

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
INSTITUTO DE CIÊNCIAS EXATAS
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

**Moodle como Infraestrutura para o
Sequenciamento Curricular Adaptativo
Implementação de uma Prova de Conceito para a
Geração Automática de Trilhas de Aprendizagem
Personalizadas**

Luíza Machado Costa Nascimento

JUIZ DE FORA
JULHO, 2026

Moodle como Infraestrutura para o Sequenciamento Curricular Adaptativo Implementação de uma Prova de Conceito para a Geração Automática de Trilhas de Aprendizagem Personalizadas

LUÍZA MACHADO COSTA NASCIMENTO

Universidade Federal de Juiz de Fora
Instituto de Ciências Exatas
Departamento de Ciência da Computação
Bacharelado em Ciência da Computação

Orientador: Jairo Francisco de Souza
Coorientador: Marcelo de Oliveira Costa Machado

JUIZ DE FORA
JULHO, 2026

MOODLE COMO INFRAESTRUTURA PARA O
SEQUENCIAMENTO CURRICULAR ADAPTATIVO

Implementação de uma Prova de Conceito para a Geração Automática de
Trilhas de Aprendizagem Personalizadas

Luíza Machado Costa Nascimento

MONOGRAFIA SUBMETIDA AO CORPO DOCENTE DO INSTITUTO DE CIÊNCIAS
EXATAS DA UNIVERSIDADE FEDERAL DE JUIZ DE FORA, COMO PARTE INTE-
GRANTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE
BACHAREL EM CIÊNCIA DA COMPUTAÇÃO.

Aprovada por:

Jairo Francisco de Souza
Doutor em Informática (PUC-Rio)

Marcelo de Oliveira Costa Machado
Doutor em Informática (UNIRIO)

Heder Soares Bernardino
Doutor em Modelagem Computacional (LNCC/MCTI)

Eduardo Barrére
Doutor em Engenharia de Sistemas e Computação (COPPE/UFRJ)

JUIZ DE FORA
14 DE JULHO, 2026

Resumo

A personalização do ensino tem se consolidado como uma estratégia eficaz para atender às diferentes necessidades dos estudantes em ambientes virtuais de aprendizagem. Nesse cenário, o Sequenciamento Curricular Adaptativo (ACS) se apresenta como uma abordagem que visa oferecer conteúdos em uma ordem adequada ao perfil de cada aluno, mas enfrenta uma lacuna significativa entre os modelos teóricos e sua aplicação prática em Sistemas de Gestão de Aprendizagem (LMS). O Moodle se destaca como uma plataforma promissora para suprir essa lacuna: por sua arquitetura *open source* e suporte nativo a diversos recursos, permite que dados pedagógicos sejam estruturados e extraídos sob demanda. Este trabalho propõe a estruturação de cursos na plataforma que viabilizam a extração sistemática dos dados necessários para o processamento das sequências curriculares adaptativas. A partir de um curso estruturado com dados de um experimento prévio inseridos na plataforma, o algoritmo é executado sobre os dados extraídos, gerando sequências de materiais adaptadas ao perfil de cada estudante. A estratégia demonstra a viabilidade de transformar o Moodle em um ambiente adaptativo, oferecendo um modelo replicável para a integração entre algoritmos de otimização e recursos já consolidados em ambientes virtuais de aprendizagem.

Palavras-chave: Sequenciamento Curricular Adaptativo, Moodle, Metaheurísticas, Trilhas de Aprendizagem Personalizadas, Sistema de Gestão de Aprendizagem.

Abstract

The personalization of teaching has established itself as an effective strategy for meeting the different needs of students in virtual learning environments. In this scenario, Adaptive Curriculum Sequencing (ACS) presents itself as an approach that aims to deliver content in an order suited to each student's profile, but faces a significant gap between theoretical models and their practical application in Learning Management Systems (LMS). Moodle stands out as a promising platform to bridge this gap: its *open source* architecture and native support for various resources allow pedagogical data to be structured and extracted on demand. This work proposes the structuring of courses on the platform that enable the systematic extraction of data necessary for processing adaptive curriculum sequences. Based on a structured course with data from a previous experiment inserted into the platform, the algorithm is executed on the extracted data, generating sequences of materials tailored to each student's profile. The strategy demonstrates the feasibility of transforming Moodle into an adaptive environment, offering a replicable model for integrating optimization algorithms with resources already established in virtual learning environments.

Keywords: Adaptive Curriculum Sequencing, Moodle, Metaheuristics, Personalized Learning Paths, Learning Management System.

Conteúdo

Lista de Figuras	5
Lista de Tabelas	6
Lista de Abreviações	7
1 Introdução	8
1.1 Contextualização	8
1.2 Justificativa	9
1.3 Objetivos	10
1.3.1 Objetivo Geral	10
1.3.2 Objetivos Específicos	11
1.4 Contribuições	11
1.5 Organização do Trabalho	11
2 Fundamentação Teórica	13
2.1 Sequenciamento Curricular Adaptativo e Algoritmos	13
2.1.1 Metaheurísticas aplicadas ao ACS	14
2.1.2 Algoritmo Presa-Predador	15
2.1.3 Modelagem complementar do conhecimento	16
2.2 Critérios pedagógicos incorporados aos modelos de otimização	16
2.3 Evidências de eficácia em aplicações reais	17
2.4 Formalização da Função Objetivo para o Sequenciamento Curricular Adaptativo Multiobjetivo	18
2.4.1 Cobertura de conceitos (O_1)	19
2.4.2 Habilidade do estudante (O_2)	19
2.4.3 Duração do curso (O_3)	20
2.4.4 Equilíbrio entre os materiais (O_4)	20
2.4.5 Preferências de aprendizagem (O_5)	20
2.5 O Moodle como ambiente para operacionalização do ACS	21
2.5.1 SCORM e Empacotamento de Conteúdo Educacional	22
2.6 Técnicas Complementares de Análise de Dados	23
2.6.1 K-means	23
3 Trabalhos Relacionados	25
3.1 Critério de classificação dos trabalhos	25
3.1.1 Abordagens validadas em ambientes teóricos ou simulados	25
3.1.2 Abordagens com usuários reais em sistemas próprios ou distintos do Moodle	26
3.1.3 Abordagens com algum grau de conexão com o Moodle	27
3.2 Síntese da categorização	28
4 Metodologia	30
4.1 Caracterização do Dataset Original	30
4.1.1 Estrutura do currículo	31

4.1.2	Materiais de aprendizagem	32
4.1.3	Perfil dos estudantes	33
4.2	Preparação do Moodle	34
4.2.1	Importação de usuários	35
4.2.2	Criação dos materiais como atividades SCORM	35
4.2.3	Framework de Competências: cobertura e habilidades	36
4.2.4	Extensão de dificuldade dos materiais	38
4.2.5	Extensão de tempo estimado para materiais	39
4.2.6	Planos de Aprendizagem: acompanhamento individualizado	40
4.2.7	Questionários para preferências de aprendizagem	41
4.2.8	Questionários para disponibilidade de tempo	42
4.3	Síntese do Mapeamento	43
4.4	Desenho Experimental e Avaliação	46
5	Resultados	48
5.1	Desempenho do Experimento PPA	48
5.2	Comparação com o Experimento de Referência	51
5.3	Materiais Mais Selecionados e Interseção entre Experimentos	53
5.4	Clusterização dos Alunos e dos Materiais	56
5.4.1	Clusterização dos alunos	56
5.4.2	Clusterização dos materiais	57
5.4.3	Relação entre clusters de alunos e clusters de materiais	58
6	Conclusão e Trabalhos Futuros	60
6.1	Limitações	61
6.2	Trabalhos Futuros	62
	Bibliografia	64

Lista de Figuras

4.1	Exibição de materiais no formato SCORM para seção de Algoritmos no Moodle	35
4.2	Exibição de competências associadas a cursos no Moodle	36
4.3	Exibição de escalas associadas a competências no Moodle.	37
4.4	Gerenciamento do <i>plugin</i> de dificuldade.	38
4.5	Associação de dificuldade aos materiais.	39
4.6	Recurso para inserir tempo estimado para materiais.	39
4.7	Visão detalhada de um plano de aprendizagem associado a um aluno . . .	40
4.8	Questionários no Moodle para identificação do estilo de aprendizado . . .	42
4.9	Questionário no Moodle para identificação da disponibilidade de tempo . .	42
4.10	Visão geral do processo de adaptação do Moodle e geração de sequências. .	43
5.1	Decomposição do <i>fitness</i> médio por disciplina.	50
5.2	Distribuição do <i>fitness</i> médio (5 rodadas) por disciplina — Experimento PPA. Cada ponto representa a média das cinco execuções de um aluno. . .	51
5.3	Distribuição do <i>fitness</i> por execução e disciplina — Experimento PPA. A sobreposição das caixas entre rodadas evidencia a estabilidade do algoritmo. .	52
5.4	Top 10 materiais mais selecionados por disciplina nos experimentos PPA e de referência.	55

Lista de Tabelas

3.1	Categorização dos trabalhos relacionados por proximidade de ecossistema	29
4.1	Distribuição dos materiais de aprendizagem por disciplina	32
4.2	Mapeamento entre as variáveis da função objetivo e os recursos do Moodle	46
5.1	Estatísticas do <i>fitness</i> médio por disciplina — Experimento PPA	48
5.2	Comparação do <i>fitness</i> médio por disciplina: Experimento PPA vs. experimento de referência	53
5.3	Interseção dos 10 materiais mais selecionados por disciplina	54
5.4	Perfil médio dos <i>clusters</i> de alunos (escala ILS: -11 a $+11$)	56
5.5	Dificuldade e interatividade médias dos <i>clusters</i> de materiais por disciplina ($K = 3$)	58
5.6	<i>Fitness</i> médio da melhor rodada por <i>cluster</i> de aluno e disciplina	59

Lista de Abreviações

ABC	Colônia de Abelhas Artificiais
ACS	Sequenciamento Curricular Adaptativo
AG	Algoritmo Genético
AGG	Algoritmo Genético de Agrupamento
AGP	Algoritmo Genético com Predação
BPSO	<i>Binary Particle Swarm Optimization</i>
DCC	Departamento de Ciência da Computação
DE	Evolução Diferencial
DINA	<i>Deterministic Input, Noisy “And” Gate</i>
DPSO	<i>Discrete Particle Swarm Optimization</i>
FSLSM	<i>Felder-Silverman Learning Style Model</i>
ILS	<i>Index of Learning Styles</i>
IRT	Teoria de Resposta ao Item
LMS	<i>Learning Management System</i>
LOM	<i>Learning Object Metadata</i>
LSTM	<i>Long Short-Term Memory</i>
NSGA-II	<i>Non-dominated Sorting Genetic Algorithm II</i>
OCF	Otimização por Colônia de Formigas
OEP	Otimização por Enxame de Partículas
PPA	Algoritmo Presa-Predador
SCORM	<i>Sharable Content Object Reference Model</i>
SSA	<i>Sparrow Search Algorithm</i>
UFJF	Universidade Federal de Juiz de Fora
VLCR	<i>Variable Length Continuous Representation</i>

1 Introdução

1.1 Contextualização

O crescimento do ensino *online* tem gerado uma demanda crescente por abordagens pedagógicas personalizadas que atendam às necessidades individuais de cada estudante (Machado *et al.*, 2021). Ambientes *online* frequentemente apresentam um único percurso de aprendizagem para todos os alunos, independentemente de seu nível de conhecimento prévio, de seu estilo de aprendizagem ou do tempo disponível para dedicação aos estudos. Essa lógica tende a penalizar tanto estudantes com mais dificuldade, que avançam sem consolidar conceitos básicos, quanto estudantes mais avançados, que permanecem revisando conteúdos já dominados.

Nesse cenário, o Sequenciamento Curricular Adaptativo (ACS) se destaca como uma estratégia fundamental para otimizar a oferta de recursos de aprendizagem, visando aumentar o engajamento, uma vez que a utilização do ACS fundamenta-se na busca da sequência ótima de materiais de aprendizagem que maximize a adequação ao perfil do aluno, sendo frequentemente formalizado como um problema de otimização combinatória complexo da classe NP-Hard (Martins *et al.*, 2021; Nogueira *et al.*, 2024). A implementação prática de soluções de ACS é crucial para mitigar problemas como a desorientação do aluno e a sobrecarga cognitiva, fatores que contribuem diretamente para o insucesso acadêmico. A automação desse processo permite que percursos personalizados sejam gerados em escala, superando as barreiras de tempo e esforço exigidas pelo sequenciamento manual feito por instrutores, que normalmente não possuem condições de adaptar individualmente o percurso de cada estudante em turmas numerosas. Essa complexidade decorre do número de combinações possíveis entre materiais, conceitos e restrições pedagógicas, o que tem motivado a literatura a investigar diferentes famílias de algoritmos, como métodos evolutivos, inteligência de enxame e técnicas de otimização, ou seja, soluções heurísticas robustas.

No entanto, apesar de seu potencial teórico, a aplicação prática do ACS em am-

bientes de aprendizagem *online* ainda encontra desafios significativos, resultando em uma lacuna notável entre a pesquisa e a implementação efetiva. A maioria das soluções propostas permanece em ambientes experimentais isolados ou utiliza sistemas proprietários, sem uma integração efetiva com os Ambientes Virtuais de Aprendizagem (LMS) amplamente adotados por instituições de ensino. Dessa forma, o Moodle surge como uma alternativa, uma vez que a plataforma consolidou-se como referência no contexto de gestão de aprendizagem, amplamente utilizada devido à sua arquitetura aberta e modular (Gamage; Ayres; Behrend, 2022).

1.2 Justificativa

Apesar dos avanços na literatura relacionados ao desenvolvimento de algoritmos sofisticados para a implementação do ACS, fundamentados em metaheurísticas de otimização multiobjetivo para o problema de sequenciamento, observa-se que tais contribuições permanecem pouco incorporadas aos ambientes de ensino utilizados pelas instituições (Machado *et al.*, 2021). O Moodle ilustra bem essa limitação: embora ofereça recursos nativos relevantes para a configuração de cursos, como o *Framework* de Competências, condicionais de acesso e planos de aprendizagem, além de permitir a implementação de *plugins* para demandas específicas de cada curso, esses recursos são frequentemente subutilizados. Na maioria dos casos, são empregados apenas para o controle administrativo de notas e liberação sequencial de conteúdo, sem qualquer lógica de otimização.

Nesse sentido, para além de um ecossistema voltado à hospedagem estática de repositórios de conteúdo, o Moodle oferece uma infraestrutura que pode ser reaproveitada para a operacionalização de modelos de ACS. Ao mapear os recursos da plataforma a algoritmos de otimização, torna-se possível demonstrar a viabilidade de transformar um ambiente já amplamente utilizado em um sistema dinamicamente adaptativo, sem demandar a substituição da infraestrutura tecnológica já consolidada nas instituições de ensino. O distanciamento entre os recursos e adaptações disponibilizados pelas plataformas e algoritmos de otimização limita a capacidade das instituições de gerar sequências verdadeiramente dinâmicas, perpetuando o cenário em que o sequenciamento adaptativo, quando existe, depende de configuração manual de trilhas específicas por parte do profes-

sor.

O problema de sequenciamento curricular pode ser compreendido, de forma geral, como a busca pela sequência de materiais de aprendizagem que melhor se adequa ao perfil de cada estudante, a partir de suas características individuais, dos materiais disponíveis e da estrutura de conceitos do curso – uma formalização detalhada na Seção 2.1. Para resolver este problema, o presente trabalho integra os requisitos de uma metaheurística de otimização aos recursos disponíveis na arquitetura do Moodle, a partir de uma função objetivo que combina linearmente cinco dimensões fundamentais (Machado *et al.*, 2021): os dados de entrada dessa função são extraídos diretamente da plataforma, e utilizados para a execução efetiva do algoritmo, produzindo como saída uma sequência de materiais para cada perfil de estudante considerado.

É diante dessas limitações práticas e da complexidade inerente à personalização que o problema central desta pesquisa se manifesta: a dificuldade de implementar sistemas de ACS eficientes e escaláveis no Moodle, representando um ambiente de aprendizado comum e acessível. Essa dificuldade se manifesta em duas dimensões principais: (1) a complexidade computacional inerente aos algoritmos de otimização quando aplicados em ambientes com restrições de integração; (2) os desafios de integração entre os parâmetros exigidos pela formulação de metaheurísticas e os recursos pedagógicos disponíveis no Moodle.

1.3 Objetivos

1.3.1 Objetivo Geral

Este trabalho tem como objetivo geral adaptar a plataforma Moodle para o mapeamento e a estruturação dos dados necessários à implementação de algoritmos de Sequenciamento Curricular Adaptativo, viabilizando a geração automática de percursos de aprendizagem personalizados ao preparar a configuração da plataforma para extração de dados para geração de trilhas de aprendizado.

1.3.2 Objetivos Específicos

Para alcançar o objetivo geral proposto, este trabalho realiza, inicialmente, um levantamento da literatura voltado à identificação dos principais métodos e requisitos de dados empregados em soluções de ACS. A partir desse levantamento, os elementos identificados são mapeados aos recursos do Moodle, com o propósito de analisar suas possibilidades e limitações de adaptação frente às exigências dos algoritmos de sequenciamento.

Em seguida, configura-se um curso no Moodle com os recursos mapeados, como competências, planos de aprendizagem e campos personalizados, populado a partir de dados de um experimento prévio, e desenvolve-se um mecanismo de extração desses dados por meio do banco de dados da plataforma. Por fim, esses dados são utilizados como entrada para a execução de uma metaheurística de sequenciamento curricular, e os resultados obtidos – as sequências de materiais geradas para diferentes perfis de estudante – são analisados quanto à sua adequação aos critérios da função objetivo adotada, permitindo avaliar a viabilidade técnica e a qualidade prática da integração proposta.

1.4 Contribuições

As contribuições deste trabalho incluem: (1) um modelo de integração replicável entre algoritmos de otimização e o sistema do Moodle; (2) a demonstração prática de que dados extraídos da plataforma podem alimentar a execução real de uma metaheurística de ACS, produzindo sequências de materiais como resultado; e (3) o fornecimento de uma base sólida e replicável para futuras implementações e validações em ambientes com dados de novos usuários.

1.5 Organização do Trabalho

O restante deste documento está organizado em seis capítulos. O Capítulo 2 fundamenta os conceitos de ACS e a arquitetura do Moodle. O Capítulo 3 revisa trabalhos relacionados e identifica as lacunas supridas por esta pesquisa. O Capítulo 4 detalha a metodologia de desenvolvimento e o desenho experimental e descreve a implementação técnica da prova

de conceito. O Capítulo 5 apresenta e discute os resultados obtidos a partir de simulações com dados disponibilizados por (Machado; Barrére; Souza, 2019)¹. Por fim, o Capítulo 6 sintetiza as conclusões, limitações e direções para trabalhos futuros.

¹Dados utilizados na avaliação: <https://github.com/lapic-ufjf/evolutionary-ACS-benchmark>

2 Fundamentação Teórica

Este capítulo apresenta os fundamentos teóricos que embasam o desenvolvimento deste trabalho. A Seção 2.1 introduz o conceito de ACS e as principais metaheurísticas aplicadas ao problema, bem como estruturas complementares de modelagem do conhecimento. A Seção 2.2 discute os critérios pedagógicos incorporados aos modelos de otimização, como estilo de aprendizagem, nível de habilidade e tempo disponível. A Seção 2.3 apresenta evidências de eficácia reportadas na literatura em aplicações reais de ACS. A Seção 2.4 formaliza a função objetivo multiobjetivo adotada como base teórica deste trabalho, detalhando cada uma de suas cinco dimensões. Por fim, a Seção 2.5 descreve os recursos do Moodle relevantes para a operacionalização do ACS, como o *Framework* de Competências, os Planos de Aprendizagem e o sistema de *tags* criadas por meio de extensões.

2.1 Sequenciamento Curricular Adaptativo e Algoritmos

O ACS consiste na geração automática de percursos de aprendizagem individualizados, a partir da seleção e do ordenamento de materiais educacionais que melhor se adequem ao perfil de cada estudante. Formalmente, pode ser definido pela função $\varphi : U \times L \times C \rightarrow S$, em que U representa o espaço de representações (modelos) do estudante, L o espaço de informações sobre os materiais de aprendizagem, C o espaço de estruturas de conceitos, e S o espaço de sequências curriculares possíveis. A função φ retorna, portanto, uma sequência $s \in S$ que otimiza a adequação ao modelo do estudante.

Essa formalização evidencia a natureza combinatória do problema: dado um conjunto de materiais e de conceitos a serem cobertos, o número de sequências possíveis cresce de forma exponencial (Martins *et al.*, 2021; Nogueira *et al.*, 2024). Por esse motivo, soluções exatas tornam-se computacionalmente inviáveis para cenários realistas, o que justifica o uso recorrente de metaheurísticas como estratégia para obter soluções de boa

qualidade em tempo aceitável.

2.1.1 Metaheurísticas aplicadas ao ACS

O ACS tem se beneficiado significativamente da aplicação de metaheurísticas, capazes de lidar com a complexidade inerente à personalização de percursos de aprendizagem. A análise da literatura revela que as metaheurísticas mais utilizadas no Sequenciamento Curricular Adaptativo são Algoritmo Genético(AG), como em (Benmesbah; Mahnane; Hafidi, 2021a), em que o AG foi otimizado por redes neurais, (Xiao, 2024; Chen; Peng; Wang, 2025), (Son *et al.*, 2021), esse último comparando AG com Otimização por Colônia de Formigas (OCF). Além disso, existem adaptações mais diversas do AG, adaptadas para funções multiobjetivo, como o NSGA-II (Nogueira *et al.*, 2024), o Algoritmo Genético de Agrupamento (AGG), adaptado para otimizar o mapeamento de conceitos (Benmesbah; Mahnane; Hafidi, 2021b), e o Algoritmo Genético com Predação (AGP), em (Su, 2025). O OCF também é frequente, como em (Li *et al.*, 2023), que introduz predição da evolução dos feromônios e um modelo de janela temporal, limitando o tempo de execução, além de (Zheng *et al.*, 2025), que implementou a Otimização por Colônia de Formigas Melhorado, abordando uma solução combinatória com múltiplas restrições. Nesse contexto, ainda há (Imamah *et al.*, 2024a) e (Niknam; Thulasiraman, 2020), que implementaram o algoritmo tradicional de OCF. Outras metaheurísticas foram apresentadas, como a Evolução Diferencial (DE), em (Zhang *et al.*, 2022), aplicado por meio de LSHADE-cnEpSin, e o Otimização por Enxame de Partículas (OEP), em (Son *et al.*, 2021) e (Subiyantoro; Ashari; Suprpto, 2021), que utilizou o Binary OEP (BPSO) para representar classes cognitivas mapeadas em três níveis de acordo com as habilidades dos alunos, e o OEP Discreto (DPSO), empregado para determinar a ordem dos objetos de aprendizagem (OAs). Cada um desses algoritmos foi adaptado para considerar critérios pedagógicos essenciais, como nível de conhecimento do aluno, estilo de aprendizagem e tempo disponível.

Existem também trabalhos comparativos entre diferentes metaheurísticas, como em (Martins *et al.*, 2021), no qual foram aplicados AG, OEP, DE e o Algoritmo Presa Predador (PPA) sobre uma mesma função de avaliação multivariada, baseada em perfis reais de alunos. Em (Sivaji; Venkatesh, 2020), foi aplicado o Colônia de Abelhas Artificiais

(ABC), combinado com K-means. Estudos como (Xiao *et al.*, 2024), por meio de DE com representação de comprimento variável (VLCR), demonstram resultados promissores, com alunos se beneficiando de percursos cruzados entre cursos (*cross-course*).

2.1.2 Algoritmo Presa-Predador

O Algoritmo Presa-Predador (*Prey-Predator Algorithm* – PPA) é uma metaheurística populacional bioinspirada, que modela a dinâmica de interação entre presas e predadores observada em ecossistemas naturais como estratégia de busca no espaço de soluções. Assim como outras metaheurísticas populacionais, como o AG e a OEP, o PPA mantém uma população de soluções candidatas que evolui ao longo de iterações sucessivas, guiada por mecanismos que equilibram a exploração de novas regiões do espaço de busca e o refinamento de soluções já promissoras.

No PPA, cada indivíduo da população é tratado como uma presa, cuja posição no espaço de busca representa uma solução candidata ao problema de otimização. A cada iteração, o indivíduo com pior valor de *fitness* na população assume o papel de predador, movendo-se em direção às demais presas; as presas, por sua vez, tendem a se afastar do predador enquanto se aproximam das regiões do espaço de busca associadas a melhores soluções, análogo ao comportamento de sobrevivência observado na natureza. Esse mecanismo de aproximação e afastamento permite ao algoritmo escapar de ótimos locais, uma vez que a pressão exercida pelo predador introduz perturbações que impedem a estagnação prematura da população em torno de uma única região do espaço de busca.

A escolha do PPA como metaheurística para problemas de ACS foi originalmente proposta por Machado, Barrére e Souza (2019), que adaptou o algoritmo para operar sobre o vetor binário de decisão $x = (x_1, \dots, x_{|M|})$, no qual cada posição indica a inclusão ou não de um material na sequência gerada para um estudante. Essa adaptação também foi utilizada por (Martins *et al.*, 2021) em um estudo comparativo entre o PPA e outras metaheurísticas aplicadas ao mesmo problema, sobre uma função de avaliação multivariada construída a partir de perfis reais de alunos (Seção 2.1). A implementação do PPA utilizada neste trabalho segue a formulação proposta por esses últimos autores, conforme detalhado na Seção 4.4.

2.1.3 Modelagem complementar do conhecimento

Além das metaheurísticas, muitas abordagens combinam técnicas baseadas em grafos para estruturar o conhecimento e definir relações entre conceitos, como em (Son *et al.*, 2021; Zheng *et al.*, 2025) e (Niknam; Thulasiraman, 2020). Eficazes para modelar dependências e pré-requisitos, essas estruturas atuam de forma complementar às metaheurísticas, sem necessariamente integrar-se a processos de otimização. O trabalho de (Zheng *et al.*, 2025) utiliza grafos de conhecimento para mapear tópicos e suas conexões, enquanto outros aplicam Cadeias de Markov (Paxinou *et al.*, 2024b) para analisar padrões de navegação em ambientes virtuais de aprendizagem. De forma semelhante, abordagens como a de (Acam-pora; Gaeta; Loia, 2011) combinam modelos ontológicos a algoritmos evolucionários, criando estruturas hierárquicas que mapeiam competências e pré-requisitos, permitindo uma representação mais rica do conhecimento no que se refere à descrição de propriedades relevantes – estrutura conceitualmente próxima ao *Framework* de Competências do Moodle, discutido na Seção 2.5.

Observa-se, assim, que grande parte dos estudos foca no refinamento dos algoritmos, integrando técnicas existentes com o objetivo de mapear dados dos alunos e buscar a melhor sequência de materiais. Nas seções seguintes, discute-se quais critérios pedagógicos esses algoritmos buscam atender, quais evidências de eficácia foram reportadas e em que medida esses casos foram efetivamente testados e integrados a *Learning Management Systems* (LMS).

2.2 Critérios pedagógicos incorporados aos modelos de otimização

Os modelos de otimização baseados em metaheurísticas para o ACS incorporam critérios pedagógicos fundamentais. Dentre eles, destaca-se o nível de conhecimento do aluno, frequentemente avaliado por meio da Teoria de Resposta ao Item (IRT) (Imamah *et al.*, 2024b) ou de modelos cognitivos como o DINA (Xiao, 2024). O estilo de aprendizagem, baseado no modelo de FSLSM (*Felder-Silverman Learning Style Model*) (Felder; Silverman, 1988), é adaptado por algoritmos como AG e OCF para alinhar formatos de

conteúdo (visual/verbal) às preferências individuais, como em (Martins *et al.*, 2021) e (Nogueira *et al.*, 2024). Critérios como tempo disponível e carga cognitiva são otimizados por técnicas como OEP e DE para equilibrar eficiência e aprendizagem, enquanto objetivos pedagógicos são frequentemente mapeados como funções multiobjetivo em algoritmos como o NSGA-II (Nogueira *et al.*, 2024), (Wang *et al.*, 2022), (Benmesbah; Mahnane; Hafidi, 2021a), (Xiao *et al.*, 2024), (Xiao, 2024), (Li *et al.*, 2023), (Zhang *et al.*, 2022), (Benmesbah; Mahnane; Hafidi, 2021b), (Sun, 2025), (Son *et al.*, 2021), (Zheng *et al.*, 2025), (Martins *et al.*, 2021) e (Su, 2025), evidenciando a relevância de atender às necessidades dos alunos no processo de sequenciamento. A variabilidade de métodos utilizados e dos critérios pedagógicos aplicados em cada solução revela a complexidade de traduzir modelos algorítmicos em recursos pedagógicos práticos, como observado em (Paxinou *et al.*, 2024b), que analisa a subutilização de funcionalidades nativas de LMS.

Essa diversidade de critérios é sintetizada, de forma recorrente na literatura, por meio de uma função objetivo multiobjetivo que combina linearmente diferentes dimensões pedagógicas. A Seção 2.4 apresenta a formalização dessa função, adotada como base teórica deste trabalho.

2.3 Evidências de eficácia em aplicações reais

Os resultados reportados em aplicações reais de ACS com metaheurísticas revelam impactos significativos tanto no desempenho educacional quanto na eficiência operacional, embora com variações conforme a técnica e o contexto de implementação. No aspecto pedagógico, estudos como (Imamah *et al.*, 2024b) e (Xiao, 2024) demonstram melhorias médias nas notas dos alunos em comparação com métodos tradicionais. Resultados como os de (Benmesbah; Mahnane; Hafidi, 2021a) mostram ainda aumento na satisfação discente, atribuído à personalização baseada em múltiplas dimensões contextuais (tempo, formato de mídia, mobilidade).

Aplicações reais em plataformas educacionais (Paxinou *et al.*, 2024a) revelam, no entanto, desafios persistentes relacionados à integração incompleta com recursos nativos de LMS. Embora metaheurísticas como AG e OCF tenham demonstrado validação estatística significativa em melhorias de desempenho, como observado em (Imamah *et al.*, 2024b)

e (Xiao, 2024), a maioria dos estudos ainda depende de simulações ou dados históricos, como em (Su, 2025) e (Wang *et al.*, 2022) – cenário também adotado neste trabalho.

2.4 Formalização da Função Objetivo para o Sequenciamento Curricular Adaptativo Multiobjetivo

Para operacionalizar o problema de ACS descrito na Seção 2.1, este trabalho adota como base teórica a formalização proposta em uma revisão sistemática sobre metaheurísticas aplicadas ao ACS (Machado *et al.*, 2021), na qual são analisadas as funções objetivo presentes em diferentes soluções da literatura, resultando em um ranking das principais dimensões utilizadas. Embora o problema de ACS seja, por natureza, multiobjetivo – uma vez que envolve dimensões pedagógicas distintas –, este trabalho adota uma função objetivo mono-objetivo, na qual as cinco dimensões fundamentais identificadas no levantamento são combinadas linearmente em um único valor escalar a ser minimizado:

$$f(x) = \sum_{i=1}^5 \omega_i O_i(x) \quad (2.1)$$

em que O_i representa uma dimensão do problema: a cobertura de conceitos do curso pela sequência de materiais (O_1), a habilidade do estudante de acordo com os conceitos definidos (O_2), a relação entre o tempo esperado para a conclusão dos materiais e o tempo de conclusão do curso (O_3), o equilíbrio entre os materiais fornecidos pelo sequenciamento (O_4), e o estilo de aprendizagem do aluno (O_5). O termo ω_i corresponde ao peso associado à função O_i , e $x = (x_1, x_2, \dots, x_{|M|})$ é o vetor de variáveis de decisão binárias, em que M é o conjunto de materiais disponíveis.

A solução buscada corresponde ao vetor x^* que minimiza a função objetivo, isto é, $x^* = \arg \min_x f(x)$. A sequência de materiais associada a x^* corresponde, portanto, à sequência ótima $s \in S$ referida na formalização apresentada na Seção 2.1.

2.4.1 Cobertura de conceitos (O_1)

A função O_1 tem como propósito assegurar que a sequência de materiais gerada pela solução de ACS englobe todo o conjunto de conceitos essenciais definidos para o curso. Dado um conjunto de conceitos abordados pelos materiais, conforme o vetor x , define-se:

$$R(x) = \bigcup_{i=1}^{|M|} \{R^{m_i} \mid x_i = 1\} \quad (2.2)$$

em que R^{m_i} representa o conjunto de conceitos abordados pelo material m_i . Incluindo os objetivos educacionais E – os conceitos que devem ser obrigatoriamente cobertos pela sequência de materiais – e um parâmetro de ponderação $\rho \in [0, 1]$, a função O_1 é definida como:

$$O_1(x) = (1 - \rho) (|R(x)| - |R(x) \cap E|) + \rho (|E| - |R(x) \cap E|) \quad (2.3)$$

Essa função penaliza tanto a inclusão de conceitos irrelevantes quanto a ausência de conceitos necessários não cobertos, permitindo o mapeamento dos conceitos cobertos pelos materiais selecionados por meio de $R(x)$, conforme a Equação 2.2.

2.4.2 Habilidade do estudante (O_2)

A função O_2 expressa a relação entre o nível de conhecimento dos estudantes e a dificuldade intrínseca dos materiais selecionados D^{m_i} , em que $m_i \in M$. Considerando um conjunto de conceitos cobertos C , para cada material m_i , a função considera quais conceitos $c_j \in C$ são cobertos pelos materiais, indicado por $R_{c_j}^{m_i}$, sendo $R_{c_j}^{m_i} = 1$ se o material cobre o conceito c_j e $R_{c_j}^{m_i} = 0$ caso contrário. O nível de domínio dos estudantes para o conceito c_j é representado por H_{c_j} , enquanto E_{c_j} indica se o material está de acordo com os conceitos que devem ser cobertos ao longo do curso. Por conseguinte:

$$O_2(x) = \sum_{i=1}^{|M|} x_i \left| D^{m_i} - \frac{\sum_{j=1}^{|C|} R_{c_j}^{m_i} E_{c_j} H_{c_j}}{\sum_{j=1}^{|C|} R_{c_j}^{m_i} E_{c_j}} \right| \cdot \frac{1}{\sum_{i=1}^{|M|} x_i} \quad (2.4)$$

2.4.3 Duração do curso (O_3)

A função O_3 representa a dimensão temporal da função objetivo, por meio da relação entre o tempo estimado para a conclusão dos materiais propostos (T^{m_i}) e o tempo estimado do curso. Os termos $T^\downarrow$ e $T^\uparrow$ representam os limites mínimo e máximo de tempo estimados, definidos por meio da carga horária do curso ou tempo disponível pelo aluno:

$$O_3(x) = \max \left(T^\downarrow - \sum_{i=1}^{|M|} T^{m_i} x_i, 0 \right) + \max \left(0, \sum_{i=1}^{|M|} T^{m_i} x_i - T^\uparrow \right) \quad (2.5)$$

O tempo de conclusão de cada material pode ser extraído diretamente de metadados – como a duração de vídeos – ou estimado por meio de bibliotecas de programação específicas (Hofmann *et al.*, 2022).

2.4.4 Equilíbrio entre os materiais (O_4)

A função O_4 avalia se os materiais selecionados estão equilibrados quanto aos diferentes conceitos abordados no curso, penalizando situações em que alguns tópicos são mais abordados que outros:

$$O_4(x) = \sum_{j=1}^{|C|} E_{c_j} \left| \sum_{i=1}^{|M|} x_i R_{c_j}^{m_i} - \frac{\sum_{i'=1}^{|M|} \sum_{j'=1}^{|C|} x_{i'} R_{c_{j'}}^{m_{i'}} E_{c_{j'}}}{\sum_{j'=1}^{|C|} E_{c_{j'}}} \right| \quad (2.6)$$

Um valor baixo de O_4 indica que os materiais estão bem distribuídos entre os conceitos, enquanto valores altos indicam desequilíbrio.

2.4.5 Preferências de aprendizagem (O_5)

A função O_5 avalia o alinhamento entre os materiais selecionados e as preferências de aprendizagem do estudante. Embora diferentes modelos de preferência possam ser adotados, a literatura tem associado essa dimensão, com frequência, ao modelo FSLSM (Machado *et al.*, 2021). Para cada dimensão $k = 1, \dots, 4$ (Processamento, Percepção, Entrada e Compreensão), $\theta_k^{m_i}$ representa a intensidade do material m_i na dimensão k , e $L_k \in [-3, 3]$ representa a intensidade de preferência do estudante nessa mesma dimensão:

$$O_5(x) = \sum_{k=1}^4 \frac{\sum_{i=1}^{|M|} x_i |3 \operatorname{sgn}(\theta_k^{m_i}) - L_k|}{4 \sum_{i=1}^{|M|} x_i} \quad (2.7)$$

O termo $|3 \operatorname{sgn}(\theta_k^{m_i}) - L_k|$ considera a diferença absoluta entre a intensidade normalizada do material e a preferência do estudante, resultando em uma métrica normalizada entre 0 (alinhamento perfeito) e 1 (desalinhamento total). Cabe destacar que a intenção desse tipo de função objetivo é modelar características intrínsecas dos estudantes, descrevendo suas preferências; outras características do estudante podem ser utilizadas como modelo de preferência, substituindo o modelo de estilo de aprendizagem sem prejuízo da formulação geral da função objetivo.

2.5 O Moodle como ambiente para operacionalização do ACS

O Moodle consolidou-se como uma das plataformas de gestão de aprendizagem (LMS) mais utilizadas, tanto na pesquisa educacional quanto na prática pedagógica, com estudos comprovando sua eficácia como base para sistemas de aprendizagem (Gamage; Ayres; Behrend, 2022). Sua arquitetura aberta e seu conjunto de recursos nativos – incluindo planos de aprendizagem e sistema de competências – oferecem um cenário propício para a implementação de estratégias de Sequenciamento Curricular, conforme discutido a seguir.

O *Framework* de Competências do Moodle permite representar os conceitos de um curso como competências que o estudante precisa adquirir. Essa ferramenta organiza as competências em uma estrutura hierárquica com subníveis, permitindo a criação de blocos de competências que podem possuir relações entre si ou serem isoladas, dependendo do objetivo do professor ou gestor do curso. O Moodle também permite a associação manual de competências a cada material individualmente.

O Plano de Aprendizagem é o recurso do Moodle que permite associar um conjunto de competências a um grupo de usuários, criando uma relação de progresso dentro do curso à medida que cada objetivo é completado. Esse recurso possibilita medir a proficiência dos alunos ao longo do curso, funcionando como uma ferramenta útil tanto

para os alunos quanto para os professores, ao permitir uma observação individualizada do progresso de cada estudante.

Além disso, a natureza *open source* do Moodle permite a personalização da plataforma para além de seus recursos nativos, possibilitando a criação de campos personalizados associados a materiais e atividades. Esses campos viabilizam a categorização de conteúdos de acordo com metadados que não são contemplados nativamente pela plataforma, como a definição explícita de um tempo estimado de conclusão para cada material, além de criação de restrições específicas para a utilização desse recurso. Essa flexibilidade é particularmente relevante quando o tempo de conclusão não pode ser extraído automaticamente de metadados já existentes, além do nível de dificuldade dos materiais.

Por fim, os recursos nativos de interação do Moodle, como questionários (*quizzes*), também desempenham um papel relevante na coleta de dados sobre os estudantes. Os *quizzes* permitem associar o desempenho individual do aluno a cada atividade avaliativa, fornecendo uma fonte de dados objetiva para a avaliação de proficiência em competências específicas, complementar às Regras de Competência discutidas anteriormente nesta seção, e extração de preferências dos alunos, além da extração de dados sobre o perfil dos estudantes, como preferências e particularidades de disponibilidade de estudo, relevantes para adaptar o percurso do curso às características individuais do estudante.

Em conjunto, o *Framework* de Competências, os Planos de Aprendizagem, as Regras de Competência, os campos personalizados e os recursos de *quizzes* constituem os principais recursos do Moodle relevantes para a implementação de estratégias de Sequenciamento Curricular Adaptativo. O mapeamento específico entre esses recursos e as dimensões da função objetivo apresentada na Seção 2.4 é detalhado no Capítulo 4, além da especificação da extensão da plataforma para implementação de funções auxiliares.

2.5.1 SCORM e Empacotamento de Conteúdo Educacional

SCORM (*Sharable Content Object Reference Model*) é um conjunto de especificações técnicas que define como conteúdos de aprendizagem devem ser empacotados e estruturados para serem importados e executados de forma padronizada em diferentes plataformas de ensino.

Cada pacote SCORM é organizado como um arquivo compactado contendo os recursos do material (páginas, vídeos, exercícios) e um arquivo de manifesto, denominado `imsmanifest.xml`, no qual são declarados os metadados associados ao conteúdo, como título, estrutura organizacional dos recursos e sequência de navegação. O padrão SCORM incorpora, em sua especificação de metadados, o modelo IEEE LOM (*Learning Object Metadata*), permitindo que informações pedagógicas relevantes – como nível de dificuldade, tipo de recurso e tempo típico de aprendizagem – sejam declaradas de forma estruturada e padronizada dentro do próprio pacote.

Por sua ampla adoção e suporte nativo à importação de pacotes SCORM em plataformas como o Moodle, esse padrão constitui um mecanismo direto para a inserção de conteúdos educacionais previamente estruturados segundo o modelo LOM em um LMS, sem a necessidade de recriação manual dos materiais na plataforma de destino.

2.6 Técnicas Complementares de Análise de Dados

Além dos algoritmos empregados diretamente na geração das sequências curriculares, este trabalho utiliza técnicas complementares de análise de dados para investigar, de forma exploratória, padrões nos perfis de alunos e materiais e sua relação com os resultados do sequenciamento. Essas técnicas não fazem parte do processo de otimização do ACS, atuando exclusivamente na etapa de análise posterior à geração das sequências.

2.6.1 K-means

O K-means é um algoritmo de aprendizado não supervisionado utilizado para particionar um conjunto de dados em K grupos (*clusters*), de modo que elementos dentro de um mesmo grupo sejam mais semelhantes entre si do que elementos de grupos distintos. Cada *cluster* é representado por um centroide, calculado como a média dos pontos a ele atribuídos, e o algoritmo busca minimizar iterativamente a soma das distâncias euclidianas quadráticas entre cada ponto e o centroide de seu respectivo *cluster* (inércia).

O processo é iterativo e ocorre em duas etapas alternadas até a convergência: (i) atribuição, na qual cada ponto é associado ao centroide mais próximo; e (ii) atualização,

na qual cada centroide é recalculado como a média dos pontos a ele atribuídos na etapa anterior. Por depender da distância euclidiana, o K-means pressupõe implicitamente que os *clusters* tenham geometria aproximadamente convexa e dispersão semelhante no espaço de atributos, sendo sensível tanto à escala das variáveis utilizadas quanto à inicialização aleatória dos centroides – este último problema comumente mitigado pela execução do algoritmo com múltiplas inicializações distintas, das quais se seleciona a de menor inércia final.

A qualidade da partição obtida pode ser avaliada por métricas como o coeficiente de silhueta, que mede, para cada ponto, o quão bem ele se ajusta ao seu próprio *cluster* em comparação aos demais, com valores próximos de 1 indicando *clusters* bem definidos e separados, e valores próximos de 0 (ou negativos) indicando sobreposição entre grupos ou estrutura de agrupamento mal ajustada aos dados.

3 Trabalhos Relacionados

O Capítulo 2 apresentou os conceitos, algoritmos e critérios pedagógicos que fundamentam o Sequenciamento Curricular Adaptativo (ACS), bem como os recursos nativos do Moodle sobre os quais este trabalho se apoia. Partindo dessa base conceitual, o presente capítulo revisita os principais trabalhos da literatura sob um recorte complementar: o ambiente em que cada solução foi validada e o grau de proximidade desse ambiente com um LMS real em uso. Essa análise tem como objetivo situar a contribuição deste trabalho dentro do panorama atual da área.

3.1 Critério de classificação dos trabalhos

Para estruturar essa análise, os trabalhos discutidos no Capítulo 2 são organizados em três categorias, definidas de acordo com o grau de proximidade entre a solução proposta e um ambiente real de ensino baseado em LMS: (i) abordagens validadas em ambientes teóricos ou simulados; (ii) abordagens validadas com usuários reais em sistemas próprios ou fora do Moodle; e (iii) abordagens com algum grau de conexão com o Moodle. Essa categorização permite observar como diferentes trabalhos optaram por diferentes ambientes de validação, de acordo com os objetivos específicos de cada estudo.

3.1.1 Abordagens validadas em ambientes teóricos ou simulados

A primeira categoria reúne trabalhos cuja validação ocorre em ambientes simulados, com dados sintéticos ou históricos, voltados sobretudo à investigação do desempenho algorítmico em si. Wang *et al.* (2022) valida seu sistema de aprendizagem personalizada baseado em grafos de conhecimento e Evolução Diferencial em problemas simulados, com foco na qualidade da solução encontrada pelo algoritmo. De forma semelhante, Zhang *et al.* (2022) avalia sua representação de comprimento variável (VLCR) em um ambiente de avaliação controlado, o que permite isolar variáveis e comparar diferentes configurações do algoritmo com maior precisão.

Estudos comparativos entre metaheurísticas também se inserem nessa categoria: Martins *et al.* (2021) compara AG, OEP, DE e PPA sobre uma função de avaliação multivariada construída a partir de perfis de alunos, com o objetivo de identificar qual técnica apresenta melhor desempenho relativo. O mesmo tipo de abordagem é seguido por Su (2025), cujo Algoritmo Genético com Predação é validado em um cenário de tutoria inteligente simulado, e por Niknam e Thulasiraman (2020), cujo sistema de recomendação bio-inspirado (LPR) é testado em ambiente controlado. Por fim, Sun (2025) utiliza um modelo híbrido SSA-LSTM para otimizar trilhas de aprendizagem em inglês a partir de dados históricos de desempenho.

Em conjunto, esses trabalhos têm como foco principal a modelagem algorítmica do problema de ACS, priorizando a investigação de seu comportamento e desempenho computacional como etapa anterior a uma eventual aplicação prática.

3.1.2 Abordagens com usuários reais em sistemas próprios ou distintos do Moodle

A segunda categoria reúne trabalhos que avançam para a validação com estudantes reais, utilizando para isso sistemas próprios, desenvolvidos especificamente para o estudo, ou plataformas distintas do Moodle. Benmesbah, Mahnane e Hafidi (2021a) testa seu Algoritmo Genético otimizado por redes neurais com 60 alunos reais, utilizando o repositório de objetos de aprendizagem MERLOT como ambiente de validação. Já Imamah *et al.* (2024b) e Imamah *et al.* (2024a) validam, respectivamente, um modelo de OCF combinado à Teoria de Resposta ao Item e uma interface web própria, ambos desenvolvidos especificamente para os fins de cada pesquisa.

O trabalho de Xiao *et al.* (2024) relata testes com 70 alunos em um ambiente customizado, criado para suportar percursos cruzados entre cursos (*cross-course*). De forma semelhante, Xiao (2024) valida seu modelo cognitivo DINA aplicado a estudantes de inglês avançado por meio de instrumentos estatísticos (SPSS, flexCDMs). Por fim, Nogueira *et al.* (2024) aplica o NSGA-II com 24 alunos reais, disponibilizando código e dados no GitHub, uma contribuição primordial para a replicabilidade do estudo.

Esses trabalhos evidenciam que a validação com usuários reais é viável e já foi

explorada pela literatura, geralmente por meio de sistemas desenvolvidos especificamente para cada estudo, em paralelo à infraestrutura de LMS já utilizada pelas instituições de ensino.

3.1.3 Abordagens com algum grau de conexão com o Moodle

A terceira categoria reúne os trabalhos que estabelecem alguma forma de conexão com o Moodle especificamente – um recorte mais restrito, já que a maior parte da literatura sobre ACS, como discutido nas seções anteriores, não tem essa plataforma como foco. Dentro dessa categoria, observam-se diferentes formas de conexão. O trabalho de Chang, Li e Huang (2022) ilustra uma integração abrangente: os autores propuseram um sistema compatível com o Moodle 3.6.2, incorporando módulos personalizados para importar portfólios de estudantes e gerar trilhas personalizadas com base em classificação bayesiana, estendendo a plataforma com recursos de *feedback* automático, mapas de aprendizagem e monitoramento por meio da tecnologia Beacon, em um ambiente LAMP (Linux, Apache, MySQL, PHP). Trata-se de uma extensão construída sobre o Moodle, com foco no desenvolvimento de novos módulos – uma estratégia distinta da adotada neste trabalho, que parte dos recursos pedagógicos já disponíveis ou desenvolvidos na plataforma, como o *Framework* de Competências e os Planos de Aprendizagem discutidos na Seção 2.5.

Já Benmesbah, Mahnane e Hafidi (2021b) utiliza o Moodle como grupo de controle experimental, no qual alunos acessaram objetos de aprendizagem manualmente pela plataforma, enquanto a proposta adaptativa baseada em Algoritmo Genético de Agrupamento foi implementada e testada separadamente, em Python. Nesse desenho experimental, o Moodle cumpre o papel de referência de comparação para avaliar os ganhos da proposta adaptativa.

Esses trabalhos mostram que existem diferentes caminhos possíveis para relacionar soluções de ACS ao Moodle, seja por meio de ambientes complementares personalizados, seja utilizando a plataforma como ambiente de comparação. Um caminho ainda pouco explorado nessa categoria é o de utilizar recursos nativos do Moodle e extensões com um propósito mais específico: não para construir, sobre o Moodle, um novo sistema pedagógico completo, mas para complementar pontualmente os recursos já nativos da pla-

taforma – como competências, planos de aprendizagem e *tags* – e, a partir deles, extrair os dados necessários para alimentar a execução de um algoritmo de sequenciamento.

3.2 Síntese da categorização

A Tabela 3.1 resume os trabalhos discutidos, organizados de acordo com a categoria de proximidade de ecossistema, a técnica principal empregada e o ambiente de validação utilizado por cada estudo.

A categorização apresentada permite observar uma tendência geral: a maior parte dos trabalhos sobre ACS com metaheurísticas concentra seus esforços na investigação algorítmica, priorizando ambientes simulados ou sistemas desenvolvidos especificamente para cada estudo (Seções 3.1.1 e 3.1.2). Já os trabalhos que se conectam ao Moodle (Seção 3.1.3) o fazem por meio de ambientes complementares construídos sobre a plataforma, ou utilizando-a como referência de comparação experimental.

Esse contexto indica uma oportunidade pouco explorada: o Moodle já oferece, nativamente, parte considerável da infraestrutura de dados necessária para operacionalizar as cinco dimensões da função objetivo apresentada na Seção 2.4 – como discutido na Seção 2.5 –, o que sugere ser possível extrair esses dados diretamente da plataforma por meio de uma extensão de propósito específico, com foco na extração e na alimentação do algoritmo, em vez de uma extensão dedicada à construção de um sistema pedagógico completo. É nesse espaço que este trabalho se insere.

Diante do panorama apresentado, este trabalho ocupa um ponto pouco explorado dentro do espectro discutido: assim como os trabalhos da Seção 3.1.1, há aqui uma preocupação com a formulação e a execução correta da metaheurística de sequenciamento; assim como os trabalhos da Seção 3.1.2, busca-se uma validação concreta, com dados de um experimento prévio; e, assim como os trabalhos da Seção 3.1.3, este trabalho adapta o Moodle para extração dos dados necessários.

Tabela 3.1: Categorização dos trabalhos relacionados por proximidade de ecossistema

Categoria	Trabalho	Técnica principal	Ambiente de validação
Teóricas ou simuladas	(Wang <i>et al.</i> , 2022)	DE + Knowledge Graph	Ambiente simulado
	Zhang <i>et al.</i> (2022)	LSHADE-cnEpSin (DE)	Ambiente controlado
	Martins <i>et al.</i> (2021)	AG vs OEP vs DE vs PPA	Perfis de alunos simulados
	Su (2025)	PSGA (AG adaptado)	Tutoria inteligente simulada
	Niknam e Thulasiraman (2020)	OCF (LPR)	Ambiente controlado
	Sun (2025)	SSA + LSTM	Dados históricos de desempenho
Com usuários reais, fora do Moodle	Benmesbah, Mahnane e Hafidi (2021a)	AG em 2 estágios	Repositório MERLOT (60 alunos)
	Imamah <i>et al.</i> (2024b)	OCF + IRT	Plataforma própria de pesquisa
	Imamah <i>et al.</i> (2024a)	OCF dinâmico	Interface web própria
	Xiao <i>et al.</i> (2024)	LSHADE-cnEpSin + IRT	Ambiente customizado (70 alunos)
	Xiao (2024)	AG + DINA/IRT	Instrumentos estatísticos (SPSS, flexCDMs)
	Nogueira <i>et al.</i> (2024)	NSGA-II (AG multiobjetivo)	24 alunos reais, código público
	Chang, Li e Huang (2022)	Classificação Bayesiana	Extensão personalizada (Moodle 3.6.2)
Com conexão ao Moodle	Benmesbah, Mahnane e Hafidi (2021b)	AGA (AG adaptado)	Moodle como grupo de controle

4 Metodologia

Este capítulo descreve a metodologia adotada para a adaptação da plataforma Moodle, visando a preparação dos dados necessários ao ACS apresentado neste trabalho. A Seção 4.1 caracteriza o conjunto de dados históricos que serve de base para o experimento. A Seção 4.2 descreve as etapas de preparação da plataforma, comuns a todas as dimensões do ACS e apresenta, para cada recurso do Moodle utilizado, tanto sua função nativa na plataforma quanto a adaptação realizada para operacionalizar a dimensão correspondente da função objetivo. A Seção 4.3 sintetiza esse mapeamento sob a ótica de cada dimensão O_i . Por fim, a Seção 4.4 descreve o desenho experimental adotado para a execução e avaliação do algoritmo.

4.1 Caracterização do Dataset Original

Os dados utilizados neste trabalho têm origem em um experimento prévio de Sequenciamento Curricular Adaptativo, conduzido com estudantes reais de um curso de Introdução à Computação oferecido pela Universidade Federal de Juiz de Fora (UFJF). Esse experimento, descrito por Machado, Barrére e Souza (2019), propôs uma adaptação do Algoritmo Presa Predador (PPA) para o problema de ACS e teve seus dados armazenados em um banco de dados relacional, posteriormente exportado e utilizado como fonte primária para a construção deste trabalho. Diferentemente do experimento original, em que os dados foram processados diretamente a partir do banco relacional para alimentar o PPA, neste trabalho esses mesmos dados foram integralmente adaptados para popular um curso no Moodle, de modo a viabilizar sua extração por meio dos recursos da plataforma e demonstrar a adaptação dos dados para o algoritmo de sequenciamento, conforme detalhado na Seção 4.4, sendo utilizado, também, o algoritmo PPA.

4.1.1 Estrutura do currículo

O currículo abrangido pelo dataset é composto por seis disciplinas do curso de Introdução à Computação: História dos Computadores e da Computação (ICHCC), Lógica e Sistemas Numéricos (ICLSN), Fundamentos de Algoritmos (ICFA), Fundamentos de Banco de Dados e Engenharia de Software (ICFBDES), Fundamentos de Sistemas Operacionais e Organização de Computadores (ICFSOOC) e Redes de Computadores (ICRC). Ao todo, o currículo totaliza 30 conceitos distribuídos entre essas disciplinas, organizados com identificadores únicos por sigla (por exemplo, ICHCC01, ICLSN01, ICFA01), o que permite rastrear de forma direta a qual disciplina e a qual posição na hierarquia curricular cada conceito pertence. Essa divisão simula diferentes execuções do experimento, correspondentes às seis semanas do curso original, de modo que cada estudante recebe uma sequência de materiais distinta a cada semana, contemplando, de forma isolada, os conceitos referentes à disciplina daquela semana.

A distribuição dos 30 conceitos entre as disciplinas não é uniforme, variando conforme a abrangência temática de cada uma. A disciplina de História da Computação (ICHCC) é a que apresenta maior número de conceitos, com seis no total: Histórico, Gerações de Computadores, Arquitetura de Von Neumann, Big Data, Computação em Nuvem e Inteligência Artificial. A disciplina de Redes de Computadores (ICRC) é composta por cinco conceitos: Introdução a Redes, Tipos de Redes, Topologias, Protocolos e Modelos OSI/TCP-IP. Já a disciplina de Lógica e Sistemas Numéricos (ICLSN) agrupa, sob siglas próprias para cada sub-bloco temático, quatro conceitos de Sistemas Numéricos (ICSN) – Sistema Numérico, Principais Sistemas, Conversões entre Bases e Byte/Word/Unidades – e três conceitos de Lógica (ICL) – O que é Lógica, Lógica Proposicional, e Operadores Lógicos e Tabela Verdade. De forma semelhante, a disciplina de Fundamentos de Banco de Dados e Engenharia de Software (ICFBDES) reúne três conceitos de Banco de Dados (ICFBD) – Introdução a BD, Modelo Relacional e SQL – e três conceitos de Engenharia de Software (ICES) – Introdução a ES, Processos de Software e Engenharia de Requisitos. Por fim, as disciplinas de Fundamentos de Algoritmos (ICFA) e de Fundamentos de Sistemas Operacionais e Organização de Computadores (ICFSOOC) contam, cada uma, com três conceitos: respectivamente, O que é Algoritmo,

Representação de Algoritmos e Paradigmas de Programação; e O Sistema Operacional, Tipos de SO e Visão Geral do Computador.

Para os fins deste trabalho, os conceitos são tratados como independentes entre si dentro de cada disciplina, não havendo relações de pré-requisito ou dependência sequencial entre eles. Essa independência simplifica a representação do currículo na matriz binária $R_{c_j}^{m_i}$ (Seção 2.4.1): cada material pode cobrir um ou mais conceitos de uma mesma disciplina, sem que a cobertura de um conceito condicione ou seja condicionada pela cobertura de outro. Essa característica é especialmente relevante para a dimensão O_4 (equilíbrio entre os materiais), já que, na ausência de uma ordem de precedência entre os conceitos, o algoritmo de sequenciamento é livre para distribuir os materiais de forma equilibrada entre todos os conceitos obrigatórios da disciplina, sem restrições de ordenação.

4.1.2 Materiais de aprendizagem

O conjunto de materiais de aprendizagem é composto por 284 objetos de aprendizagem, descritos no formato IEEE LOM (*Learning Object Metadata*) em XML, distribuídos entre as seis disciplinas do currículo, conforme apresentado na Tabela 4.1.

Tabela 4.1: Distribuição dos materiais de aprendizagem por disciplina

Disciplina	Nº de materiais
História da Computação (ICHCC)	62
Lógica e Sistemas Numéricos (ICLSN)	56
Fundamentos de Algoritmos (ICFA)	39
Banco de Dados e Engenharia de Software (ICFBDES)	58
Sistemas Operacionais (ICFSOOC)	31
Redes de Computadores (ICRC)	38
Total	284

Para cada material, o padrão LOM registra metadados relevantes para o experimento, dentre os quais título, tipo de recurso, nível de interatividade, dificuldade e tempo típico de conclusão se destacam pela utilidade direta na composição da função objetivo do ACS.

O título e o tipo de recurso permitem identificar e categorizar cada material dentro do currículo, servindo de base para seu posterior mapeamento aos conceitos que aborda. O nível de interatividade caracteriza a forma como o estudante interage com

o conteúdo (por exemplo, leitura passiva ou exercícios práticos), informação relevante para futuras extensões do modelo que considerem o tipo de engajamento do material. A dificuldade, registrada no campo `<difficulty>` com valores *very easy*, *easy*, *medium*, *difficult* e *very difficult*, é o dado que origina o parâmetro D^{m_i} , utilizado na dimensão O_2 (habilidade do estudante) para verificar se a dificuldade do material está de acordo com o nível de domínio do estudante. Por fim, o tempo típico de conclusão, expresso no campo `<typicalLearningTime>` em formato ISO 8601 (por exemplo, PT20M29S), origina o parâmetro T^{m_i} , utilizado na dimensão O_3 (duração do curso) para verificar se a carga total de materiais selecionados é compatível com o tempo disponível do estudante. Esses dados foram adaptados de forma direta com os recursos do Moodle, especificado nas sessões seguintes.

O mapeamento de cada material aos seus respectivos conceitos é definido em arquivos CSV organizados por disciplina, contendo as colunas `material_id`, `nome` e uma coluna para cada sigla de conceito associado. Esse mapeamento constitui, em termos da formalização apresentada na Seção 2.4.1, a matriz binária $R_{c_j}^{m_i}$ utilizada pelo algoritmo para determinar quais conceitos são cobertos por cada material selecionado.

4.1.3 Perfil dos estudantes

No experimento original (Machado; Barrére; Souza, 2019), o curso foi oferecido de forma gratuita, ao longo de seis semanas, a 128 estudantes matriculados voluntariamente, em sua maioria vinculados a cursos de Ciência da Computação, Sistemas de Informação e áreas afins da UFJF. Desses, 88 completaram integralmente os questionários iniciais de caracterização, incluindo a avaliação de conhecimento prévio por conceito e o questionário ILS, e foram divididos em dois grupos experimentais: o Grupo 1, com 27 estudantes, que recebeu materiais selecionados manualmente pelo professor responsável, garantindo a cobertura dos conceitos do curso; e o Grupo 2, com 61 estudantes, que recebeu sequências de materiais geradas pela adaptação do PPA proposta no experimento original. Os demais 40 estudantes matriculados não completaram os questionários iniciais e não foram considerados na análise.

O conjunto de dados de estudantes utilizado neste trabalho contempla os perfis

desses participantes, incluindo o nível de habilidade global sobre o conteúdo dos materiais presentes no curso (habilidade $\in [0, 5]$), os tempos mínimo e máximo de estudo disponíveis (em unidades discretas) e os quatro escores do *Index of Learning Styles* (ILS), de Felder e Silverman – Ativo/Reflexivo, Sensorial/Intuitivo, Visual/Verbal e Sequencial/Global –, armazenados como valores inteiros na escala de -11 a $+11$. Por exemplo, um estudante pode ter habilidade 2 em um dos conceitos abordados no curso, disponibilidade entre 2 e 4 horas semanais, e escores ILS como Ativo (+3), Sensorial (+5), Visual (+7) e Sequencial (+1).

O nível de domínio de cada estudante em cada conceito do currículo, correspondente ao termo H_{c_j} da função objetivo, foi extraído a partir dos questionários iniciais e está registrado no banco de dados do experimento original, totalizando 2.910 registros de pares (aluno, conceito, habilidade), o que cobre, nesse trabalho, a proficiência individualizada de cada estudante em cada um dos 30 conceitos do currículo, uma vez que os conceitos foram adaptados como competências, como descrito nas próximas subseções.

Neste trabalho, as sequências originalmente recebidas pelos estudantes do Grupo 2 – geradas pela adaptação do PPA – são utilizadas como *baseline* de comparação, por meio de uma amostra de 51 estudantes com dados completos, para fins de avaliação da execução do algoritmo PPA executado no atual estudo, e mapeando dos dados no Moodle, conforme detalhado na Seção 4.4. Adotou-se como critério de exclusão para determinação da amostra os casos em que os alunos não tenham respondido um questionário inicial ou tenham informações incompletas sobre o tempo e estilo de aprendizagem, uma vez que é necessário a extração do nível de habilidade dos estudantes em relação aos conceitos trabalhados no curso e aspectos individuais de adaptação para o funcionamento completo do algoritmo de sequenciamento.

4.2 Preparação do Moodle

Para cada recurso do Moodle utilizado, as subseções a seguir apresentam tanto seu funcionamento na plataforma quanto a adaptação realizada para operacionalizar a dimensão correspondente da função objetivo, definida na Seção 2.4.

4.2.1 Importação de usuários

Os 128 estudantes do dataset original foram importados como usuários do Moodle, com seus dados pessoais e de matrícula. Desses, apenas 51 estudantes foram utilizados como amostra de referência neste trabalho, como especificado em 4.1.3.

4.2.2 Criação dos materiais como atividades SCORM

Como os materiais do dataset original já estavam organizados segundo o padrão LOM, e o Moodle oferece suporte nativo à importação de pacotes SCORM, esse formato foi adotado como solução para a inserção dos dados originais do experimento na plataforma, uma vez que o arquivo de manifesto do SCORM permite associar aos materiais os recursos de categorização disponíveis no Moodle.

Cada um dos 284 objetos de aprendizagem foi importado ao Moodle como uma atividade SCORM, organizada em seções do curso por disciplina, por meio de um *script* que lê os arquivos XML no formato LOM, gera os pacotes SCORM com os metadados embutidos (título, descrição, palavras-chave) e cria os registros correspondentes no banco de dados da plataforma. Essa importação de dados pode ser vista na Figura 4.1.



Figura 4.1: Exibição de materiais no formato SCORM para seção de Algoritmos no Moodle

Contudo, como descrito nas seções seguintes, as características mais relevantes para o ACS foram especificadas no Moodle por meio de outros recursos da plataforma, e não apenas pelos metadados embutidos no pacote SCORM. Essa escolha reflete o obje-

tivo deste trabalho de sistematizar os dados pedagógicos diretamente nas estruturas do Moodle, de modo que fiquem acessíveis e consultáveis por meio de seus próprios recursos, em vez de permanecerem encapsulados apenas em arquivos compactados cujo conteúdo não é diretamente explorável.

4.2.3 Framework de Competências: cobertura e habilidades

Os 30 conceitos do currículo foram representados por meio do *Framework* de Competências do Moodle, recurso nativo que permite organizar objetivos de aprendizagem em uma estrutura hierárquica com subníveis. Cada conceito do currículo foi cadastrado como uma competência individual, recebendo como identificador (*idnumber*) a própria sigla do conceito – o que permite rastreabilidade direta entre a competência no Moodle e o conceito original do dataset. A Figura 4.2 demonstra como as competências são exibidas dentro de um curso, uma vez criadas na estrutura de competências e associadas aos materiais.




Figura 4.2: Exibição de competências associadas a cursos no Moodle

Essa estrutura de competências viabiliza tanto a operacionalização da dimensão O_1 (cobertura de conceitos) quanto da dimensão O_2 (habilidade do estudante). Para O_1 , cada material foi associado às competências dos conceitos que aborda, por meio de *scripts* que percorrem os arquivos CSV de mapeamento material-conceito descritos na Seção 4.1, construindo na própria plataforma a matriz $R_{c_j}^{m_i}$ utilizada pelo algoritmo. Para O_2 , o

sistema de avaliação de competências do Moodle permite associar notas a competências específicas, possibilitando representar o nível de domínio do estudante (H_{c_j}) para cada conceito do currículo.

Para a operacionalização do nível de conhecimento prévio no sistema proposto, os dados foram extraídos do dataset original de Machado, Barrére e Souza (2019), caracterizado na Seção 4.1.3. O conhecimento inicial dos estudantes em cada conceito foi obtido da tabela `aluno_conceito`, que registra o campo `habilidade`, coletada no momento do cadastro, variando de 1,0 a 5,0. Para representar esse conhecimento no modelo de competências do Moodle, os valores foram mapeados para uma escala discreta de cinco níveis: Insuficiente (1), Básico (2), Intermediário (3), Avançado (4) e Especialista (5), mediante arredondamento para o inteiro mais próximo. O limiar de proficiência foi definido em grau ≥ 3 (Intermediário), indicando domínio suficiente do conceito para fins de sequenciamento. A Figura 4.3 ilustra a escala de competências configurada na plataforma.

Scale value	Default !	Proficient !
Insuficiente	☒	☐
Básico	☐	☐
Intermediário	☐	☐
Avançado	☐	☐
Expert	☐	☐

Cancel Save

Figura 4.3: Exibição de escalas associadas a competências no Moodle.

Esse mapeamento foi realizado de forma automatizada para cada par (aluno, conceito) e persistido na tabela `competency_usercomp` do Moodle por meio de *scripts* de integração. Essa estratégia permitiu integrar o perfil histórico do aprendiz ao *Framework* de Competências nativo da plataforma, fornecendo os dados necessários (H_{c_j}) para que o algoritmo de sequenciamento selecione materiais com dificuldade (D^{m_i}) calibrada ao nível de cada estudante.

4.2.4 Extensão de dificuldade dos materiais

Para representar a dificuldade de cada material (D^{m_i}), parâmetro também utilizado na dimensão O_2 , foi desenvolvido um *plugin* local para o Moodle responsável por associar níveis de dificuldade aos materiais de aprendizagem. Essa extensão foi adotada em vez do uso direto das *tags* nativas da plataforma porque estas permitem a associação de múltiplas *tags* a um mesmo material, o que é incompatível com a natureza do atributo de dificuldade, que deve assumir exatamente um valor por material. O *plugin* desenvolvido garante essa unicidade, restringindo cada material a um único nível de dificuldade dentre cinco níveis fixos do padrão LOM (*Very Easy*, *Easy*, *Medium*, *Difficult* e *Very Difficult*), cujo gerenciamento é realizado por meio da própria interface de administração de *plugins* locais do Moodle, conforme ilustrado na Figura 4.4.



Figura 4.4: Gerenciamento do *plugin* de dificuldade.

A associação entre os materiais e os níveis de dificuldade definidos no *plugin* é realizada por meio de um *script* que percorre os arquivos XML LOM de cada disciplina, extrai o valor do campo `<difficulty>` e associa o nível correspondente à atividade SCORM no Moodle; essa classificação é posteriormente normalizada para o intervalo $[0, 1]$ ao ser consumida pelo algoritmo. A Figura 4.5 demonstra a associação dos níveis de dificuldade aos materiais, uma vez que todos os níveis foram previamente cadastrados na extensão.

Dificuldade ? Medium ▼

☐ Send content change notification ?

Save and return to course Save and display Cancel

! Required

Figura 4.5: Associação de dificuldade aos materiais.

4.2.5 Extensão de tempo estimado para materiais

Como o Moodle não possui, nativamente, um campo para o tempo estimado de conclusão de um material, foi desenvolvida uma extensão (*plugin*) que adiciona esse campo ao formulário de criação e edição de materiais, armazenando o valor em uma tabela própria do *plugin*. No padrão LOM, o tempo estimado de cada material é registrado no campo `<typicalLearningTime>` no formato ISO 8601 (por exemplo, PT20M29S), pouco adequado para inserção e leitura direta por um administrador de curso. Por esse motivo, o *plugin* desenvolvido armazena e exibe esse valor em minutos, formato mais direto e de fácil interação pela interface do Moodle. Para popular esse campo a partir dos dados do experimento original, um *script* complementar lê o campo `<typicalLearningTime>` dos arquivos XML LOM, converte o valor do formato ISO 8601 para minutos e popula a tabela correspondente, compondo o parâmetro T^{m_i} utilizado na dimensão O_3 da função objetivo (Seção 2.4.3). A Figura 4.6 apresenta a extensão desenvolvida, com a especificação do tempo estimado para conclusão de um material, em minutos.

Metadados LOM do SCORM

Tempo estimado ? (min) 9

Figura 4.6: Recurso para inserir tempo estimado para materiais.

4.2.6 Planos de Aprendizagem: acompanhamento individualizado

Os Planos de Aprendizagem (*Learning Plans*) do Moodle foram utilizados para associar o conjunto de competências do currículo aos alunos, além de operacionalizar o progresso individual de cada estudante de acordo com o conjunto de competências do currículo. Por meio desse recurso, cada aluno passa a ter um plano próprio, vinculado ao curso, permitindo o acompanhamento individualizado de sua proficiência ao longo do tempo. A Figura 4.7 apresenta a visualização detalhada do plano de aprendizado de um aluno.




Figura 4.7: Visão detalhada de um plano de aprendizagem associado a um aluno

É importante destacar que a adoção do ACS não elimina a relevância do acompanhamento pedagógico exercido pelo professor; pelo contrário, os dois mecanismos operam de forma complementar. Enquanto o algoritmo de sequenciamento atua na seleção automatizada dos materiais mais adequados ao perfil de cada estudante, o Plano de Aprendizagem permanece disponível como instrumento de supervisão, permitindo ao professor identificar, a qualquer momento, o nível de proficiência individual alcançado por cada aluno em cada competência do currículo. Dessa forma, mesmo com o sequenciamento

operando de maneira automática, o professor continua tendo acesso a uma visão clara do progresso de cada estudante, podendo identificar casos que exijam atenção pedagógica adicional – como alunos com dificuldade persistente em determinadas competências, mesmo após a exposição aos materiais selecionados pelo ACS – e intervir de forma direcionada, sem depender exclusivamente da lógica de otimização do algoritmo.

4.2.7 Questionários para preferências de aprendizagem

A dimensão O_5 (preferências de aprendizagem) tem como objetivo modelar características intrínsecas dos estudantes para descrever suas preferências durante o processo de ensino. Embora o modelo FSLSM (Felder; Silverman, 1988) seja amplamente adotado na literatura de ACS, a formulação geral da função objetivo, apresentada na Seção 2.4.5, permite a substituição ou complementação por outros modelos de preferência, sem prejuízo à lógica de otimização.

Diversos autores exploram parâmetros alternativos para a personalização, tais como traços de personalidade baseados no modelo *Big Five*, níveis de engajamento e motivação, e até mesmo o histórico de acesso do usuário por meio de fatoração de matrizes. Destaca-se, ainda, a possibilidade de adaptar a seleção de materiais à estabilidade emocional e à competência do aprendiz, conforme proposto por Alhathli, Masthoff e Beacham (2020).

Como o dataset original deste trabalho já contava com perfis populados conforme o FSLSM, optou-se por operacionalizar a dimensão O_5 por meio de questionários nativos do Moodle correspondentes ao ILS de Felder e Silverman. Esses questionários permitem capturar, diretamente na plataforma, os escores do estudante nas quatro dimensões do modelo – Ativo/Reflexivo, Sensorial/Intuitivo, Visual/Verbal e Sequencial/Global –, que alimentam o cálculo do termo L_k da função objetivo. O questionário, obtido a partir do site oficial do ILS² e dividido em quatro partes no Moodle, é composto por 44 questões dicotômicas (11 por dimensão).

Para cada dimensão, o escore é calculado como a diferença entre as respostas do tipo b (polo reflexivo, intuitivo, verbal ou global) e do tipo a (polo ativo, sensorial,

²Disponível em: <https://learningstyles.webtools.ncsu.edu/>. Acesso em: 24 jun. 2026.

visual ou sequencial), resultando em valores no intervalo $[-11, +11]$. Escores negativos indicam preferência pelo primeiro polo, enquanto escores positivos indicam o segundo, com a intensidade da preferência variando entre leve (1 a 3), moderada (5 a 7) e forte (9 a 11). A Figura 4.8 demonstra a interface desses questionários implementada.



Figura 4.8: Questionários no Moodle para identificação do estilo de aprendizado

4.2.8 Questionários para disponibilidade de tempo

Para identificar o tempo mínimo e máximo de disponibilidade semanal de cada estudante para o estudo – parâmetros $T^\downarrow$ e $T^\uparrow$, também utilizados na dimensão O_3 –, foi utilizado um formato de questionário especial do Moodle: o módulo *Feedback*. A Figura 4.9 apresenta o formato desse questionário.

Disponibilidade de Estudo


A screenshot of a Moodle Feedback form titled 'Disponibilidade de Estudo'. At the top right is a blue 'Continue' button. Below the title, a small note says 'Mode: User's name will be logged and shown with answers'. There are two numbered text input fields: '1. Tempo mínimo de disponibilidade (horas)' and '2. Tempo máximo de disponibilidade (horas)'. Both fields have a red required icon. At the bottom left, there is a red required icon and the text 'Required'. At the bottom right, there is another blue 'Continue' button.

Figura 4.9: Questionário no Moodle para identificação da disponibilidade de tempo

Um questionário denominado “Disponibilidade de Estudo” foi oferecido no ambiente virtual do curso, contendo dois campos de resposta aberta: tempo mínimo de disponibilidade (em horas) e tempo máximo de disponibilidade (em horas).

As respostas foram registradas de forma nominal, vinculadas ao perfil de cada estudante, permitindo que o sistema de sequenciamento adaptativo acessasse individualmente esses valores para compor o perfil do aprendiz. Os dados coletados por esse questionário foram utilizados como parâmetros de entrada no algoritmo de sequenciamento, delimitando o intervalo de carga de estudo compatível com a disponibilidade declarada pelo próprio estudante.

4.3 Síntese do Mapeamento

Com as adaptações descritas na Seção 4.2, cada uma das cinco dimensões da função objetivo apresentada na Seção 2.4 passa a ser operacionalizável. Esta seção sintetiza esse mapeamento sob a ótica de cada dimensão O_i , detalhando a correspondência entre as variáveis das formulações apresentadas na Seção 2.4 e os recursos do Moodle a partir dos quais elas são obtidas.




Figura 4.10: Visão geral do processo de adaptação do Moodle e geração de sequências.

A Figura 4.10 sintetiza, em quatro etapas, o processo descrito ao longo deste capítulo. A infraestrutura do Moodle reúne os quatro recursos adaptados na Seção 4.2: o *Framework* de Competências, utilizado para representar os conceitos do currículo e a proficiência dos estudantes (Seção 4.2.3); os *plugins* desenvolvidos para suprir metadados não nativos da plataforma, como dificuldade e tempo estimado dos materiais (Seções 4.2.4 e 4.2.5); os materiais em formato SCORM, responsáveis por empacotar o conteúdo educacional segundo o padrão LOM; e os questionários nativos do Moodle, utilizados para capturar o estilo de aprendizagem e a disponibilidade de tempo de cada estudante (Seção 4.2.7). A partir desses recursos, os dados são extraídos diretamente do banco de dados da plataforma e organizados nos arquivos de instância exigidos pelo algoritmo de sequenciamento. Esses arquivos alimentam a execução do PPA, realizada em um ambiente externo ao Moodle, conforme detalhado na Seção 4.4, cujo resultado final é a geração das sequências de materiais personalizadas para cada estudante, analisadas no Capítulo 5.

A dimensão O_1 (cobertura de conceitos) é operacionalizada por meio do *Framework* de Competências do Moodle. Cada conceito do currículo é cadastrado como uma competência individual, e a matriz de associação $R_{c_j}^{m_i}$ é construída vinculando os materiais de aprendizagem às competências que eles abordam: o valor é 1 quando existe um vínculo técnico entre o material e a competência correspondente no Moodle, e 0 caso contrário. O conjunto de objetivos educacionais E corresponde, por sua vez, à totalidade das competências cadastradas para cada disciplina.

A dimensão O_2 (habilidade do estudante) combina dois recursos distintos da plataforma. A dificuldade de cada material (D^{m_i}) é obtida da extensão de dificuldade desenvolvida para o Moodle, que classifica os materiais em níveis de dificuldade customizados, mapeados numericamente para o intervalo $[0, 1]$. Já a proficiência do estudante em cada conceito (H_{c_j}) é obtida da estrutura de avaliação de competências do Moodle, registrada na tabela `competency_usercomp` a partir dos dados históricos de habilidade do aluno, mapeados para os cinco níveis de proficiência (Insuficiente a Especialista).

A dimensão O_3 (duração do curso) é calculada a partir de dois parâmetros temporais obtidos de fontes complementares. O tempo estimado de cada material (T^{m_i}) é

suprido pela extensão de tempo estimado desenvolvida para o Moodle, que adiciona o campo correspondente ao *Typical Learning Time* do padrão LOM às atividades SCORM. Já os limites de tempo disponível de cada estudante ($T^\downarrow$ e $T^\uparrow$) são coletados diretamente por meio do módulo *Feedback* do Moodle, a partir do questionário de disponibilidade de estudo preenchido pelo próprio aluno.

A dimensão O_4 (equilíbrio entre os materiais) é obtida diretamente da mesma matriz de associação entre materiais e competências utilizada para O_1 . Essa associação permite ao algoritmo contabilizar, para cada conceito obrigatório, quantos materiais selecionados o abordam, possibilitando identificar e penalizar distribuições desproporcionais de materiais entre os conceitos ao longo da sequência gerada.

Por fim, a dimensão O_5 (preferências de aprendizagem) relaciona duas fontes de dados. A intensidade de preferência do estudante em cada dimensão do FSLSM (L_k) é calculada a partir das respostas do estudante ao questionário ILS, integrado nativamente ao Moodle. Já a intensidade de cada material em relação a essas mesmas dimensões ($\theta_k^{m_i}$) é inferida a partir dos metadados dos arquivos LOM/SCORM importados, que indicam se o recurso favorece um perfil mais visual ou verbal, ativo ou reflexivo, conforme as quatro dimensões do modelo.

A Tabela 4.2 sintetiza essa correspondência entre as variáveis das formulações da função objetivo e os recursos do Moodle a partir dos quais elas são extraídas.

Após a preparação e mapeamento no Moodle, os dados são extraídos sistematicamente por meio de consultas diretas ao banco de dados e organizados em arquivos de instância, servindo de entrada para o motor de otimização responsável pela geração dos percursos adaptativos, conforme detalhado na Seção 4.4.

Concluídas as etapas de adaptação da plataforma, é feita a extração dos dados estruturados do Moodle, por meio de consulta direta ao banco de dados da plataforma, organizando-os nos formatos exigidos pelo algoritmo de sequenciamento: um arquivo com o perfil dos estudantes (incluindo tempos disponíveis, escores ILS e objetivos de aprendizagem por conceito), um arquivo com a proficiência de cada estudante por conceito, e arquivos de instância para cada disciplina. Esses arquivos constituem a entrada para a execução do PPA responsável pela geração das sequências de materiais, descrita na Seção

Tabela 4.2: Mapeamento entre as variáveis da função objetivo e os recursos do Moodle

Variável	Significado pedagógico	Recurso correspondente
$R_{c_j}^{m_i}$	Relação material-conceito	Vínculos no <i>Framework</i> de Competências
E	Objetivos educacionais da disciplina	Competências cadastradas no <i>Framework</i> de Competências
D^{m_i}	Dificuldade do material	Extensão de dificuldade customizada (<i>plugin</i> local)
H_{c_j}	Habilidade/proficiência do estudante	Sistema de avaliação de competências (tabela <code>competency_usercomp</code>)
T^{m_i}	Tempo estimado do material	Extensão de tempo estimado (<i>plugin local scorm_lom</i>)
$T^\downarrow, T^\uparrow$	Janela de tempo disponível do estudante	Módulo <i>Feedback</i> (questionário de disponibilidade de estudo)
L_k	Intensidade de preferência do estudante	Módulo de questionário (instrumento ILS)
$\theta_k^{m_i}$	Suporte do material a cada estilo	Metadados inferidos dos arquivos LOM/SCORM

4.4. O código-fonte dos *scripts* de adaptação, extração e execução, bem como o *plugin* desenvolvido para o Moodle, está disponível publicamente em um repositório no GitHub³.

4.4 Desenho Experimental e Avaliação

A função objetivo total, definida na Seção 2.4 como $f(x) = \min \sum_{i=1}^5 \omega_i O_i(x)$, é minimizada pelo algoritmo PPA sobre o vetor binário de decisão $x = (x_1, \dots, x_{|M|})$, em que cada posição indica se o material correspondente é incluído (1) ou não (0) na sequência gerada para um determinado estudante. Cada componente O_i representa um desvio em relação ao perfil ideal do estudante, de modo que valores menores de $f(x)$ correspondem a sequências mais aderentes às cinco dimensões pedagógicas descritas na Seção 2.4. O algoritmo é executado por disciplina, utilizando instâncias independentes com os materiais e os estudantes daquela disciplina, conforme os arquivos extraídos do Moodle na etapa descrita na Seção 4.3.

A escolha do PPA como algoritmo de otimização neste trabalho se justifica, em primeiro lugar, pela necessidade de estabelecer uma base de comparação direta com o

³Disponível em: <https://github.com/luizamc003/ACS-moodle>. Acesso em: 23 jun. 2026.

experimento original descrito por Machado, Barrére e Souza (2019), que também utiliza essa metaheurística para a geração das sequências adaptativas do Grupo 2 (Seção 4.1.3). A implementação do PPA utilizada neste trabalho segue a proposta de (Martins *et al.*, 2021), adaptada para operar sobre os arquivos de instância extraídos do Moodle conforme descrito na Seção 4.3.

Para cada estudante, o algoritmo foi executado 5 vezes por disciplina, com critério de parada por estagnação, definido como 100 iterações consecutivas sem melhora na função de *fitness* e com sementes fixas para cada rodada. As sequências de materiais geradas nessas execuções são posteriormente comparadas com as sequências de materiais do experimento original, descritas na Seção 4.1.3, segundo duas perspectivas: (i) o desempenho médio e a estabilidade do *fitness* obtido pelo PPA executado sobre os dados extraídos do Moodle, por disciplina; e (ii) a diferença entre os valores de *fitness* e os materiais selecionados nas sequências geradas neste trabalho em relação às sequências de referência do experimento original, conforme detalhado no Capítulo 5.

5 Resultados

Este capítulo apresenta os resultados obtidos a partir da execução do algoritmo PPA sobre os dados extraídos do Moodle, conforme o desenho experimental descrito na Seção 4.4. As análises estão organizadas em quatro partes: (i) desempenho do experimento PPA por disciplina; (ii) comparação com o experimento de referência ; (iii) caracterização dos materiais mais selecionados; e (iv) clusterização dos alunos e materiais.

5.1 Desempenho do Experimento PPA

O algoritmo PPA foi executado cinco vezes por estudante por disciplina, totalizando 1.530 execuções ($51 \text{ alunos} \times 6 \text{ disciplinas} \times 5 \text{ rodadas}$). Para cada aluno e disciplina, o *fitness* médio das cinco rodadas foi calculado e utilizado como medida de desempenho. Cada execução utilizou semente fixada, com critério de parada por estagnação definido como 100 iterações consecutivas sem melhora no *fitness*.

A Tabela 5.1 apresenta, por disciplina, a média e o desvio padrão do *fitness* entre os alunos, o intervalo observado e o desvio padrão médio entre as cinco execuções de um mesmo aluno. A variável N representa a quantidade de alunos em cada disciplina.

Tabela 5.1: Estatísticas do *fitness* médio por disciplina — Experimento PPA

Disciplina	N	Média	DP entre alunos	Mín	Máx	DP médio entre execuções
ICFA	51	66,99	5,68	61,25	82,25	0,46
ICFBDES	51	61,99	0,87	60,35	65,89	0,68
ICFSOOC	51	64,19	1,40	61,73	68,03	1,06
ICHCC	51	63,40	3,29	60,06	72,67	0,69
ICLSN	51	62,33	1,83	60,32	67,67	0,97
ICRC	51	64,93	2,91	61,67	73,61	1,33

A coluna Média representa a média, entre os 51 alunos, do *fitness* médio individual de cada um – ou seja, a média das médias –, refletindo o nível geral de penalidade produzido pelo PPA para aquela disciplina (valores menores indicam sequências mais aderentes ao perfil dos estudantes, uma vez que o *fitness* representa uma penalidade a ser minimizada). A coluna DP entre alunos corresponde ao desvio padrão, entre os 51

alunos, de seus *fitness* médios individuais, medindo o quão heterogêneo é o desempenho do algoritmo de aluno para aluno dentro de uma mesma disciplina. As colunas Mín e Máx indicam, respectivamente, o menor e o maior valor de *fitness* médio individual observados entre os alunos da disciplina, delimitando o intervalo de desempenho do algoritmo na amostra.

Por fim, a coluna DP médio entre execuções inverte a ordem das agregações: calcula-se primeiro o desvio padrão das cinco rodadas de cada aluno individualmente, e em seguida a média desses desvios entre todos os alunos da disciplina. Diferentemente das demais colunas, essa métrica não descreve a variabilidade entre estudantes, mas sim a estabilidade e a reprodutibilidade do próprio algoritmo – isto é, o quanto o resultado do PPA varia entre execuções distintas para um mesmo aluno, sob sementes aleatórias diferentes. Valores baixos nessa coluna indicam que o algoritmo converge de forma consistente, independentemente da semente utilizada. Em síntese, as colunas Média, DP entre alunos, Mín e Máx descrevem a variabilidade *entre* estudantes – isto é, o quão uniforme é o desempenho do algoritmo ao longo da turma –, enquanto o DP médio entre execuções descreve a variabilidade *intra-aluno* entre rodadas, evidenciando dois eixos de análise distintos e complementares.

Observa-se que a disciplina ICFBDES (BD e Engenharia de Software) apresentou a menor média de *fitness* (61,99) e o menor desvio padrão entre alunos (DP = 0,87), indicando que o algoritmo gerou sequências mais aderentes ao perfil dos estudantes e com menor variação entre eles. Em contrapartida, ICFA (Fundamentos de Algoritmos) obteve a maior média (66,99) e o maior desvio padrão (5,68), sugerindo que as sequências geradas para essa disciplina se afastaram mais do perfil ideal dos alunos e com maior variabilidade entre eles.

A análise anterior pode ser observada ao decompor o *fitness* em seus cinco componentes (cobertura de conceitos, dificuldade, tempo, balanceamento de materiais e estilo de aprendizagem). Observa-se que o afastamento verificado em ICFA concentra-se majoritariamente na penalidade de cobertura de conceitos (média de 54,08, contra 48,97 em ICFBDES), que isoladamente responde pela maior parte da diferença entre as médias totais das duas disciplinas. A penalidade de tempo também se mostrou mais expressiva em

ICFA (1,44 contra 0,09), indicando sequências cuja duração total se desviou com maior frequência dos limites estabelecidos para os alunos. Em contrapartida, o componente de balanceamento entre conceitos foi ligeiramente melhor em ICFA (7,29 contra 9,16), o que descarta esse fator como causa do afastamento observado. Esses resultados sugerem que, para ICFA, a estrutura de pré-requisitos conceituais e/ou a disponibilidade de materiais que cubram adequadamente os conceitos exigidos pelo perfil dos alunos foi o principal fator limitante da qualidade das sequências geradas, e não as características individuais de estilo de aprendizagem ou nível de dificuldade dos alunos. A Figura 5.1 ilustra essa decomposição para todas as disciplinas, evidenciando a predominância da cobertura de conceitos como componente majoritário do *fitness* em todos os casos, e o destaque da penalidade de tempo como fator adicional.




Figura 5.1: Decomposição do *fitness* médio por disciplina.

Quanto à estabilidade do algoritmo ao longo das cinco execuções, os desvios padrão médios entre os alunos são baixos em todas as disciplinas (variando de 0,46 a 1,33), o que evidencia a reprodutibilidade das soluções geradas pelo PPA. Esse comportamento é esperado em metaheurísticas com critério de parada por estagnação, nas quais a diversidade das execuções é limitada quando o espaço de busca está bem explorado.

A Figura 5.2 apresenta a distribuição do *fitness* médio (média das cinco rodadas) por disciplina. ICFA destaca-se visualmente pela maior amplitude interquartil e pelos valores mais elevados de mediana, reflexo direto do maior desvio padrão entre alunos

(DP,=,5,68) observado na Tabela 5.1. Como a função objetivo é minimizada, valores mais altos indicam maior penalidade, sugerindo que nessa disciplina o algoritmo encontrou mais dificuldade em adequar as sequências ao perfil dos alunos. As demais disciplinas apresentam menor variação das distribuições, com medianas próximas e mais baixas, indicando que o algoritmo convergiu para soluções de menor penalidade e mais uniformes entre os estudantes.




Figura 5.2: Distribuição do *fitness* médio (5 rodadas) por disciplina — Experimento PPA. Cada ponto representa a média das cinco execuções de um aluno.

A Figura 5.3 detalha a distribuição do *fitness* separada por execução dentro de cada disciplina, permitindo avaliar a estabilidade entre os alunos ao longo das cinco iterações. Em todas as disciplinas, a sobreposição quase total das caixas entre as rodadas confirma a baixa variabilidade entre alunos reportada na Tabela 5.1 (DPs entre 0,46 e 1,33). Isso indica que, dadas as mesmas condições de instância e perfil de aluno, o PPA tende a convergir para soluções de qualidade equivalente em execuções distintas, o que valida a representatividade do *fitness* médio como métrica de desempenho consolidada.

5.2 Comparação com o Experimento de Referência

Os resultados do experimento PPA foram comparados com as sequências de referência do experimento original, que correspondem às sequências geradas pela adaptação do PPA




Figura 5.3: Distribuição do *fitness* por execução e disciplina — Experimento PPA. A sobreposição das caixas entre rodadas evidencia a estabilidade do algoritmo.

descrita em Machado, Barrère e Souza (2019) e disponíveis para os mesmos 51 estudantes. Como o experimento PPA produziu cinco rodadas por estudante, utilizou-se a média do *fitness* das cinco rodadas como valor representativo de cada estudante, de modo que a comparação entre os dois experimentos foi realizada com 51 pares de valores por disciplina (*fitness* médio do PPA vs. *fitness* do experimento de referência, por aluno).

Antes de aplicar o teste estatístico de comparação, foi verificada a normalidade das diferenças pareadas de *fitness* por aluno em cada disciplina, utilizando o teste de Shapiro-Wilk. Em quatro das seis disciplinas (ICFA, ICFSOOC, ICHCC e ICRC), o teste rejeitou a hipótese de normalidade ($p < 0,05$); nas demais (ICFBDES e ICLSN), a hipótese de normalidade não foi rejeitada. Como o teste- t pareado pressupõe que as diferenças sigam uma distribuição normal, optou-se pelo teste de Wilcoxon para amostras pareadas (*signed-rank*), não-paramétrico, aplicado uniformemente às seis disciplinas por consistência metodológica. A Tabela 5.2 apresenta a média e o desvio padrão do *fitness* de cada experimento por disciplina ($N = 51$ em ambos), bem como a diferença absoluta entre as médias (Δ) e o p -valor do teste de Wilcoxon.

A diferença foi estatisticamente significativa em todas as disciplinas ($p < 0,05$). A redução foi mais expressiva em ICFA ($\Delta = -9,65$) e menos pronunciada em ICFBDES

Tabela 5.2: Comparação do *fitness* médio por disciplina: Experimento PPA vs. experimento de referência

Disciplina	Experimento PPA		Referência		Δ	<i>p</i> -valor*
	Média	DP	Média	DP		
ICFA	66,99	5,68	76,65	9,70	-9,65	<0,001
ICFBDES	61,99	0,87	64,14	4,22	-2,16	0,005
ICFSOOC	64,19	1,40	69,41	7,03	-5,22	<0,001
ICHCC	63,40	3,29	70,07	8,44	-6,68	<0,001
ICLSN	62,33	1,83	67,14	7,01	-4,81	<0,001
ICRC	64,93	2,91	70,50	9,22	-5,57	<0,001

*Teste de Wilcoxon pareado por aluno.

($\Delta = -2,16$).

Além da diferença nas médias, destaca-se que o experimento de referência apresenta desvios padrão consideravelmente maiores entre alunos (entre 4,22 e 9,70) em comparação ao experimento PPA (entre 0,87 e 5,68). Isso indica que o experimento PPA convergiu para soluções mais consistentes entre os estudantes, enquanto o experimento de referência apresentou maior variação nos valores de *fitness* entre alunos. Essa diferença é plausivelmente associada a distinções na parametrização entre os dois experimentos: a implementação do PPA utilizada neste trabalho segue a formulação de (Martins *et al.*, 2021), distinta da empregada originalmente por Machado, Barrère e Souza (2019), podendo diferir em aspectos como critério de parada, tamanho de população e demais parâmetros do algoritmo.

5.3 Materiais Mais Seleccionados e Interseção entre Experimentos

Para cada disciplina, os dez materiais com maior frequência de aparição nas sequências geradas foram identificados em cada experimento. A Tabela 5.3 apresenta o número de materiais em comum entre os dois experimentos para cada disciplina.

A baixa sobreposição média (18%) entre os materiais mais frequentes dos dois experimentos indica que os algoritmos exploraram partes distintas do espaço de materiais disponíveis. A exceção mais expressiva é ICFSOOC (Sistemas Operacionais e Organização de Computadores), na qual 6 dos 10 materiais mais seleccionados são comuns

Tabela 5.3: Interseção dos 10 materiais mais seleccionados por disciplina

Disciplina	Materiais em comum	Percentual
ICFA	1	10%
ICFBDES	1	10%
ICFSOOC	6	60%
ICHCC	0	0%
ICLSN	0	0%
ICRC	3	30%
Média	1,8	18%

aos dois experimentos, sugerindo que, nessa disciplina, há um conjunto de materiais com características claramente mais adequadas ao perfil médio dos alunos, independentemente da configuração do algoritmo.

No experimento atual, o material mais seleccionado em ICFA foi o material 26 (presente em 90,2% das sequências), com dificuldade média (nível 3). Em ICRC, o material 37 apareceu em 64,7% das sequências, com dificuldade baixa (nível 2). Esse padrão de preferência por materiais de dificuldade média a baixa é consistente com o perfil geral dos alunos da amostra, cuja habilidade média varia entre 1,1 e 3,5 nas dimensões avaliadas.

A Figura 5.4 detalha os dez materiais mais seleccionados em cada disciplina para os dois experimentos. Cada barra representa a proporção de alunos que recebeu aquele material em sua sequência; materiais destacados em verde aparecem no top-10 de ambos os experimentos simultaneamente.

A figura permite visualizar tanto a concentração de seleção em poucos materiais (como o material 26 em ICFA, presente em mais de 90% das sequências do experimento PPA) quanto a divergência entre os dois experimentos nas disciplinas com menor sobreposição (ICHCC e ICLSN, sem nenhum material em comum). Em ICFSOOC, a convergência é evidente: seis materiais em verde aparecem com frequências próximas nos dois experimentos, indicando que essa disciplina possui um subconjunto de materiais com características objetivamente mais adequadas ao perfil da amostra, reconhecido de forma consistente pelos dois algoritmos.




Figura 5.4: Top 10 materiais mais seleccionados por disciplina nos experimentos PPA e de referência.

5.4 Clusterização dos Alunos e dos Materiais

Esta seção tem como objetivo investigar, de forma exploratória, se é possível identificar alguma correspondência entre os perfis de alunos e os perfis de materiais selecionados pelo algoritmo. Como o PPA otimiza a sequência de cada estudante de forma individual, sem operar sobre nenhuma estrutura de agrupamento entre alunos ou materiais, busca-se verificar se, ainda assim, alunos de um mesmo perfil de *cluster* tendem a receber materiais com características semelhantes, ou se essa correspondência não se manifesta de forma clara nos dados.

Para essa investigação, alunos e materiais foram agrupados separadamente por meio do algoritmo K-means, e os *clusters* resultantes foram posteriormente cruzados com o *fitness* médio obtido por disciplina, permitindo avaliar se alunos de um mesmo perfil de *cluster* apresentam desempenho e padrões de seleção de materiais semelhantes entre si.

5.4.1 Clusterização dos alunos

A clusterização dos 51 alunos foi realizada com base em seis atributos de perfil: as quatro dimensões do modelo Felder-Silverman (Ativo/Reflexivo, Sensorial/Intuitivo, Visual/Verbal, Sequencial/Global), a habilidade média e o tempo médio disponível. O número ótimo de grupos foi determinado pelo *silhouette score*, que apontou $K = 6$ como melhor configuração (pontuação de silhueta = 0,205). A Tabela 5.4 apresenta o perfil médio de cada *cluster* nas seis dimensões avaliadas.

Tabela 5.4: Perfil médio dos *clusters* de alunos (escala ILS: -11 a +11)

Cluster	Ativo/Reflex.	Sensor./Intuit.	Visual/Verbal	Sequen./Global	Habilidade	Tempo
C0 (n=13)	+1,15	+1,69	+1,69	+1,38	1,93	4,00
C1 (n=9)	+0,44	+1,11	-1,78	+1,22	1,88	2,22
C2 (n=14)	-1,14	+1,57	+1,14	-0,71	1,89	2,04
C3 (n=5)	+1,60	+1,80	+0,60	+0,60	3,50	3,10
C4 (n=6)	+1,17	-1,17	+1,50	+1,00	2,06	3,17
C5 (n=4)	-1,50	+1,00	+0,25	+0,25	3,17	9,00

Os *clusters* com maior habilidade prévia são C3 e C5, com médias de 3,50 e 3,17, respectivamente. C5 se destaca ainda pelo elevado tempo disponível (9 horas), o que os distingue claramente dos demais grupos. Os Clusters C0, C1, C2 e C4 têm habilidades médias próximas (entre 1,88 e 2,06), diferenciando-se principalmente pelas dimensões de

estilo de aprendizagem. C1, por exemplo, é o único *cluster* com escore negativo em Visual/Verbal ($-1,78$), indicando preferência pelo polo verbal, enquanto C2 é o único com escore negativo em Ativo/Reflexivo ($-1,14$), apontando para perfis mais reflexivos.

O valor de silhueta relativamente baixo (0,205) indica que a estrutura dos dados não se ajusta bem ao formato de agrupamento pressuposto pelo K-means. Isso não significa necessariamente que os alunos não possam ser agrupados em perfis distintos, mas sim que, nas dimensões avaliadas, tais grupos – se existentes – podem não apresentar essa geometria específica, o que é plausível em dados de estilo de aprendizagem autodeclarado, cuja distribuição não segue necessariamente uma organização convexa no espaço de atributos. Ainda assim, a clusterização permite identificar grupos com características pedagógicas distintas, úteis para a análise qualitativa das sequências geradas.

5.4.2 Clusterização dos materiais

Para cada disciplina, os materiais foram agrupados separadamente em três clusters ($K = 3$) por meio do algoritmo K-Means, aplicado sobre os atributos pedagógicos padronizados (*z-score*): dificuldade, as quatro dimensões do modelo Felder-Silverman (ativo/reflexivo, sensorial/intuitivo, visual/verbal, sequencial/global), interatividade e tipo de material. Como o conjunto de materiais é específico de cada disciplina, a clusterização não pôde ser feita sobre um pool único, sendo necessário repetir o procedimento individualmente para cada uma das seis disciplinas.

O valor $K = 3$ foi fixado de forma uniforme entre todas as disciplinas, em vez de se adotar o número ótimo de clusters segundo o *silhouette score* para cada disciplina individualmente. Essa escolha se justifica por três razões. Primeiro, a comparabilidade entre disciplinas: manter o mesmo K permite que os clusters (por exemplo, Cluster 0, 1 e 2) tenham um significado consistente — via de regra, materiais de dificuldade e interatividade baixa, média e alta — possibilitando a análise cruzada entre o cluster de perfil do aluno e o cluster de material selecionado, o que não seria possível caso cada disciplina apresentasse uma quantidade distinta de clusters. Segundo, a interpretabilidade pedagógica: três grupos correspondem naturalmente a uma leitura qualitativa de baixo/médio/alto, mais adequada à discussão dos resultados do que uma granularidade

maior. Terceiro, o tamanho amostral: as disciplinas do experimento possuem entre 31 e 62 materiais: valores de K mais altos, ainda que eventualmente favorecidos pelo *silhouette score* em disciplinas específicas, resultariam em clusters pequenos e pouco robustos estatisticamente, especialmente nas disciplinas com menor número de materiais.

Tabela 5.5: Dificuldade e interatividade médias dos *clusters* de materiais por disciplina ($K = 3$)

Disciplina	Cluster	Dificuldade média	Interatividade média
ICFA	C0	3,45	0,75
	C1	2,75	1,12
	C2	2,82	0,55
ICFBDES	C0	2,84	0,56
	C1	3,12	1,75
	C2	3,78	0,28
ICFSOOC	C0	3,29	0,14
	C1	3,20	0,40
	C2	2,00	0,89
ICHCC	C0	2,71	0,21
	C1	2,97	0,00
	C2	2,50	1,62
ICLSN	C0	2,82	1,82
	C1	3,69	0,85
	C2	2,38	0,57
ICRC	C0	3,12	0,75
	C1	2,63	0,52
	C2	2,33	2,00

Observa-se que, na maioria das disciplinas, é possível identificar ao menos um *cluster* com maior interatividade (por exemplo, ICHCC-C2 com 1,62, ICLSN-C0 com 1,82 e ICRC-C2 com 2,00) e outro com maior dificuldade (ICFBDES-C2 com 3,78 e ICLSN-C1 com 3,69).

5.4.3 Relação entre clusters de alunos e clusters de materiais

Para investigar se o algoritmo diferenciou as sequências de acordo com o perfil dos alunos, o *fitness* médio e o número médio de materiais por sequência foram analisados separadamente para cada *cluster* de aluno, em cada disciplina. A Tabela 5.6 apresenta o *fitness* médio por *cluster*.

O Cluster C5 — composto por quatro alunos com habilidade prévia elevada (3,17)

Tabela 5.6: *Fitness* médio da melhor rodada por *cluster* de aluno e disciplina

Cluster	ICFA	ICFBDES	ICFSOOC	ICHCC	ICLSN	ICRC
C0 (n=13)	68,77	64,00	66,74	66,04	63,80	68,47
C1 (n=9)	65,97	62,77	64,62	62,99	62,81	64,57
C2 (n=14)	64,46	62,32	64,68	62,13	62,18	64,49
C3 (n=5)	66,07	62,16	65,49	63,70	62,87	66,49
C4 (n=6)	67,11	62,48	66,28	63,37	63,84	64,82
C5 (n=4)	81,29	63,35	67,41	71,82	70,44	74,36

e o maior tempo disponível da amostra (9 horas) — obteve os maiores valores de *fitness* em todas as disciplinas, com diferenças expressivas em ICFA (81,29 vs. 64–69 dos demais *clusters*) e ICHCC (71,82). Isso é consistente com o fato de que alunos com mais tempo disponível permitem ao algoritmo selecionar sequências mais longas: C5 recebeu em média 12 materiais em ICHCC e 9 em ICLSN, frente a 6–8 e 4–5 dos demais *clusters* nessas disciplinas. Já os Clusters C1 e C2 — cujas habilidades médias são as mais baixas (1,88 e 1,89) e cujos tempos disponíveis são reduzidos (2,22 e 2,04 horas) — apresentaram os menores valores de *fitness* de forma consistente, indicando que as restrições de tempo limitaram a cobertura de conceitos e, conseqüentemente, a qualidade das sequências.

Esses resultados mostram que o PPA diferenciou as sequências de forma coerente com os perfis dos *clusters*: não pela dimensão do estilo de aprendizagem (cujos efeitos ficaram diluídos pela baixa separabilidade dos grupos, silhueta = 0,205), mas principalmente pela interação entre habilidade prévia e tempo disponível, que são os parâmetros que afetaram de forma mais acentuada as dimensões O_2 (adequação de dificuldade) e O_3 (restrição temporal) da função objetivo.

Em síntese, os resultados demonstram que o algoritmo PPA, executado sobre os dados extraídos do Moodle, é capaz de gerar sequências de materiais personalizadas para cada aluno. As sequências apresentam boa estabilidade entre as rodadas e valores de *fitness* consistentes com os critérios pedagógicos da função objetivo. A diferença em relação ao experimento de referência aponta para o potencial de ajuste nos parâmetros do algoritmo ou nos dados de instância para resultados mais próximos ao *baseline*, o que não compromete a validade da integração proposta entre o Moodle e o algoritmo de sequenciamento.

6 Conclusão e Trabalhos Futuros

Este capítulo apresenta as considerações finais do trabalho, retomando os objetivos propostos e avaliando os objetivos alcançados. Em seguida, a Seção 6.1 discute as principais limitações identificadas ao longo do desenvolvimento e da validação experimental. Por fim, a Seção 6.2 aponta direções para a continuidade desta pesquisa, incluindo a validação em cenário real e o desenvolvimento de mecanismos a disponibilidade automatizada de trilhas de aprendizagem na plataforma do Moodle resultantes dos algoritmos aplicados ao ACS.

Este trabalho teve como objetivo geral adaptar a plataforma Moodle para o mapeamento e a estruturação dos dados necessários à implementação de algoritmos de ACS, viabilizando a geração automática de percursos de aprendizagem personalizados a partir de recursos já consolidados no ambiente. Os resultados obtidos confirmam a viabilidade dessa proposta: as cinco dimensões da função objetivo apresentada na Seção 2.4 puderam ser operacionalizadas integralmente a partir de recursos do Moodle – Framework de Competências, Planos de Aprendizagem e questionários – complementados por extensões específicas desenvolvidas para suprir lacunas pontuais da plataforma, como a ausência de campos para dificuldade e tempo estimado dos materiais.

A partir desse mapeamento, foi possível estruturar um curso populado com os dados de um experimento prévio de ACS e extrair sistematicamente os arquivos de instância necessários à execução do algoritmo PPA. A execução do algoritmo sobre esses dados, descrita no Capítulo 5, gerou sequências de materiais personalizadas para os 51 estudantes da amostra, com valores de *fitness* consistentes com os critérios pedagógicos da função objetivo e boa estabilidade entre execuções. A comparação com as sequências do experimento de referência revelou diferenças nos valores médios de *fitness* e na composição dos materiais selecionados, mais acentuadas em algumas disciplinas do que em outras, mas que não comprometem a validade da integração proposta, uma vez que o objetivo central deste trabalho não era reproduzir exatamente o comportamento do experimento original, e sim demonstrar que o Moodle pode ser utilizado como infraestrutura de dados suficiente

para alimentar, de ponta a ponta, uma metaheurística de sequenciamento.

Dessa forma, os três objetivos específicos definidos na Seção 1.3.2 foram atendidos: o levantamento da literatura permitiu identificar os principais métodos e requisitos de dados empregados em soluções de ACS; o mapeamento entre esses requisitos e os recursos do Moodle evidenciou tanto as possibilidades quanto as limitações de adaptação da plataforma; e a execução do algoritmo de sequenciamento sobre os dados extraídos, bem como a análise de sua adequação aos critérios da função objetivo, foi realizada e discutida. Como consequência, as três contribuições propostas na Seção 1.4 também se concretizam: um modelo de integração replicável entre algoritmos de otimização e o sistema de competências do Moodle; a demonstração prática de que dados extraídos nativamente da plataforma podem alimentar a execução real de uma metaheurística de ACS; e uma base replicável, com código-fonte disponibilizado publicamente, para futuras implementações e validações em ambientes com dados de novos usuários.

De forma mais ampla, este trabalho contribui para reduzir a lacuna identificada na Seção 1.2 entre os modelos teóricos de ACS e sua aplicação prática em LMS. Ao demonstrar que um LMS amplamente adotado pelas instituições de ensino pode ser reaproveitado como infraestrutura de dados para metaheurísticas de sequenciamento, sem demandar a substituição da tecnologia já consolidada, o trabalho oferece um caminho concreto para que a personalização do ensino deixe de depender exclusivamente de sistemas proprietários ou de ambientes experimentais isolados.

6.1 Limitações

Algumas limitações devem ser consideradas na interpretação dos resultados apresentados. Em primeiro lugar, a validação experimental foi realizada sobre os dados de um experimento prévio (Machado; Barrére; Souza, 2019), importados retroativamente para o Moodle, e não sobre dados coletados de estudantes interagindo diretamente com a plataforma já adaptada. Embora essa abordagem tenha sido adequada para demonstrar a viabilidade técnica da extração e do mapeamento de dados, ela não permite avaliar aspectos como a usabilidade dos recursos desenvolvidos do ponto de vista do professor ou do estudante, nem o comportamento do sistema em um cenário de uso real e contínuo.

Em segundo lugar, a clusterização dos alunos apresentou separabilidade relativamente baixa entre os grupos (*silhouette score* = 0,205), o que é esperado em dados de estilo de aprendizagem autodeclarado, mas limita a robustez das conclusões sobre a relação entre estilo de aprendizagem e desempenho do algoritmo. Os efeitos mais claros identificados na análise por cluster estiveram associados à habilidade prévia e ao tempo disponível dos estudantes, e não à dimensão de estilo de aprendizagem propriamente dita.

Por fim, mesmo com a integração proposta, persistem limites na automatização de algumas etapas do processo. O professor ainda precisa definir manualmente quais materiais serão disponibilizados no curso e caracterizar seus aspectos pedagógicos, ainda que os campos correspondentes já estejam totalmente disponíveis na plataforma. Alguns desses dados podem ser automatizados por algoritmos de identificação – como o tempo estimado de conclusão, extraído diretamente dos metadados dos arquivos LOM/SCORM –, enquanto outros, como a dificuldade, dependem do critério pedagógico do professor responsável pela disciplina, já que um mesmo material pode apresentar níveis de dificuldade distintos dependendo do curso em que é utilizado. As competências também precisam ser definidas manualmente, ao menos uma vez, para que possam ser associadas ao curso; a partir desse cadastro inicial, no entanto, é possível automatizar etapas subsequentes, como a associação do plano de aprendizagem a todos os alunos, conforme realizado neste trabalho.

6.2 Trabalhos Futuros

A partir das limitações apontadas e dos resultados obtidos, identificam-se algumas direções para a continuidade desta pesquisa. Uma primeira direção é a validação da integração proposta em um cenário de uso real, com estudantes interagindo diretamente com o curso adaptado no Moodle, em vez da importação retroativa de dados de um experimento prévio. Esse tipo de validação permitiria avaliar não apenas a viabilidade técnica da extração de dados, mas também a percepção de professores e estudantes quanto à usabilidade dos recursos desenvolvidos – como o *plugin* de dificuldade e a extensão de tempo estimado – no fluxo de trabalho cotidiano de configuração de cursos.

Essa validação em cenário real depende, no entanto, de um mecanismo que de-

volva a sequência gerada pelo algoritmo à própria plataforma, de modo que cada estudante possa efetivamente seguir seu percurso adaptado durante o curso. Neste trabalho, a extração de dados ocorre em um único sentido – do Moodle para o algoritmo –, e as sequências geradas são analisadas externamente, sem retroalimentar o ambiente virtual de aprendizagem. Como segunda direção, propõe-se o desenvolvimento de um *plugin* para o Moodle responsável por inserir a sequência de materiais gerada pelo algoritmo diretamente no curso, de forma individualizada para cada aluno, permitindo que cada estudante acesse sua própria trilha de conteúdo adaptada por meio da interface nativa da plataforma e fechando o ciclo entre extração de dados, execução do algoritmo e entrega do percurso personalizado ao usuário final.

Por fim, sugere-se a extensão do modelo de mapeamento proposto para outras metaheurísticas além do PPA, de forma a avaliar se a infraestrutura de dados estruturada no Moodle é suficientemente genérica para alimentar diferentes famílias de algoritmos de sequenciamento, bem como a investigação de modelos de preferência de aprendizagem complementares ao FSLSM, conforme discutido na Seção 2.4.5.

Bibliografia

ACAMPORA, G.; GAETA, M.; LOIA, V. Hierarchical optimization of personalized experiences for e-learning systems through evolutionary models. *Neural Computing and Applications*, v. 20, n. 5, p. 641–657, July 2011. ISSN 1433-3058. Disponível em: <https://doi.org/10.1007/s00521-009-0273-z>.

ALHATHLI, M.; MASTHOFF, J.; BEACHAM, N. Adapting learning activity selection to emotional stability and competence. *Frontiers in Artificial Intelligence*, v. 3, p. 11, 2020.

BENMESBAH, O.; MAHNANE, L.; HAFIDI, M. An enhanced genetic algorithm for solving learning path adaptation problem. *Education and Information Technologies*, v. 26, n. 5, p. 5237–5268, 2021. ISSN 1573-7608. Disponível em: <https://doi.org/10.1007/s10639-021-10509-z>.

BENMESBAH, O.; MAHNANE, L.; HAFIDI, M. An improved constrained learning path adaptation problem based on genetic algorithm. *Interactive Learning Environments*, v. 31, n. 6, p. 3595–3612, jun. 2021. Received 02 Jun 2020; Accepted 28 May 2021; Published online 13 Jun 2021. Disponível em: <https://doi.org/10.1080/10494820.2021.1937659>.

CHANG, Y.-C.; LI, J.-W.; HUANG, D.-Y. A personalized learning service compatible with moodle e-learning management stem. In: *Proceedings of the Applied Sciences*. Online: MDPI, 2022. v. 12, n. 7, p. 3562. ISSN 2076-3417. Disponível em: <https://www.mdpi.com/2076-3417/12/7/3562>.

CHEN, Y.; PENG, C.; WANG, C. An analytical study of shortest path algorithms for learning paths in french courses with digital resources. In: *Proceedings of the Journal of Combinatorial Mathematics and Combinatorial Computing*. Online: JCMCC, 2025. v. 127a, p. –. Disponível em: <https://doi.org/10.61091/jcmcc127a-264>.

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

GAMAGE, S. H. P. W.; AYRES, J. R.; BEHREND, M. B. A systematic review on trends in using moodle for teaching and learning. In: *International Journal of STEM Education*. Online: Springer, 2022. v. 9, n. 1, p. 9. ISSN 2196-7822. Disponível em: <https://doi.org/10.1186/s40594-021-00323-x>.

HOFMANN, M. J. *et al.* Language models explain word reading times better than empirical predictability. *Frontiers in Artificial Intelligence*, v. 4, p. 730570, 2022. Disponível em: <https://www.frontiersin.org/journals/artificial-intelligence/articles/10.3389/frai.2021.730570/full>.

IMAMAH *et al.* Development of dynamic personalized learning paths based on knowledge preferences and the ant colony algorithm. *IEEE Access*, v. 12, p. 144193–144207, 2024.

IMAMAH *et al.* Enhancing students performance through dynamic personalized learning path using ant colony and item response theory (acoirt). In: *Proceedings of the Computers and Education: Artificial Intelligence*. Online: Elsevier, 2024. v. 7, p.

100280. ISSN 2666-920X. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2666920X24000833>.

LI, S. *et al.* Online personalized learning path recommendation based on saltatory evolution ant colony optimization algorithm. In: *Proceedings of Mathematics*. Online: MDPI, 2023. v. 11, n. 13, p. 2792. ISSN 2227-7390. Disponível em: <https://www.mdpi.com/2227-7390/11/13/2792>.

MACHADO, M. d. O. C.; BARRÉRE, E.; SOUZA, J. Solving the adaptive curriculum sequencing problem with prey-predator algorithm. *International Journal of Distance Education Technologies*, IGI Global, v. 17, n. 4, p. 71–93, 2019.

MACHADO, M. d. O. C. *et al.* Metaheuristic-based adaptive curriculum sequencing approaches: a systematic review and mapping of the literature. *Artificial Intelligence Review*, v. 54, n. 1, p. 711–754, 2021. Disponível em: <https://doi.org/10.1007/s10462-020-09864-z>.

MARTINS, A. F. *et al.* A comparative analysis of metaheuristics applied to adaptive curriculum sequencing. In: . [s.n.], 2021. v. 25, n. 16, p. 11019–11034. ISSN 1433-7479. Disponível em: <https://doi.org/10.1007/s00500-021-05836-9>.

NIKNAM, M.; THULASIRAMAN, P. Lpr: A bio-inspired intelligent learning path recommendation system based on meaningful learning theory. *Education and Information Technologies*, v. 25, n. 5, p. 3797–3819, 2020. ISSN 1573-7608. Disponível em: <https://doi.org/10.1007/s10639-020-10133-3>.

NOGUEIRA, J. V. de C. M. F. *et al.* Exploring the solution space for adaptive curriculum sequencing: Study of a multi-objective approach. In: *Proceedings of the Internet of Things*. Online: Elsevier, 2024. v. 25, p. 101052. Disponível em: <https://www.sciencedirect.com/science/article/pii/S254266052300375X>.

PAXINOU, E. *et al.* Decoding students' paths in moodle to distill significance of learning resources. In: *2024 15th International Conference on Information, Intelligence, Systems & Applications (IISA)*. [S.l.: s.n.], 2024. p. 1–8.

PAXINOU, E. *et al.* Tracing student activity patterns in e-learning environments: Insights into academic performance. *Future Internet*, v. 16, n. 6, p. 190, 2024. ISSN 1999-5903. Disponível em: <https://www.mdpi.com/1999-5903/16/6/190>.

SIVAJI, S.; VENKATESH, M. Smart learning using personalized recommendations in web based learning systems using artificial bee colony algorithm to improve learning performance. *Electronic Government, an International Journal*, v. 16, p. 1, 01 2020.

SON, N. T. *et al.* Meta-heuristic algorithms for learning path recommender at mooc. *IEEE Access*, v. 9, p. 59093–59107, 2021.

SU, W. A comparative study on optimizing intelligent tutoring system based on genetic algorithm to enhance the effectiveness of ideological and political education. *Journal of Combinatorial Mathematics and Combinatorial Computing*, Combinatorial Press, v. 127a, p. 1871–1895, 2025. Published online 15 April 2025. Disponível em: <https://www.combinatorialpress.com/jcmcc>.

SUBIYANTORO, E.; ASHARI, A.; SUPRAPTO, S. Learning path recommendation using hybrid particle swarm optimization. *Advances in Science, Technology and Engineering Systems Journal*, v. 6, p. 570–576, 01 2021.

SUN, Y. Construction and optimization of personalized learning paths for english learners based on ssa-lstm model. *Systems and Soft Computing*, v. 7, p. 200218, 2025. ISSN 2772-9419. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2772941925000365>.

WANG, F. *et al.* A personalized self-learning system based on knowledge graph and differential evolution algorithm. In: *Proceedings of the Concurrency and Computation: Practice and Experience*. Online: Wiley, 2022. v. 34, n. 8, p. e6190. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/cpe.6190>.

XIAO, H. An adaptive learning path optimization model for advanced english learners. *Applied Mathematics and Nonlinear Sciences*, v. 9, n. 1, 2024. Disponível em: <https://doi.org/10.2478/amns-2024-2666>.

XIAO, Q. *et al.* Sustainable personalized e-learning through integrated cross-course learning path planning. *Sustainability*, v. 16, n. 20, p. 8867, 2024. ISSN 2071-1050. Disponível em: <https://www.mdpi.com/2071-1050/16/20/8867>.

ZHANG, Y.-W. *et al.* Learning path optimization based on multi-attribute matching and variable length continuous representation. In: *Proceedings of Symmetry*. Online: MDPI, 2022. v. 14, n. 11, p. 2360. ISSN 2073-8994. Disponível em: <https://www.mdpi.com/2073-8994/14/11/2360>.

ZHENG, Y. *et al.* A multigranularity learning path recommendation framework based on knowledge graph and improved ant colony optimization algorithm for e-learning. *IEEE Transactions on Computational Social Systems*, v. 12, n. 2, p. 586–607, 2025.