XXXI Simpósio Brasileiro de Informática na Educação**. Porto Alegre, RS, Brasil: SBC, 2020. p. 1273–1282. ISSN 0000-0000. <<https://doi.org/10.5753/cbie.sbie.2020.1273>>. Disponível em: <<https://sol.sbc.org.br/index.php/sbie/article/view/12883>>.
- COSTA, N. et al. Application of ai planning in the context of e-learning. In: **International Conference on Advanced Learning Technologies (ICALT)**. [S.l.: s.n.], 2019. p. 57. <<https://doi.org/10.1109/ICALT.2019.00021>>.
- COSTA, N.; JÚNIOR, C. P.; FERNANDES, M. 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)**. [S.l.: s.n.], 2019. v. 30, p. 1531. <<https://doi.org/10.5753/cbie.sbie.2019.1531>>.
- COSTA, N. T. et al. Customized pedagogical recommendation using automated planning for sequencing based on bloom’s taxonomy. **International Journal of Distance Education Technologies (IJDET)**, IGI Global, v. 20, n. 1, p. 1–19, 2022. <<https://doi.org/10.4018/ijdet.296700>>.
- COSTA, N. T. da; FERNANDES, M. A. Sequenciamento de ações pedagógicas baseadas na taxonomia de bloom usando planejamento automatizado apoiado por algoritmo genético. **Revista Brasileira de Informática na Educação**, v. 29, p. 485–501, 2021. <<https://doi.org/10.5753/rbie.2021.29.0.485>>.

_____. Sequenciamento de ações pedagógicas baseadas na taxonomia de bloom usando planejamento automatizado apoiado por algoritmo genético. **Revista Brasileira de Informática na Educação**, v. 29, p. 485–501, 2021.

DUFF, A. The revised approaches to studying inventory (rasi) and its use in management education. **Active learning in higher education**, Sage Publications, v. 5, n. 1, p. 56–72, 2004. <<https://doi.org/10.1177/1469787404040461>>.

DWIVEDI, P.; KANT, V.; BHARADWAJ, K. K. Learning path recommendation based on modified variable length genetic algorithm. **Education and Information Technologies**, Springer, v. 23, n. 2, p. 819–836, 2018. <<https://doi.org/10.1007/s10639-017-9637-7>>.

ENGELBRECHT ANDRIES, P. **Computational intelligence: an introduction**. 2nd. ed. [S.l.]: John Wiley & Sons, 2007. ISBN 9780470035610.

ENTWISTLE, N.; HANLEY, M.; HOUNSELL, D. Identifying distinctive approaches to studying. **Higher education**, Springer, v. 8, n. 4, p. 365–380, 1979. <<https://doi.org/10.1007/BF01680525>>.

ENTWISTLE, N.; TAIT, H. 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**, 03 2013.

FELDER, R. M.; SILVERMAN, L. K. Learning and teaching styles in engineering education. **Engineering education**, v. 78, n. 7, p. 674–681, 1988.

FERRAZ, A.; BELHOT, R. V. et al. Taxonomia de bloom: revisão teórica e apresentação das adequações do instrumento para definição de objetivos instrucionais. **Gest. Prod., São Carlos**, v. 17, n. 2, p. 421–431, 2010. <<https://doi.org/10.1590/S0104-530X2010000200015>>.

FERREIRA, J. P. B. et al. Análise de vídeos como recurso educacional em plataforma não formal de aprendizagem. In: SBC. **Anais do XXXI Simpósio Brasileiro de Informática na Educação**. [S.l.], 2020. p. 1733–1742.

FOX, M.; LONG, D. Pddl+: Modeling continuous time dependent effects. In: **Proceedings of the 3rd International NASA Workshop on Planning and Scheduling for Space**. [S.l.: s.n.], 2002. v. 4, p. 34.

GARRIDO, A.; MORALES, L. E-learning and intelligent planning: Improving content personalization. **IEEE Revista Iberoamericana de Tecnologías del Aprendizaje**, v. 9, n. 1, p. 1–7, Feb 2014. ISSN 1932-8540. <<https://doi.org/10.1109/RITA.2014.2301886>>.

GARRIDO, A.; MORALES, L.; SERINA, I. On the use of case-based planning for e-learning personalization. **Expert Systems with Applications**, Elsevier, v. 60, p. 1–15, 2016. <<https://doi.org/10.1016/j.eswa.2016.04.030>>.

GARRIDO, A.; ONAINDIA, E. Assembling learning objects for personalized learning: An ai planning perspective. **IEEE Intelligent Systems**, v. 28, n. 2, p. 64–73, March 2013. ISSN 1541-1672. <<https://doi.org/10.1109/MIS.2011.36>>.

- GOYAL, M.; RAJALAKSHMI, K. Personalization of test sheet based on bloom's taxonomy in e-learning system using genetic algorithm. In: **Recent Findings in Intelligent Computing Techniques**. [S.l.]: Springer, 2018. p. 409–414. <https://doi.org/10.1007/978-981-10-8636-6_42>.
- HSSINA, B.; ERRITALI, M. A personalized pedagogical objectives based on a genetic algorithm in an adaptive learning system. **Procedia Computer Science**, Elsevier, v. 151, p. 1152–1157, 2019. <<https://doi.org/10.1016/j.procs.2019.04.164>>.
- HUANG, J. L. et al. Detecting and deterring insufficient effort responding to surveys. **Journal of Business and Psychology**, Springer, v. 27, n. 1, p. 99–114, 2012. <<https://doi.org/10.1007/s10869-011-9231-8>>.
- İNCE, M.; YİĞİT, T.; İŞİK, A. H. A hybrid ahp-ga method for metadata-based learning object evaluation. **Neural Computing and Applications**, Springer, v. 31, n. 1, p. 671–681, 2019. <<https://doi.org/10.1007/s00521-017-3023-7>>.
- JOURDAN, D. B.; WECK, O. L. de. Multi-objective genetic algorithm for the automated planning of a wireless sensor network to monitor a critical facility. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. **Sensors, and Command, Control, Communications, and Intelligence (C3I) Technologies for Homeland Security and Homeland Defense III**. [S.l.], 2004. v. 5403, p. 565–575. <<https://doi.org/10.1117/12.541685>>.
- JÚNIOR, C. X. P.; DORÇA, F. A.; ARAUJO, R. D. Towards an adaptive approach that combines semantic web technologies and metaheuristics to create and recommend learning objects. In: IEEE. **2019 IEEE 19th International Conference on Advanced Learning Technologies (ICALT)**. [S.l.], 2019. v. 2161, p. 395–397.
- KONAK, A.; COIT, D. W.; SMITH, A. E. Multi-objective optimization using genetic algorithms: A tutorial. **Reliability engineering & system safety**, Elsevier, v. 91, n. 9, p. 992–1007, 2006.
- KRATHWOHL, D. R. A revision of bloom's taxonomy: An overview. **Theory Into Practice**, Routledge, v. 41, n. 4, p. 212–218, 2002. <https://doi.org/10.1207/s15430421tip4104_2>.
- KURILOVAS, E.; KUBILINSKIENE, S.; DAGIENE, V. Web 3.0 – based personalisation of learning objects in virtual learning environments. **Computers in Human Behavior**, v. 30, p. 654 – 662, 2014. ISSN 0747-5632. <<https://doi.org/10.1016/j.chb.2013.07.039>>. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0747563213002781>>.
- KURILOVAS, E.; ZILINSKIENE, I.; DAGIENE, V. Recommending suitable learning scenarios according to learners' preferences: An improved swarm based approach. **Computers in Human Behavior**, Elsevier, v. 30, p. 550–557, 2014. <<https://doi.org/10.1016/j.chb.2013.06.036>>.
- LAMBERT, J. **Digital storytelling: capturing lives, creating community**. 4. ed. Routledge, 2012. ISBN 0415627028, 9780415627023, 0415627036, 9780415627030, 0203102320, 9780203102329. Disponível em: <<http://gen.lib.rus.ec/book/index.php?md5=0c5b004f208e17e47e3471829f74c525>>.

- LEU, D. J. et al. New literacies: A dual-level theory of the changing nature of literacy, instruction, and assessment. **Journal of Education**, SAGE Publications Sage CA: Los Angeles, CA, v. 197, n. 2, p. 1–18, 2017. <<https://doi.org/10.1177/002205741719700202>>.
- LI, B.-h. et al. Applications of artificial intelligence in intelligent manufacturing: a review. **Frontiers of Information Technology & Electronic Engineering**, Springer, v. 18, n. 1, p. 86–96, 2017. <<https://doi.org/10.1631/FITEE.1601885>>.
- LIMONGELLI, C.; SCIARRONE, F. Fuzzy student modeling for personalization of e-learning courses. In: ZAPHIRIS, P.; IOANNOU, A. (Ed.). **Learning and Collaboration Technologies. Designing and Developing Novel Learning Experiences**. Cham: Springer International Publishing, 2014. p. 292–301. ISBN 978-3-319-07482-5. <https://doi.org/10.1007/978-3-319-07482-5_28>.
- LIN, Y.-S.; CHANG, Y.-C.; CHU, C.-P. An innovative approach to scheme learning map considering tradeoff multiple objectives. **Journal of Educational Technology & Society**, JSTOR, v. 19, n. 1, p. 142–157, 2016.
- LU, J. et al. Recommender system application developments: a survey. **Decision Support Systems**, Elsevier, v. 74, p. 12–32, 2015. <<https://doi.org/10.1016/j.dss.2015.03.008>>.
- MACHADO, M.; BARRÉRE, E.; SOUZA, J. Uma abordagem evolutiva para o problema de sequenciamento curricular adaptativo. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S.l.: s.n.], 2018. v. 29, p. 1243. <<https://doi.org/10.5753/cbie.sbie.2018.1243>>.
- MANCEBO, D. Trabalho remoto na educação superior brasileira: efeitos e possibilidades no contexto da pandemia. **Revista USP**, n. 127, p. 105–116, 2020. <<https://doi.org/10.11606/issn.2316-9036.i127p105-116>>.
- MARINOV, M.; VALOVA, I. Application of planning techniques in knowledge-managed tutoring systems. In: **2016 15th International Conference on Information Technology Based Higher Education and Training (ITHET)**. [S.l.: s.n.], 2016. p. 1–5. <<https://doi.org/10.1109/ITHET.2016.7760745>>.
- MARTINS, A. F. et al. A comparative analysis of metaheuristics applied to adaptive curriculum sequencing. **Soft Computing**, Springer, v. 25, n. 16, p. 11019–11034, 2021. <<https://doi.org/10.1007/s00500-021-05836-9>>.
- MASCHIO, P. de T. et al. Um panorama acerca da mineração de dados educacionais no brasil. **Anais do XXIX Simpósio Brasileiro de Informática na Educação**, 2018. <<https://doi.org/10.5753/cbie.sbie.2018.1936>>.
- MCDERMOTT, D. et al. **PDDL-the planning domain definition language**. [S.l.]: Technical Report CVC TR-98-003/DCS TR-1165, Yale Center for Computational . . . , 1998.
- MIRANDA, P. B. de et al. Uma abordagem multiobjetivo para recomendação de caminhos de aprendizagem para grupo de usuários. **Revista Brasileira de Informática na Educação**, v. 27, n. 3, 2019. <<https://doi.org/10.5753/rbie.2019.27.03.336>>.

MORAES, C. P. de et al. Análise da satisfação discente: é possível ser feliz em cursos de graduação? **Brazilian Journal of Development**, v. 7, n. 5, p. 51642–51653, 2021.

MOREIRA, C.; PIMENTEL, A. R.; MASCHIO, E. **Sequenciamento Inteligente e Adaptativo de Enunciados em Programação de Computadores**. Tese (Doutorado) — Dissertação de mestrado, Universidade Federal do Paraná, Curitiba, 2016. GS Search.

MORO, F. F.; TAROUÇO, L. M. R.; VICARI, R. M. Proposta de arquitetura baseada em agentes inteligentes integrados em ambientes e-learning. **Revista Educar Mais**, v. 5, n. 2, p. 249–260, 2021. <<https://doi.org/10.15536/reducarmais.5.2021.2163>>.

NAU, D.; GHALLAB, M.; TRAVERSO, P. **Automated Planning: Theory & Practice**. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 2004. <<https://doi.org/10.1016/B978-155860856-6/50021-1>>. ISBN 1558608567.

OHLEER, J. B. **Digital storytelling in the classroom: New media pathways to literacy, learning, and creativity**. [S.l.]: Corwin Press, 2013. <<https://doi.org/10.4135/9781452277479>>.

PAIVA, R. A. de; PADILHA, M. A. S. A webquest e a taxonomia digital de bloom como uma nova coreografia didática para a educação online. **Revista Brasileira de Ensino de Ciência e Tecnologia**, v. 5, n. 1, 2012. <<https://doi.org/10.3895/S1982-873X2012000100006>>.

PAIVA, R. O. A. et al. Improving pedagogical recommendations by classifying students according to their interactional behavior in a gamified learning environment. In: **ACM. Proceedings of the 30th Annual ACM Symposium on Applied Computing**. [S.l.], 2015. p. 233–238. <<https://doi.org/10.1145/2695664.2695874>>.

PENG, H.; MA, S.; SPECTOR, J. M. Personalized adaptive learning: an emerging pedagogical approach enabled by a smart learning environment. **Smart Learning Environments**, SpringerOpen, v. 6, n. 1, p. 1–14, 2019. <<https://doi.org/10.1186/s40561-019-0089-y>>.

PIREVA, K.; KEFALAS, P. A recommender system based on hierarchical clustering for cloud e-learning. **Intelligent Distributed Computing XI**, v. 53, p. 235 – 245, 2018. ISSN 1084-8045. <https://doi.org/10.1007/978-3-319-66379-1_21>.

PRASAD, G. Evaluating student performance based on bloom's taxonomy levels. In: IOP PUBLISHING. **Journal of Physics: Conference Series**. [S.l.], 2021. v. 1797, n. 1, p. 012063. <<https://doi.org/10.1088/1742-6596/1797/1/012063>>.

RASTEGARMOGHADAM, M.; ZIARATI, K. Improved modeling of intelligent tutoring systems using ant colony optimization. **Education and Information Technologies**, Springer, v. 22, n. 3, p. 1067–1087, 2017. <<https://doi.org/10.1007/s10639-016-9472-2>>.

RUSSEL, S.; NORVIG, P. et al. **Artificial intelligence: a modern approach**. [S.l.]: Pearson Education Limited London, 2013.

RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. 3rd. ed. Upper Saddle River, NJ, USA: Prentice Hall Press, 2010. ISBN 0136042597, 9780136042594.

- SANCHEZ NIGENDA, R. et al. Design and evaluation of planning and mathematical models for generating learning paths. **Computational Intelligence**, v. 34, n. 3, p. 821–838, 2017. <<https://doi.org/10.1111/coin.12134>>. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/coin.12134>>.
- SANTOS, B. C. dos. Algoritmo genético multiobjetivo para seleção de atributos aplicado a predição de função de proteína. 2017. Disponível em: <http://www.biblioteca.pucminas.br/teses/Informatica_SantosBC_1.pdf>.
- Schrock, Kathy. **Bloomin' Apps: Kathy Schrock's Guide to Everything**. 2011. Disponível em: <<https://www.schrockguide.net/bloomin-apps.html>>. Acesso em: 14 maio 2021.
- SHANG, H. Cultural interpretation of deep approach to learning: an empirical analysis in a chinese university. In: **Cross-Cultural Business Conference 2019**. [S.l.: s.n.], 2019. p. 207.
- SHMELEV, V.; KARPOVA, M.; DUKHANOV, A. An approach of learning path sequencing based on revised bloom's taxonomy and domain ontologies with the use of genetic algorithms. **Procedia Computer Science**, Elsevier, v. 66, p. 711–719, 2015. <<https://doi.org/10.1016/j.procs.2015.11.081>>.
- TAIT, H.; ENTWISTLE, N. Identifying students at risk through ineffective study strategies. **Higher education**, Springer, v. 31, n. 1, p. 97–116, 1996.
- TARUS, J. K.; NIU, Z.; MUSTAFA, G. Knowledge-based recommendation: a review of ontology-based recommender systems for e-learning. **Artificial intelligence review**, Springer, v. 50, n. 1, p. 21–48, 2018. <<https://doi.org/10.1007/s10462-017-9539-5>>.
- TORRES, I.-D.; GUZMÁN-LUNA, J. Reactive planning to compose learning routes in uncertain environments. In: **New Trends in Networking, Computing, E-learning, Systems Sciences, and Engineering**. [S.l.]: Springer, 2015. p. 101–108. <https://doi.org/10.1007/978-3-319-06764-3_13>.
- VALENTE, J. A. et al. Informática na educação no brasil: análise e contextualização histórica. **O computador na sociedade do conhecimento**. Campinas: UNICAMP/NIED, p. 1–13, 1999.
- VANITHA, V.; KRISHNAN, P.; ELAKKIYA, R. Collaborative optimization algorithm for learning path construction in e-learning. **Computers & Electrical Engineering**, Elsevier, v. 77, p. 325–338, 2019. <<https://doi.org/10.1016/j.compeleceng.2019.06.016>>.
- WRUK, J. et al. Automated planning of smart low voltage networks using an evolutionary algorithm. In: **25th International Conference on Electricity Distribution**. Madrid, Spain: AIM, 2019. p. 1–5. Disponível em: <<http://www.cired2019.org/>>.
- ZHANG, J. et al. Automated classification of computing education questions using bloom's taxonomy. In: **Australasian Computing Education Conference**. [S.l.: s.n.], 2021. p. 58–65. <<https://doi.org/10.1145/3441636.3442305>>.
- ZOLLER, U. **Are lecture and learning compatible? Maybe for LOCS: Unlikely for HOCS**. [S.l.]: ACS Publications, 1993.

Apêndices

Questionário RASI

Neste apêndice são apresentadas as traduções livres para o português dos questionários RASI (versões completa e curta), propostos em Entwistle e Tait (2013) e utilizados neste trabalho. Em ambos os questionários é utilizada uma escala Likert de 5 níveis, com as seguintes opções de resposta:

- Discordo*
- Discordo Parcialmente*
- Indiferente*
- Concordo Parcialmente*
- Concordo*

A.1 RASI - versão completa (52 questões)

1. Consigo encontrar condições para estudar, o que me permite continuar meu trabalho com facilidade.
2. Ao trabalhar em uma tarefa, tenho em mente a melhor forma de impressionar o tutor/professor.
3. Muitas vezes me pergunto se o trabalho que estou fazendo aqui vale realmente a pena.
4. Eu geralmente começo a entender por mim mesmo o significado do que tenho que aprender.
5. Organizo meu tempo de estudo com cuidado para fazer o melhor uso dele.
6. Penso que tenho que me concentrar apenas em memorizar boa parte do que tenho que aprender.

7. Repasso o trabalho que fiz cuidadosamente para verificar o raciocínio e se isso faz sentido.
8. Muitas vezes sinto que estou me afogando na enorme quantidade de material que estamos tendo que lidar.
9. Olho para a evidência cuidadosamente e tento chegar a minha própria conclusão sobre o que estou estudando.
10. É importante para mim sentir que estou fazendo o melhor que posso nos cursos aqui.
11. Tento relacionar ideias que encontro com outras pessoas em outros tópicos ou outros cursos sempre que possível.
12. Costumo ler muito pouco além do que é realmente necessário para passar.
13. Regularmente me vejo pensando em ideias de palestras quando estou fazendo outras coisas.
14. Acredito que sou bastante sistemático e organizado quando se trata de revisar para avaliações.
15. Analiso cuidadosamente os comentários dos tutores/professores sobre o trabalho do curso para ver como conseguir notas mais altas na próxima vez.
16. Não há muito do trabalho aqui que eu ache interessante ou relevante.
17. Quando leio um artigo ou livro, tento descobrir por mim mesmo exatamente o que o autor quer dizer.
18. Sou muito bom em começar a trabalhar sempre que preciso.
19. Muito do que estou estudando faz pouco sentido: é como partes e fragmentos não relacionados.
20. Penso sobre o que quero obter deste curso para manter meus estudos bem focados.
21. Quando estou trabalhando em um novo tópico, tento ver em minha mente como todas as ideias se encaixam.
22. Eu sempre me preocupo se algum dia poderei lidar adequadamente com a profissão pretendida ao final do curso.
23. Muitas vezes me pego questionando coisas que ouço em palestras ou leio em livros.
24. Sinto que estou me dando bem, e isso me ajuda a colocar mais esforço no trabalho.

25. Eu me concentro em aprender apenas aquelas informações que preciso saber para passar.
26. Acho que estudar tópicos acadêmicos pode ser bastante excitante às vezes.
27. Sou bom em acompanhar algumas das leituras sugeridas por professores ou tutores.
28. Tenho em mente quem marcará uma tarefa e o que provavelmente estarão esperando como resultado.
29. Quando olho para trás, às vezes me pergunto por que decidi vir aqui.
30. Quando estou lendo, paro de vez em quando para refletir sobre o que estou tentando aprender com isso.
31. Trabalho de forma constante durante o semestre, em vez de deixar tudo até o último minuto.
32. Eu não tenho certeza do que é importante em palestras, então eu tento absorver tudo o que posso.
33. Ideias em livros ou artigos sobre cursos muitas vezes me desencadeiam longas correntes de pensamento.
34. Antes de começar a trabalhar em uma tarefa ou questão do exame, penso primeiro em como resolvê-lo melhor.
35. Eu muitas vezes pareço entrar em pânico se eu ficar para trás com o meu trabalho.
36. Quando leio, examino cuidadosamente os detalhes para ver como eles se encaixam no que está sendo dito.
37. Esforço-me muito para estudar porque estou determinado(a) a me sair bem.
38. Direciono meus estudos para o que parece ser necessário para tarefas e avaliações.
39. Algumas das ideias que eu me deparo no curso acho realmente emocionantes.
40. Eu normalmente planejo o trabalho da minha semana com antecedência, seja escrito ou na minha cabeça.
41. Mantenho os olhos abertos para o que os professores parecem achar importante e concentro-me nisso.
42. Eu não estou realmente interessado neste curso, mas tenho que aceitar por outros motivos.

43. Antes de abordar um problema ou tarefa, primeiro tento descobrir o que está por trás disso.
44. Eu geralmente faço bom uso do meu tempo durante o dia.
45. Muitas vezes tenho dificuldade em entender as coisas que preciso lembrar.
46. Gosto de brincar com minhas próprias ideias, mesmo que elas não me levem muito longe.
47. Quando termino um trabalho, reviso para ver se realmente atende aos requisitos.
48. Muitas vezes fico acordado me preocupando com o trabalho que acho que não conseguirei fazer.
49. É importante para mim poder seguir o argumento ou ver a razão por detrás das coisas.
50. Eu não acho difícil me motivar.
51. Gosto de saber exatamente o que fazer em ensaios ou outras tarefas.
52. Às vezes, fico "viciado" em tópicos acadêmicos e sinto que gostaria de continuar estudando-os.

A.2 RASI - versão curta (18 questões)

1. Organizo meu tempo de estudo com cuidado para fazer o melhor uso dele.
2. Muitas vezes sinto que estou me afundando na enorme quantidade de material que tenho de lidar.
3. Penso que sou bastante sistemático(a) e organizado(a) quando se trata de estudar para avaliações.
4. Não há muito do trabalho aqui que eu ache interessante ou relevante.
5. Quando leio um artigo ou livro, tento descobrir por mim mesmo exatamente o que o autor quer dizer.
6. Sou muito bom em começar a trabalhar sempre que preciso.
7. Muito do que estou estudando faz pouco sentido, como se fossem partes e fragmentos não relacionados.
8. Quando estou trabalhando em um novo tópico, tento imaginar como todas as ideias se encaixam.

9. Muitas vezes me preocupo se algum dia serei capaz de lidar com a profissão de maneira adequada.
10. Muitas vezes me pego questionando coisas que ouço em palestras ou leio em livros.
11. Trabalho de forma constante durante o semestre, em vez de deixar tudo para última hora.
12. Eu não tenho certeza do que é importante em palestras, então eu tento absorver tudo o que posso.
13. Ideias sobre cursos em livros ou artigos muitas vezes me desencadeiam longas correntes de pensamento.
14. Quando leio, examino cuidadosamente os detalhes para compreender como eles se encaixam no que está sendo dito.
15. Esforço-me muito para estudar porque estou determinado(a) a me sair bem.
16. Antes de abordar um problema ou tarefa, primeiro tento descobrir o que está por trás disso.
17. Muitas vezes tenho dificuldade em entender as coisas que preciso lembrar.
18. Eu não acho difícil me motivar.

Mapeamento entre TB e RASI

Neste apêndice, é detalhado o mapeamento realizado entre a TB e o perfil RASI.

B.1 Tabela de mapeamento (RASI x TB)

Na Tabela 27, é mostrada a classificação de cada uma das 52 questões do RASI em relação às categorias da dimensão do processo cognitivo na TB. Note que para cada questão foi rotulado um verbo-chave que está associado a uma categoria na TB. Com isso, a quantidade de ocorrências de questões que compõe cada eixo RASI, classificadas em cada uma dessas categorias, representa o grau de correspondência RASI x TB.

Tabela 27 – Detalhamento do mapeamento entre RASI e TB

#	Questão RASI	Eixo RASI	Verbo (TB)	Categoria (TB)
1	Consigo encontrar condições para estudar, o que me permite continuar meu trabalho com facilidade.	Strategic	Organizar	Analisar
2	Ao trabalhar em uma tarefa, tenho em mente a melhor forma de impressionar o tutor/professor.	Strategic	Julgar	Avaliar
3	Muitas vezes me pergunto se o trabalho que estou fazendo aqui vale realmente a pena.	Surface	Reconhecer	Lembrar
4	Eu geralmente começo a entender por mim mesmo o significado do que tenho que aprender.	Deep	Interpretar	Compreender
5	Organizo meu tempo de estudo com cuidado para fazer o melhor uso dele.	Strategic	Organizar	Avaliar
6	Penso que tenho que me concentrar apenas em memorizar boa parte do que tenho que aprender.	Surface	Explicar	Compreender
7	Repasso o trabalho que fiz cuidadosamente para verificar o raciocínio e se isso faz sentido.	Deep	Verificar	Avaliar
8	Muitas vezes sinto que estou me afogando na enorme quantidade de material que estamos tendo que lidar.	Surface	Reconhecer	Lembrar

Continuação na próxima página.

Continuação da página anterior.

#	Questão RASI	Eixo RASI	Verbo (TB)	Categoria (TB)
9	Olho para a evidência cuidadosamente e tento chegar a minha própria conclusão sobre o que estou estudando.	Deep	Concluir	Analisar
10	É importante para mim sentir que estou fazendo o melhor que posso nos cursos aqui.	Strategic	Monitorar	Avaliar
11	Tento relacionar ideias que encontro com outras pessoas em outros tópicos ou outros cursos sempre que possível.	Deep	Desconstruir	Analisar
12	Costumo ler muito pouco além do que é realmente necessário para passar.	Surface	Recuperar	Lembrar
13	Regularmente me vejo pensando em ideias de palestras quando estou fazendo outras coisas.	Deep	Planejar	Criar
14	Acredito que sou bastante sistemático e organizado quando se trata de revisar para avaliações.	Strategic	Revisar	Avaliar
15	Analiso cuidadosamente os comentários dos tutores/professores sobre o trabalho do curso para ver como conseguir notas mais altas na próxima vez.	Strategic	Analisar	Analisar
16	Não há muito do trabalho aqui que eu ache interessante ou relevante.	Surface	Reconhecer	Lembrar
17	Quando leio um artigo ou livro, tento descobrir por mim mesmo exatamente o que o autor quer dizer.	Deep	Interpretar	Compreender
18	Sou muito bom em começar a trabalhar sempre que preciso.	Strategic	Realizar	Aplicar
19	Muito do que estou estudando faz pouco sentido: é como partes e fragmentos não relacionados.	Surface	Reconhecer	Lembrar
20	Penso sobre o que quero obter deste curso para manter meus estudos bem focados.	Deep	Monitorar	Avaliar
21	Quando estou trabalhando em um novo tópico, tento ver em minha mente como todas as ideias se encaixam.	Deep	Estruturar	Analisar
22	Eu sempre me preocupo se algum dia poderei lidar adequadamente com a profissão pretendida ao final do curso.	Surface	Planejar	Criar
23	Muitas vezes me pego questionando coisas que ouço em palestras ou leio em livros.	Deep	Desconstruir	Analisar
24	Sinto que estou me dando bem, e isso me ajuda a colocar mais esforço no trabalho.	Strategic	Julgar	Avaliar
25	Eu me concentro em aprender apenas aquelas informações que preciso saber para passar.	Surface	Explicar	Compreender
26	Acho que estudar tópicos acadêmicos pode ser bastante excitante às vezes.	Deep	Interpretar	Compreender
27	Sou bom em acompanhar algumas das leituras sugeridas por professores ou tutores.	Strategic	Reconhecer	Lembrar
28	Tenho em mente quem marcará uma tarefa e o que provavelmente estarão esperando como resultado.	Strategic	Estruturar	Analisar
29	Quando olho para trás, às vezes me pergunto por que decidi vir aqui.	Surface	Comparar	Analisar
30	Quando estou lendo, paro de vez em quando para refletir sobre o que estou tentando aprender com isso.	Deep	Refletir	Avaliar

Continuação na próxima página.

Continuação da página anterior.

#	Questão RASI	Eixo RASI	Verbo (TB)	Categoria (TB)
31	Trabalho de forma constante durante o semestre, em vez de deixar tudo até o último minuto.	Strategic	Realizar	Aplicar
32	Eu não tenho certeza do que é importante em palestras, então eu tento absorver tudo o que posso.	Surface	Reconhecer	Lembrar
33	Ideias em livros ou artigos sobre cursos muitas vezes me desencadeiam longas correntes de pensamento.	Deep	Conceber	Criar
34	Antes de começar a trabalhar em uma tarefa ou questão do exame, penso primeiro em como resolvê-lo melhor.	Deep	Organizar	Analisar
35	Eu muitas vezes pareço entrar em pânico se eu ficar para trás com o meu trabalho.	Surface	Identificar	Lembrar
36	Quando leio, examino cuidadosamente os detalhes para ver como eles se encaixam no que está sendo dito.	Deep	Verificar	Avaliar
37	Esforço-me muito para estudar porque estou determinado(a) a me sair bem.	Strategic	Explicar	Compreender
38	Direciono meus estudos para o que parece ser necessário para tarefas e avaliações.	Surface	Organizar	Analisar
39	Algumas das ideias que eu me deparo no curso acho realmente emocionantes.	Deep	Julgar	Avaliar
40	Eu normalmente planejo o trabalho da minha semana com antecedência, seja escrito ou na minha cabeça.	Strategic	Planejar	Criar
41	Mantenho os olhos abertos para o que os professores parecem achar importante e concentro-me nisso.	Strategic	Resumir	Compreender
42	Eu não estou realmente interessado neste curso, mas tenho que aceitar por outros motivos.	Surface	Identificar	Lembrar
43	Antes de abordar um problema ou tarefa, primeiro tento descobrir o que está por trás disso.	Deep	Encontrar	Analisar
44	Eu geralmente faço bom uso do meu tempo durante o dia.	Strategic	Organizar	Analisar
45	Muitas vezes tenho dificuldade em entender as coisas que preciso lembrar.	Surface	Reconhecer	Lembrar
46	Gosto de brincar com minhas próprias ideias, mesmo que elas não me levem muito longe.	Deep	Inventar	Criar
47	Quando termino um trabalho, reviso para ver se realmente atende aos requisitos.	Deep	Revisar	Avaliar
48	Muitas vezes fico acordado me preocupando com o trabalho que acho que não conseguirei fazer.	Surface	Reconhecer	Lembrar
49	É importante para mim poder seguir o argumento ou ver a razão por detrás das coisas.	Deep	Estruturar	Analisar
50	Eu não acho difícil me motivar.	Strategic	Realizar	Aplicar
51	Gosto de saber exatamente o que fazer em ensaios ou outras tarefas.	Surface	Fazer	Criar
52	Às vezes, fico "viciado" em tópicos acadêmicos e sinto que gostaria de continuar estudando-os.	Deep	Interpretar	Compreender