

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
INSTITUTO DE CIÊNCIAS EXATAS
PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Marcelo de Oliveira Costa Machado

**Geração de Sequências Curriculares Adaptativas
baseada no Perfil dos Alunos e Materiais Didáticos
utilizando o Algoritmo Presa-Predador**

Juiz de Fora

2018

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
INSTITUTO DE CIÊNCIAS EXATAS
PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Marcelo de Oliveira Costa Machado

**Geração de Sequências Curriculares Adaptativas
baseada no Perfil dos Alunos e Materiais Didáticos
utilizando o Algoritmo Presa-Predador**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação, do Instituto de Ciências Exatas da Universidade Federal de Juiz de Fora como requisito parcial para obtenção do título de Mestre em Ciência da Computação.

Orientador: Jairo Francisco de Souza

Coorientador: Eduardo Berrére

Juiz de Fora

2018

Marcelo de Oliveira Costa Machado

**Geração de Sequências Curriculares Adaptativas baseada no
Perfil dos Alunos e Materiais Didáticos utilizando o Algoritmo
Presa-Predador**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação, do Instituto de Ciências Exatas da Universidade Federal de Juiz de Fora como requisito parcial para obtenção do título de Mestre em Ciência da Computação.

Aprovada em 26 de Março de 2018.

BANCA EXAMINADORA

Prof. D.Sc. Jairo Francisco de Souza - Orientador
Universidade Federal de Juiz de Fora

Prof. D.Sc. Eduardo Berrére - Coorientador
Universidade Federal de Juiz de Fora

Prof. D.Sc. Stênio Sã Rosário Furtado Soares
Universidade Federal de Juiz de Fora

Prof. D.Sc. Sean Wolfgang Matsui Siqueira
Universidade Federal do Estado do Rio de Janeiro

*A Deus em primeiro lugar. Aos
meus familiares, professores e
amigos pelo apoio incondicional.*

AGRADECIMENTOS

Agradeço a Deus pela minha vida e por todo apoio durante essa caminhada. E agradeço especialmente...

...aos meus familiares por toda educação, carinho, amor e compreensão. Principalmente, minha mãe Regina que de fato é a Rainha da minha vida.

...aos professores Jairo Souza e Eduardo Barrére pela orientação, paciência, dedicação e amizade.

...à amiga Natalie Bravo que contribuiu em todos os processos desta pesquisa sendo merecedora de todos os elogios direcionados a este trabalho.

...aos amigos do LApIC, principalmente, Jorão Júnior, Laura Lima, Marcos Paulo e Nicolas Ferranti que contribuíram diretamente em alguns com os experimentos. Além deles, agradeço aos amigos Lucas Cerqueira e Luiz Alexandre que também colaboraram nessa fase. Agradeço ainda, a tantos outros amigos que estiveram ao meu lado e que tanto me ouviram falar sobre este projeto e momento de vida. De certo, ao lerem estes agradecimentos, esses amigos saberão que foram lembrados.

...à professora Liamara Scortegagna e à Técnica em Assuntos Educacionais Josiane Santos, pelo suporte relacionado a divulgação e comunicação com os alunos que fizeram parte do curso ofertado no experimento desta dissertação. E dessa maneira, agradeço a cada um desses alunos.

...aos funcionários de toda UFJF pelos serviços prestados, carinho e compreensão (principalmente, quando foi necessário acessar o laboratório aos fins de semanas e madrugadas).

...à CAPES pelo apoio financeiro.

Obrigado!

*“And you can never find the
satisfaction*

*When you can't outgrow your
false distractions”*

Opeth

*“When you lose small mind
You free your life”*

System of A Down

RESUMO

O *e-Learning* é a representação tecnológica da Educação a Distância, sendo uma alternativa que as pessoas têm encontrado para adquirir conhecimento acadêmico ou extracurricular. Os usuários desses sistemas podem acessar os conteúdos a qualquer momento e lugar, bastando possuir um dispositivo computacional com acesso à Internet. Todavia, para que essa tecnologia seja ainda mais utilizada, não somente como um complemento, mas também como uma alternativa primária, é necessário tratar diversos desafios da área. O foco das principais tecnologias baseadas na melhoria da educação, por muitos anos, tem sido a transferência de informação baseada na figura central de um professor. Esse aspecto, em conjunto a omissões relevantes, tais como a contextualização da experiência de aprendizagem de acordo com o perfil do aluno, são considerados os principais obstáculos na adoção do *e-Learning*. Nesse contexto, um dos desafios mais interessantes nessa área é a seleção de uma sequência de materiais didáticos que considere as características do aluno no momento da entrega de conteúdo didático – Sequência Curricular Adaptativa (SCA). A geração da SCA é considerada um problema da classe NP-Difícil estimulando a utilização de metaheurísticas, particularmente de abordagens de Computação Evolucionista, na solução do problema. O presente trabalho propõe uma solução para geração de uma SCA que considere as informações intrínsecas e extrínsecas do aluno. O Algoritmo Presa-Predador foi escolhido para o problema mostrando-se adequado. Os resultados da solução proposta, se deram a partir de experimentos com uma turma real de alunos e mostram que a adaptação proposta, além de conseguir selecionar materiais didáticos que atendam aos objetivos de aprendizagem do aluno, interfere positivamente na qualidade do entendimento dos conceitos. Ademais, o grupo de alunos que recebeu a SCA a partir da proposta apresentou menor desistência, sugerindo um fator motivacional. Ainda como contribuição do trabalho, foi gerada uma base de materiais didático que poderá ser utilizada em experimentos futuros, contribuindo para o desenvolvimento da área.

Palavras-chave: Sequência Curricular Adaptativa. Algoritmo Presa-Predador. Computação Evolucionista.

ABSTRACT

e-Learning is the technological representation of Distance Education, being an alternative that people have found to acquire academic or extracurricular knowledge. The users of these systems can access the contents anytime, anywhere simply by having a computer device with Internet access. However, for this technology to be even more used, not only as a complement, but also as a primary alternative, it is necessary to address several challenges. The focus of the main technologies based on the improvement of education, for many years, has been the transfer of information based on the central figure of a teacher. This aspect, together with relevant omissions, such as the contextualization of the learning experience according to the student profile, are considered the main obstacles in e-Learning adoption. One of the most interesting challenges in this field is the selection of the sequence of learning resources that considers learners characteristics at the content delivery time - Adaptive Curriculum Sequence (ACS). The ACS generation is considered a NP-Hard problem, stimulating the use of metaheuristics, particularly of Evolutionary Computing approaches. The present work proposes a solution to generate an ACS that considers the intrinsic and extrinsic information of the learner. The Prey-Predator Algorithm was chosen for the problem and it have been proved suitable. The proposed solution results were based on a real learning enviroment (with real learners) and show that the proposed adaptation, besides being able to select learning resources that meet the learners learning goals, positively affects the quality of understanding. Besides, the group of students who received the ACS from the proposal presents less dropout, suggesting a motivational factor. In addition, the database of learning resouces was generated which may be used in future experiments, contributing to the development of this field of research.

Keywords: Adaptive Curriculum Sequencing. Prey-Predator Algorithm. Evolutionary Computing.

LISTA DE FIGURAS

2.1	Relação semântica entre materiais didáticos e ontologia (ACAMPORA et al., 2011).	20
4.1	Roleta criada a partir do valor CS.	36
5.1	Exemplo da dimensão Educacional do IEE-LOM preenchida.	49
5.2	Comparação de tempo de execução variando o tamanho da população para uma base de dados contendo 300 materiais didáticos.	50
5.3	Comparação de tempo de execução entre bases de dados contendo 100, 200 e 300 materiais didáticos.	51
5.4	Curva de convergência para base de dados contendo 100 materiais didáticos.	52
5.5	Curva de convergência para base de dados contendo 200 materiais didáticos.	52
5.6	Curva de convergência para base de dados contendo 300 materiais didáticos.	53
5.7	Trecho da curva de convergência para base de dados contendo 300 materiais didáticos.	53
5.8	Distribuição dos alunos de acordo com a dimensão Participação do FSLSM.	54
5.9	Distribuição dos alunos de acordo com a dimensão Organização do FSLSM.	55
5.10	Distribuição dos alunos de acordo com a dimensão Apresentação do FSLSM.	55
5.11	Distribuição dos alunos de acordo com a dimensão Percepção do FSLSM.	55
5.12	Distribuição dos alunos de cada grupo de acordo com a pontuação no questionário de conhecimento prévio.	56
5.14	Resultado dos alunos que receberam adaptação.	58
5.13	Resultados dos alunos que não receberam adaptação.	59
5.15	Resultados dos alunos que não receberam adaptação.	61
5.16	Resultados dos alunos que não receberam adaptação.	62
5.17	Resultados dos alunos que não receberam adaptação.	62
A.1	Resultados dos alunos relacionado a Fundamentos de Sistemas Operacionais e Organização de Computadores.	76
A.2	Resultados dos alunos relacionado a História da Computação e dos Computadores.	77

A.3	Resultados dos alunos relacionado a Redes de Computadores.	77
A.4	Resultados dos alunos relacionado a Lógica e Sistemas Numéricos.	78
A.5	Resultados dos alunos relacionado a Fundamentos em Algoritmos.	78
A.6	Resultados dos alunos relacionado a Fundamentos de Banco de Dados e Engenharia de Software.	79

LISTA DE TABELAS

2.1	Dimensões do modelo de (FELDER et al., 1988)	22
3.1	Parâmetros extrínsecos dos alunos	25
3.2	Parâmetros intrínsecos dos alunos	26
3.3	Parâmetros dos materiais didáticos e EPC	27
3.4	Sumário dos trabalhos em relação à SCA, adaptado de (MACHADO et al., 2017)	28
4.1	Tabela para mapeamento de EA dos materiais didáticos.	45
5.1	Quantidade de alunos que responderam os questionários semanais separados por grupos.	59
5.2	Resultados dos alunos de cada grupo por semana.	60
5.3	Desistência dos alunos de cada grupo por semana.	61

LISTA DE ABREVIATURAS E SIGLAS

ABH Algoritmo de Busca Harmônica

AG Algoritmo Genético

AM Algoritmo Memético

APP Algoritmo Presa Predador

AVA Ambiente Virtual de Aprendizagem

CE Computação Evolucionista

EA Estilo de Aprendizagem

EaD Educação a Distância

EPC Estrutura Pedagógica dos Conceitos

FSLSM *Felder and Silverman Learning Style Model*

HBDI *Herrmann Dominance Brain Instrument*

ILS *Index of Learning Style*

MBTI *Myers-Briggs Type Indicator*

OA Objeto de Aprendizagem

OCF Otimização de Colônia de Formigas

OEP Otimização por Enxame de Partículas

PBIL *Population Based Incremental Learning*

SCA Sequência Curricular Adaptativa

SCORM *Sharable Content Object Reference Model*

SI Sequência Individual

SS Sequência Social

TIC Tecnologia de Informação e Comunicação

SUMÁRIO

1	INTRODUÇÃO	14
1.1	OBJETIVOS	17
1.2	ORGANIZAÇÃO DO TRABALHO	17
2	FUNDAMENTAÇÃO TEÓRICA	18
2.1	SEQUÊNCIAS CURRICULARES ADAPTATIVAS	18
2.2	ESTILO DE APRENDIZAGEM	21
3	COMPUTAÇÃO EVOLUCIONISTA NA LITERATURA DE SCA...	24
3.1	METODOLOGIA DE BUSCA DOS TRABALHOS RELACIONADOS	24
3.2	MODELO DE COMPARAÇÃO ADOTADO	25
3.2.1	Parâmetros extrínsecos do aluno.....	25
3.2.2	Parâmetros intrínsecos do aluno	26
3.2.3	Parâmetros do Material Didático e Estrutura Pedagógica dos Conceitos.....	26
3.2.4	Tipo de Sequenciamento.....	26
3.2.5	Abordagem de Computação Evolucionista	26
3.3	RESULTADOS E ANÁLISE	27
4	ALGORITMO PRESA-PREDADOR PARA SOLUÇÃO DO PROBLEMA DE SCA	31
4.1	MOTIVAÇÃO PARA ESCOLHA DA METAHEURÍSTICA	32
4.2	MODELAGEM DO PROBLEMA	33
4.3	ALGORITMO PRESA-PREDADOR	34
4.4	FUNÇÃO OBJETIVO	38
4.4.1	Parâmetros.....	40
4.4.2	Cobertura dos Conceitos.....	41
4.4.3	Dificuldade.....	42
4.4.4	Tempo total do curso.....	43
4.4.5	Balanceamento dos materiais	43
4.4.6	Estilo de Aprendizagem	43

5	AVALIAÇÃO	47
5.1	BASE PARA AVALIAÇÃO DE SCA	47
5.2	ANÁLISE DO COMPORTAMENTO DA ABORDAGEM	49
5.3	ANÁLISE DA QUALIDADE DA ABORDAGEM	51
5.3.1	Caracterização dos participantes	52
5.3.2	Definição dos grupos do experimento	56
5.3.3	Coleta dos dados	57
5.3.4	Resultados e análise	58
6	CONCLUSÕES	63
6.1	CONTRIBUIÇÕES	64
6.2	TRABALHOS FUTUROS	65
	REFERÊNCIAS	67
	APÊNDICES	75

1 INTRODUÇÃO

Através do desenvolvimento tecnológico dos últimos tempos, o acesso a informação ficou mais fácil e assim as pessoas começaram a buscar por novos produtos, serviços e novas formas de conhecimento. A partir de um computador ou dispositivo móvel é possível ter acesso a tudo o que necessitam “na palma de suas mãos”. A Educação a Distância (EaD) é a abordagem de ensino que leva em consideração este novo paradigma proativo de busca por conhecimento, disponibilizando materiais didáticos na forma de cursos completos, através de sistemas de *e-Learning*, trazendo flexibilidade à vida dos alunos. Essa modalidade cresce aceleradamente – bem como mostram os dados recentes disponibilizados pela Associação Brasileira de Educação a Distância (BRASIL, 2016) – existindo cada vez mais recursos e funcionalidades específicas que sejam relevantes para deixar o processo de aprendizagem cada vez mais completo. Pessoas estão sendo atraídas para cursos *online* por sua facilidade de acessibilidade e disponibilidade a qualquer momento (KARPOVA et al., 2015). De fato, a EaD se mostra como a principal opção àqueles que porventura não tenham a oportunidade de frequentar de um curso presencial.

O foco das principais tecnologias baseadas na melhoria da educação por muitos anos tem sido a transferência de informação baseada na figura central de um professor, cuja principal atividade é fornecer conteúdos educacionais a serem consumidos pelos alunos de forma passiva (ACAMPORA et al., 2011). Nesse cenário se encaixam a maioria dos cursos a distância baseados em um Ambiente Virtual de Aprendizagem (AVA). Esse aspecto, juntamente com omissões relevantes, tais como a contextualização da experiência de aprendizagem de acordo com o perfil do aluno e o envolvimento do aluno nas atividades, são considerados os principais obstáculos à adoção do *e-Learning* e traçam o caminho dos desafios a serem tratados (ACAMPORA et al., 2011). A crescente quantidade de materiais didáticos em repositórios utilizados pela maioria dos sistemas de *e-Learning* dificulta a recuperação de conteúdos relevantes às necessidades e características dos alunos, (DHARSHINI et al., 2015; DWIVEDI et al., 2017). Além disso, a tarefa de alocação dos materiais didáticos ao curso é normalmente feita por um professor, que pode preferir buscar por materiais menos específicos em relação ao grau de aprofundamento do conteúdo mas que atenda a aspectos comuns entre os alunos.

O *e-Learning* adaptativo é um dos conceitos que surgiram para tratar alguns dos problemas supracitados e pode ser considerado como um conjunto de técnicas orientadas a oferecer aos alunos uma experiência pessoal e única, com o objetivo final de maximizar seu desempenho (SHUTE; TOWLE, 2003). Segundo Shute & Towle (2003), um sistema de *e-Learning* adaptativo deve entregar o conteúdo certo para a pessoa certa da maneira mais apropriada possível. Os autores Al-Azawei & Badii (2014) pontuam alguns dos objetivos de um *e-Learning* adaptativo: melhorar a assimilação de conteúdo, reduzir o esquecimento, motivar os alunos, reduzir a evasão, orientar o melhor caminho de aprendizagem, tratar a sobrecarga cognitiva, reduzir o custo de aprendizagem e melhorar a usabilidade dos sistemas. Isso significa que a adaptatividade pode desempenhar o papel de promover e melhorar a aprendizagem.

A adaptação está em vários âmbitos, por exemplo na recomendação de materiais didáticos de acordo com as preferências e necessidades do aluno (GHAUTH; ABDULLAH, 2010; DWIVEDI; BHARADWAJ, 2011, 2013; ERDT et al., 2015). Sistemas de *e-Learning* que se propõem a implementar este nível de adaptação tentam garantir que o material certo está sendo entregue ao aluno. Todavia, apenas a recomendação não é capaz de garantir o aprimoramento na compreensão total de um conceito de aprendizagem (DWIVEDI et al., 2017), pois não considera uma organização sequencial em que cada material didático deve estar de acordo com o anterior e o próximo (DURAND et al., 2013). Assim, um outro nível de adaptação se mostra como uma das pesquisas mais interessantes na personalização da aprendizagem a distância: o sequenciamento curricular dos materiais didáticos (PREMLATHA; GEETHA, 2015). O objetivo desse nível é auxiliar o sistema a encontrar a melhor sequência de conteúdos educacionais que satisfaçam os objetivos de aprendizagem, preferências e outras características do aluno, posto que a aprendizagem não se dá apenas através da disponibilização de recursos de aprendizagem, mas também da identificação de caminhos de aprendizagem apropriados (SANTOS et al., 2015). O desafio está na geração dessa sequência, pois o sequenciamento inadequado pode levar a consequências negativas, tais como, a falta de interesse do aluno pelo curso (XIE et al., 2017).

Uma das principais dificuldades de um sistema de *e-Learning* que se adapta no nível de sequenciamento é definir os diferentes parâmetros que vão representar os alunos e os conteúdos educacionais. Recentemente, vários trabalhos exploraram soluções utilizando

diversos atributos, tal como, indicam as revisões de Wong & Looi (2010), Al-Muhaideb & Menai (2011), Wang & Wu (2011), Pushpa (2012), Khamparia & Pandey (2015) e Machado et al. (2017). Esses trabalhos demonstram que a maioria dos atributos dos materiais didáticos são criados a partir do consenso de especialistas da área, a exemplo, o grau de dificuldade e o tempo médio de aprendizado. Por outro lado, a modelagem voltada ao aluno é mais complexa, apoiando-se em questionários e até mesmo em registros associados ao comportamento passado do aluno no sistema. Existe ainda a dificuldade de relacionar o modelo do aluno com o domínio conceitual, por exemplo, ao tentar associar o Estilo de Aprendizagem (EA) do aluno a um material didático contido em um repositório. Devido a essas dificuldades, nota-se que na maioria dos trabalhos não são utilizados parâmetros intrínsecos relacionados aos alunos (AL-MUHAIDEB; MENAI, 2011; MACHADO et al., 2017), indicando que, apesar da tentativa de adaptabilidade voltada ao aluno seja o assunto principal para o sequenciamento dos materiais didáticos, as informações que definem e distinguem os alunos ainda são pouco exploradas.

Considerando o constante aumento da quantidade e variedade de materiais didáticos nos repositórios e todas as restrições que precisam ser satisfeitas para atender os objetivos de aprendizagem e preferências do aluno, o sequenciamento se mostra como um problema de otimização combinatória pertencente a classe de problemas NP-Difícil (ACAMPORA et al., 2011; PUSHPA, 2012). Vale ressaltar que esse fato motivou diversos autores a utilizarem heurísticas e metaheurísticas, sobretudo de Computação Evolucionista (CE), para tratar o sequenciamento, visto que, de maneira clássica, elas apresentaram-se como boas alternativas a problemas da mesma natureza (WONG; LOOI, 2010; AL-MUHAIDEB; MENAI, 2011; WANG; WU, 2011; PUSHPA, 2012; KHAMPARIA; PANDEY, 2015; MACHADO et al., 2017). Novas abordagens evolucionistas foram introduzidas na literatura nos últimos anos e mostraram-se promissoras a partir de comparações utilizando funções objetivo clássicas. Portanto, explorar essas novas abordagens pode trazer benefícios na resolução do problema, o que justifica a investigação.

Tendo mostrado a relevância do assunto, na próxima seção são explanados os objetivos desta dissertação.

1.1 OBJETIVOS

O sequenciamento curricular é considerado um desafio importante no contexto de *e-Learning* adaptativo e nesse cenário ainda existem questões que necessitam de atenção, tal como, a utilização adequada de parâmetros dos alunos. Portanto, este trabalho tem como objetivo tratar o problema do sequenciamento curricular de forma que os materiais didáticos selecionados contemplem os objetivos de aprendizagem do aluno considerando, principalmente, suas necessidades e características extrínsecas e intrínsecas. Ainda, é objetivo deste trabalho mostrar que o Algoritmo Presa-Predador (APP), proposto por Tilahun & Ong (2015), é adequado para esse problema, embora ainda não tenha sido explorado pela literatura.

1.2 ORGANIZAÇÃO DO TRABALHO

O trabalho está organizado em mais cinco capítulos além deste capítulo introdutório. O Capítulo 2 apresenta a fundamentação teórica da Sequência Curricular Adaptativa, bem como dos conceitos que a contemplam. No Capítulo 3 se encontram os trabalhos relacionados que serviram como base para esta pesquisa. O Capítulo 4 apresenta a proposta deste trabalho, seguido da avaliação feita no Capítulo 5. Por fim, o Capítulo 6 apresenta as contribuições deste trabalho, considerações finais e algumas possibilidades de trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo será apresentado o principal termo relacionado a esta dissertação, a Sequência Curricular Adaptativa. Além disso, será conceitualizado o termo Estilo de Aprendizagem (EA), pois esse foi utilizado como um dos parâmetros do aluno na solução proposta por este trabalho.

2.1 SEQUÊNCIAS CURRICULARES ADAPTATIVAS

O *e-Learning* corresponde a um modelo de ensino não presencial apoiado em Tecnologia de Informação e Comunicação (TIC). Atualmente, esse modelo assenta no ambiente *online*, aproveitando as capacidades da Internet para comunicação e distribuição de conteúdos (KAPLAN; HAENLEIN, 2016) permitindo que os alunos possam ter acesso a cursos sem limites espaciais e temporais (VOSS et al., 2013), bastando estar em posse de um dispositivo computacional com acesso à Internet. Além disso, esses sistemas – quando adaptativos – podem quebrar o paradigma de ensino presencial onde “*one size fits all*”, ou seja, um conceito é ensinado da mesma maneira, com os mesmos materiais para todos os alunos (LOPES; FERNANDES, 2009; WANG et al., 2008; ACAMPORA et al., 2011; HAUGER; KÖCK, 2007). Portanto, tratar o problema de encontrar a melhor sequência de materiais didáticos que considere o aluno individualmente se mostra como uma das pesquisas mais interessantes e cruciais em sistemas de aprendizagem *online* (MUHAMMAD et al., 2016). Ainda não existe na literatura um consenso relacionado ao termo que define essa sequência. Por exemplo, para Al-Muhaideb & Menai (2011), essa sequência é chamada de “Sequência Curricular”, já em Dwivedi et al. (2017) o termo utilizado é “Caminho de Aprendizagem” e entre outros ainda pode ser citado o “Planejamento Instrucional” como em Brusilovsky (2003). Embora outras nomenclaturas sejam utilizadas, neste trabalho será adotado o termo Sequência Curricular Adaptativa (SCA).

De acordo com Brusilovsky (2003), o objetivo da SCA é fornecer ao aluno a ordenação mais adequada de unidades e tarefas de conhecimento (exemplos, perguntas, problemas, etc). A intenção é ajudar o aluno a encontrarem um “caminho ideal” de aprendizagem dentro do domínio de conhecimento (HAFIDI; BENSEBAA, 2015), maximizando a compreensão, bem como a eficiência no aprendizado. Além disso, o ambiente de aprendizagem

é constantemente alterado à medida que os recursos de aprendizagem estão sendo adicionados ou removidos. Assim, é válido notar que uma solução para o problema da SCA não só ajuda os alunos a encontrarem o caminho de aprendizagem mais eficiente e adequado, mas também ajuda o professor a refinar a estrutura e conteúdo do curso (AL-MUHAIDEB; MENAI, 2011).

Um dos parâmetros importantes para a geração da SCA é a Estrutura Pedagógica de Conceitos (EPC). Essa pode ser considerada uma representação do conteúdo programático a partir dos conceitos de aprendizagem (MARCOS et al., 2011; SHARMA et al., 2012). Na literatura, três abordagens principais foram utilizadas para sua geração: (1) aproximada a partir de métodos matemáticos (2) pré definida por especialistas e (3) baseada em ontologias. Os métodos matemáticos são utilizados para aproximar a EPC de maneira automática e descentralizada (SEKI et al., 2005; CHEN, 2008; HUANG et al., 2007; GUO; ZHANG, 2009). Entretanto, esses métodos ignoram as relações entre os conceitos fazendo com que seja necessária uma avaliação sobre sua utilização no problema da SCA, pois sequências ilógicas podem ser produzidas (CHEN, 2008). A abordagem de geração a partir de especialistas é comum e bem aceita, porém ainda apresenta algumas desvantagens: gasto em mão-de-obra, depende da experiência dos envolvidos, não é flexível aos alunos, e por esse fato, a EPC também é um dos problemas relevantes na literatura de sistemas *e-Learning* adaptativo (GUTIÉRREZ; PARDO, 2007). Por fim, a última abordagem, baseada em ontologias, busca associar semântica à estrutura de conceitos. De acordo com Chen (2008), uma maneira de se conseguir isso é a partir do uso de ontologias definidas como “um conjunto de termos hierarquicamente estruturados para descrever um conhecimento de domínio que pode ser usado como base esquelética para um sistema de base de conhecimento”. Um exemplo da EPC baseada em ontologias pode ser ilustrado a partir de um exemplo advindo do trabalho de Acampora et al. (2011):




Figura 2.1: Relação semântica entre materiais didáticos e ontologia (ACAMPORA et al., 2011).

Onde HP representa “tem parte” (*Has Part*), isto é, o conceito C consiste de quatro sub-conceitos C1, C2, C3 e C4. A relação IRB representa “é requerido por” (*Is Required By*), ou seja, o conceito C1 e C3 são pré requisitos de C2. Além disso, o material didático (representados por objetos de aprendizagem do inglês *Learning Objects* - LO) LO2 cobre os conceitos C2 e C3. Como apoio a esta abordagem são utilizados padrões de OAs tais como o IEEE LOM¹.

Segundo Kardan et al. (2015), além da EPC, a SCA deve levar em consideração as características dos alunos e as informações dos materiais didáticos. Portanto, a SCA pode ser vista como uma função $f(a, d, e) \rightarrow S$ que recebe como parâmetros o modelo do aluno (representação do aluno a partir dos seus dados) a , as informações dos materiais didáticos d e as informações da EPC e . Essa função tem como retorno uma sequência $s \in S$ que melhor se aproxima do modelo do aluno, dentre as diversas possibilidades de sequências contidas em S .

A SCA é considerada um problema da classe NP-Difícil (ACAMPORA et al., 2011; PUSHPA, 2012), sobretudo por envolver diversas restrições a serem satisfeitas a fim de atender as necessidades dos alunos. Considere um curso cujo programa contém um conjunto C de conceitos de aprendizagem e que cada conceito pode estar relacionado a diversos materiais didáticos, o número de possíveis sequências seria equivalente a multiplicação entre o número de materiais didáticos de cada um desses conceitos. Ou seja, considerando

¹O IEEE-LOM (*Learning Object Metadata*) é um modelo de dados, geralmente codificado em XML, usado para descrever Objetos de Aprendizagem (OA). Sua finalidade é apoiar o reúso e descoberta dos OAs, além de facilitar a interoperabilidade, geralmente no contexto de Sistemas de Gerenciamento de Aprendizagem (por exemplo o MOODLE).

que cada conceito é abordado igualmente por um conjunto M de materiais didáticos tem-se $|M|^{|C|}$ possibilidades de sequências que poderiam ser selecionadas. O espaço de solução se torna ainda maior caso sejam consideradas permutações entre os conceitos e subseqüências. O espaço conceitual presente nos repositórios tende a aumentar com o passar do tempo, fazendo com que o número de combinações seja cada vez maior. Portanto, a seleção da SCA se torna ainda mais difícil, sobretudo quando os parâmetros do aluno e dos materiais didáticos devem ser levados em consideração.

O modelo do aluno, e o domínio de conhecimento (EPC e materiais didáticos) diferem de um trabalho para outro. Portanto, no próximo capítulo são apresentados os diferentes modelos utilizados pelos trabalhos relacionados.

2.2 ESTILO DE APRENDIZAGEM

Os alunos demonstram características individuais no processo de aprendizagem. Alguns são minuciosos observadores, outros preferem ouvir atentamente ou fazer a leitura completa do conteúdo de aprendizagem. Cada um desses alunos apresenta diferentes estratégias para solucionar problemas, elaborar conclusões e assimilar conteúdos. Essas características são comumente chamadas de Estilo de Aprendizagem (KOBASA, 2001; ZAINA; BRESSAN, 2008). O EA é único e pessoal, pois cada pessoa apresenta facilidade com um determinado estilo e dificuldade em outros.

Segundo Zaina et al. (2012), a observação do EA do aluno é uma das maneiras de se identificar características que sejam relevantes para a adequada recomendação de conteúdo e, portanto, a sua adoção em um processo de aprendizagem possibilita que o aluno possa imprimir um ritmo mais eficiente de aprendizado.

No trabalho de Manochehr et al. (2006) foi feito um estudo empírico sobre os efeitos do EA em um ambiente de *e-learning*. Neste âmbito, foi realizada uma comparação da utilização do EA em um ambiente tradicional de educação e em um ambiente de *e-Learning*. Os resultados revelaram que o EA no ambiente tradicional era irrelevante, mas que para o *e-Learning* é relevante e mais significativo.

Existem diversos modelos que descrevem modos de classificar um aluno em um determinado EA (COFFIELD et al., 2004), por exemplo, o Indicador de Myers-Briggs (*Myers-Briggs Type Indicator* - MBTI), Estilo de Aprendizagem de Kolb, Estilo de Aprendizagem de Honey e Mumford, Instrumento de Inteligência Dominante de Herrmann (HBDI) e o

Modelo de Estilos de Aprendizagem de Felder-Silverman. Na revisão feita por Valaski et al. (2011), foi demonstrado que, dos vários modelos de EA existentes, o mais utilizado é o de Felder e Silverman (FELDER et al., 1988), o qual tem sido tratado como a ferramenta mais apropriada para aprimoramento do aprendizado (VIOLA et al., 2006; GRAF et al., 2007; SCOTT et al., 2014).

O modelo de EA proposto por Felder et al. (1988) (*Felder-Silverman Learning Style Model* - FSLSM) é dividido em quatro dimensões, que podem ser vistas na Tabela a seguir:

Dimensão	Características	Estilo de Aprendizagem
Percepção	Está relacionada em como o aluno recebe o conteúdo; tipos de exercícios, por exemplo	Sensorial/Intuitivo
Apresentação	Está relacionada à forma como o conteúdo é apresentado; tipos de mídias, por exemplo.	Visual/Verbal
Participação	Representa o quanto o aluno gosta de participar das atividades; ao exemplo, se possui liderança, ou se prefere refletir mais tempo sobre um dado assunto.	Ativo/Reflexivo
Organização	Representa o tipo de visão que o aluno prefere ter do conteúdo: fragmentada ou global	Sequencial/Global

Tabela 2.1: Dimensões do modelo de (FELDER et al., 1988)

Uma das formas de capturar o EA de um aluno baseado no FSLSM é a partir de uma ferramenta chamada *Index of Learning Styles Questionnaire (ILS)*² (FELDER; SPURLIN, 2005). Essa ferramenta consiste em um questionário contendo 44 questões, sendo que cada dimensão do FSLSM é representada por 11 questões. Cada questão é composta por duas alternativas que estão relacionadas à dicotomia presente em cada dimensão, por exemplo, em uma questão da dimensão **Percepção**, uma alternativa representa o EA sensorial e a outra representa o EA intuitivo. À uma das opções da dicotomia são associados valores

²<https://www.webtools.ncsu.edu/learningstyles>

positivos e à outra são associados valores negativos, sendo o resultado final a adição das pontuações de cada opção da dimensão. Por exemplo, para a dimensão **Participação**, são associados valores inteiros positivos que variam de +1 até +11 ao EA ativo e são associados valores inteiros negativos que variam de -1 até -11 se o aluno responder 5 opções do EA Ativo e 6 do EA reflexivo tem-se o resultado -1 a partir da soma de +5 com -6. O valor encontrado para cada dimensão indica o quão intenso é a preferência de um aluno por um EA. Se a pontuação está na escala entre -3 e +3 o aluno se mostra equilibrado com relação aos EA da dimensão, se a pontuação está na escala entre -7 e -5 ou está entre +5 e +7 o aluno apresenta uma preferência moderada por um dos EA da dimensão e se sua pontuação está na escala entre -11 e -9 ou está entre +9 e +11 o aluno apresenta uma forte preferência por um dos EA da dimensão.

Outra forma de capturar o EA de um aluno é através de mecanismos de monitoramento em um sistema de *e-Learning* durante a interação do aluno. Assim, automaticamente é feita uma relação entre o EA associado aos materiais mais visitados com as preferências do aluno (WANG; WU, 2011; ZAINA et al., 2012)

O FSLSM apresentado anteriormente foi o modelo de EA escolhido para este trabalho, pois apresenta uma relação que sugere, a partir de um estilo de aprendizagem identificado, qual seria a estratégia mais adequada de ensino (COFFIELD et al., 2004; FELDER; BRENT, 2005).

Nos últimos anos, alguns trabalhos (KIRSCHNER, 2017; HUSMANN; O'LOUGHLIN, 2018) sugerem que a utilização do EA não é satisfatória na entrega de conteúdo, afirmando que embora cada aluno seja único, geralmente a maneira mais eficaz de aprender não se baseia em preferências individuais, mas sim na natureza do material de aprendizagem (MASSA; MAYER, 2006). Entretanto, neste trabalho a intenção da utilização de um modelo de EA é tratar o problema de “partida fria”, onde não há nenhuma informação intrínseca do aluno que sugira habilidades cognitivas.

3 COMPUTAÇÃO EVOLUCIONISTA NA LITERATURA DE SCA

Por se tratar de um dos problemas mais relevantes na área de sistemas de *e-Learning* adaptativos, a SCA foi abordada em diversos trabalhos: (WONG; LOOI, 2010; PUSHPA, 2012; AL-MUHAIDEB; MENAI, 2011; KHAMPARIA; PANDEY, 2015; MUHAMMAD et al., 2016; MACHADO et al., 2017). De forma investigativa, diversos parâmetros foram utilizados, sejam com relação ao aluno ou ao domínio de conhecimento (materiais didáticos e EPC). Além disso, diferentes estratégias foram utilizadas, destacando-se as metaheurísticas evolucionistas. Neste capítulo são apresentados alguns desses trabalhos de acordo com um modelo de comparação que leva em consideração as diferentes características e parâmetros utilizados nas soluções para o problema da SCA. O modelo foi dividido em dimensões, valendo citar: os parâmetros intrínsecos do aluno, os parâmetros extrínsecos do aluno, os parâmetros do material didático, o tipo de sequenciamento e a abordagem evolucionista utilizada.

3.1 METODOLOGIA DE BUSCA DOS TRABALHOS RELACIONADOS

A seleção dos trabalhos revisados foi realizada a partir dos termos de busca “*Curriculum Sequencing*”, “*Learning Path Generation*”, “*Personalized Course Generation*” e “*Instructional Planning*”. Dada a falta de consenso com relação a nomenclatura utilizada para se referenciar à SCA, foi necessário filtrar trabalhos que porventura estavam tratando outros problemas que não o definido aqui. Por exemplo, os trabalhos de Marcos et al. (2011) e de Shmelev et al. (2015) que tratam a geração automática da EPC. Ainda, apenas trabalhos relacionados com CE foram selecionados. Os termos foram pesquisados a partir das bases Google Scholar, IEEE e Scopus. De forma a expandir a rede de trabalhos que talvez não fossem encontrados a partir dos termos principais, foram utilizadas as técnicas de *Backward Snowballing* e *Forward Snowballing*. A técnica *Forward Snowballing* busca trabalhos que utilizem a lista inicial como referência, enquanto a técnica *Backward Snowballing* busca novos trabalhos nas referências da lista inicial. Foram selecionados apenas

trabalhos a partir de 2010 por representarem os trabalhos mais recentes na área – uma revisão de trabalhos dos anos anteriores é contemplada em (AL-MUHAIDEB; MENAI, 2011) – e assim, de um conjunto inicial de cerca de 160 trabalhos, foram selecionados 17 que são associados ao modelo de comparação.

3.2 MODELO DE COMPARAÇÃO ADOTADO

Esta seção apresenta o modelo considerado para comparação entre os trabalhos relacionados à SCA. Cada uma das subseções que seguem considera uma dimensão desse modelo.

3.2.1 PARÂMETROS EXTRÍNSECOS DO ALUNO

Os parâmetros extrínsecos do aluno dizem respeito às informações do ambiente ou do domínio de conhecimento (materiais e estrutura curricular de conceitos) que estão relacionadas ao usuário, ou seja, características externas. Os parâmetros extrínsecos do aluno que foram considerados pelo modelo de comparação podem ser vistos na Tabela a seguir:

ID	Parâmetros	Descrição
N	Nível de conhecimento	Representa o nível de maestria de um aluno perante a um conceito. Geralmente esse nível é calculado a partir de questionários e/ou análises estatísticas a partir de <i>logs</i> de comportamento do aluno no sistema.
T	Tempo para aprendizagem	Normalmente capturado a partir de um questionário sendo indicado o tempo de disponibilidade para o curso ou ainda é calculado de acordo com um relacionamento entre o nível de maestria do aluno e o tempo ajustado para o conceito.
Q	Qualidade de conexão	Representa a quantidade de banda de rede disponível no momento em que o usuário está acessando o sistema de <i>e-Learning</i>
R	Relação entre material didático e aluno	Especifica se um material didático é pertinente ou não para um aluno. Essa relação a princípio é gerada a partir de um sistema de recomendação ou aleatoriamente e depois é ajustado no decorrer do curso.

Tabela 3.1: Parâmetros extrínsecos dos alunos

3.2.2 PARÂMETROS INTRÍNSECOS DO ALUNO

Os parâmetros intrínsecos do aluno representam características exclusivas de cada aluno e são independentes da relação com qualquer outro elemento externo. Os parâmetros intrínsecos considerados no modelo de comparação podem ser vistos na tabela a seguir:

ID	Parâmetros	Descrição
I	Intenção	Representa a intenção de um aluno ao acessar um sistema de <i>e-Learning</i> . Pode estar relacionada à pesquisa, trabalho de pesquisa, ou apenas para obter uma introdução geral do assunto de estudo. Um exemplo de intenções pode ser o domínio cognitivo da Taxonomia de Bloom (CONKLIN et al., 2005).
A	Tipo	Representa um grupo de características que definem as preferências de aprendizagem de cada aluno. A exemplo tem-se o EA (AGARWAL et al., 2016) e o domínio cognitivo da Taxonomia de Bloom (DHARSHINI et al., 2015)

Tabela 3.2: Parâmetros intrínsecos dos alunos

3.2.3 PARÂMETROS DO MATERIAL DIDÁTICO E ESTRUTURA PEDAGÓGICA DOS CONCEITOS

Os parâmetros dos materiais didáticos bem como da EPC que foram considerados pelo modelo de comparação podem ser vistos na Tabela 3.3.

3.2.4 TIPO DE SEQUENCIAMENTO

Dois tipos de sequenciamento curricular foram considerados de acordo com o modelo do aluno: **(SI) Sequenciamento Individual**, o qual considera apenas as informações de parâmetros do próprio aluno para geração da SCA e **(SS) Sequenciamento Social**, que considera experiências de alunos anteriores para beneficiar alunos atuais.

3.2.5 ABORDAGEM DE COMPUTAÇÃO EVOLUCIONISTA

As abordagens evolucionistas não são detalhadas neste trabalho. Todavia, maiores informações sobre a Otimização de Colônia de Formigas (OCF), a Otimização de Enxame de Partículas e o Algoritmo Genético (AG) utilizadas no problema da SCA podem ser

ID	Parâmetros	Descrição
D	Dificuldade	Representa o grau de complexidade dos conceitos relacionados ao material didático, que pode ser ajustado por especialistas ou gerado a partir de <i>feedback</i> contínuo.
TM	Tempo médio de aprendizagem	Normalmente representa um valor médio de tempo que os alunos deveriam gastar no aprendizado dos conceitos relacionados ao material didático. Este tempo pode ser ajustado por especialistas ou gerado a partir de <i>feedback</i> contínuo.
P	Peso de um conceito	Representa o grau de importância de um conceito para o curso. Este valor é normalmente ajustado por especialistas.
C	Relacionamento entre conceitos	Representa a relação entre os conceitos de um curso. Pode ser capturada a partir da estrutura curricular de conceitos ou a partir da correlação entre os resultados dos alunos em pré-testes.
MC	Relação entre material didático e conceito	Indica quando um material didático cobre um conceito a ser ensinado.
M	Tipo	De maneira ampla, pode considerar a representação do material didático, seja ele vídeo, imagem, áudio, etc. Pode também estar relacionado à maneira como o conteúdo é apresentado, seja simulação, exercícios, testes etc.

Tabela 3.3: Parâmetros dos materiais didáticos e EPC

encontradas em (AL-MUHAIDEB; MENAI, 2011). Informações sobre o Algoritmo de Busca Harmônica (ABH) podem ser encontradas em (HNIDA et al., 2016). Detalhes do algoritmo evolucionário PBIL (*Population Based Incremental Learning*) estão em (WAN; LYU, 2014) e (ACAMPORA et al., 2011) esclarece sobre o Algoritmo Memético (AM).

3.3 RESULTADOS E ANÁLISE

A Tabela 3.4 apresenta o sumário dos trabalhos analisados em relação à SCA. Nesta Tabela, PIA representa parâmetros intrínsecos do aluno, PMD indica parâmetros do material didático, PEA denota os parâmetros extrínsecos do aluno, e por fim TS indica o tipo de sequenciamento.

Os trabalhos selecionados apontam que diversos parâmetros, tanto do aluno quanto do domínio de conhecimento, foram utilizados em outras abordagens da literatura. O nível de conhecimento do aluno foi o parâmetro mais utilizado na dimensão do aluno,

Artigo	PIA	PMD	PEA	CE	TS
(BHASKAR et al., 2010)	I,A	D,C,MC	Q	AG	SI
(ACAMPORA et al., 2011)	I,A	D,TM,M	N,T	AM	SI
(JEBARI et al., 2011)	-	D,C,P,MC	N	AG	SI
(WANG, 2011)	A	D	N	OCF+Fuzzy	SS
(VAZQUEZ et al., 2011)	-	D,P	N	OCF+RB	SS
(CHU et al., 2009)	-	D,TM,P,MC	N,T,R	OEP	SS
(RIAD et al., 2012)	A	D,M	N	OCF	SS
(LI et al., 2012)	-	D,TM,P,MC	N,T,R	AG e OEP	SS
(TAN et al., 2012)	-	D,TM	N,T	AG	SI
(SHARMA et al., 2012)	-	D	N,T	OCF	SS
(CHAKRAVERTY et al., 2012)	I	D,TM	N,T,R	OCF	SS
(KARDAN et al., 2014)	-	D	N	OCF	SS
(WAN; LYU, 2014)	A	P,C,MC,M	-	PBIL	SI
(DHARSHINI et al., 2015)	A	D	-	OCF	SI
(PIRES; COTA, 2015)	I	D	N	AG+Função estatística	SI
(HNIDA et al., 2016)	-	D,C,TM,P	N	ABH	SI
(AGARWAL et al., 2016)	I,A	M	N	OCF+Fuzzy	SS

Tabela 3.4: Sumário dos trabalhos em relação à SCA, adaptado de (MACHADO et al., 2017)

demonstrando que a adaptação deve levar em consideração o conhecimento prévio do aluno, aumentando a eficiência na aprendizagem. Embora Dharshini et al. (2015) não utilizem tal parâmetro de forma explícita, a intenção de aprendizagem é demonstrada a partir de um dos níveis do domínio cognitivo da Taxonomia de Bloom. Por outro lado, pode-se perceber que o contexto de infraestrutura do aluno não é largamente explorado, visto que apenas um dos trabalhos considerou o parâmetro “Qualidade de Conexão”, embora exista a impressão de que esse parâmetro seja fundamental para a EaD.

Nota-se que quase metade dos trabalhos não utilizam nenhum dos parâmetros intrínsecos relacionados aos alunos. Esse fato indica que, apesar da tentativa de adaptabilidade voltada ao aluno seja o assunto principal para a construção da SCA, as informações que os definem e os distinguem ainda são pouco utilizadas. Uma das explicações para isso está relacionada à dificuldade de relacionamento desses parâmetros com o domínio conceitual, sendo difícil, por exemplo, associar um EA a um material específico contido em

um repositório.

O parâmetro mais utilizado na dimensão do material didático está relacionado à dificuldade. Isso era esperado, dado que é necessário ter um relacionamento desse parâmetro com a dificuldade do aluno para se compreender o nível de maestria de aluno.

As metaheurísticas OCF e AG continuam sendo as abordagens evolucionistas mais utilizadas para o problema da SCA (AL-MUHAIDEB; MENAI, 2011). É possível perceber uma relação com o tipo de sequenciamento, onde, na maioria dos trabalhos, OCF está relacionada ao SS, assim como AG está relacionado ao SI. Esse comportamento está relacionado à fundamentação dessas metaheurísticas. Com AG, normalmente busca-se encontrar a melhor população de materiais didáticos para um aluno e, com OCF, o comportamento dos alunos (formigas) interferem no caminho dos demais. Porém, em (DHARSHINI et al., 2015), as formigas representam os materiais didáticos e, em Li et al. (2012), utiliza-se o *feedback* dos alunos para ajustar a dificuldade dos materiais, justificando a diferença. Essa relação mostra uma tendência no momento de utilização de uma abordagem em detrimento de outra.

Li et al. (2012) utilizam duas abordagens evolucionistas de forma paralela, pois um dos objetivos é avaliar qual tem o melhor desempenho de acordo com o crescimento do domínio conceitual. Essa é uma estratégia interessante, pois a área carece de *benchmarks* para comparação das soluções. Vazquez et al. (2011) utilizam Rede Bayesiana (RB) para prever a probabilidade de sucesso em compreender uma unidade através do histórico e dos perfis dos alunos. Wang (2011) e Agarwal et al. (2016) trabalharam com lógica *Fuzzy* para melhorar a seleção dos materiais didáticos de acordo com as informações da sequência encontrada pela abordagem evolucionista utilizada. Pires & Cota (2015) empregam uma função estatística (Qui-quadrado) que serve como uma pré-avaliação associada à função de *fitness*. Ou seja, técnicas já conhecidas estão sendo utilizadas em conjunto com abordagens evolucionistas para melhorar a acurácia ou o desempenho da solução.

Duas abordagens evolucionistas que não haviam sido citadas em trabalhos anteriores de revisão foram utilizadas: PBIL e ABH. Wan & Lyu (2014) abordam a adaptabilidade utilizando PBIL visto que esse algoritmo é aplicado em problemas com altos requisitos computacionais. O trabalho faz uma comparação com um problema utilizando AG e indica que o PBIL tem melhores resultados de desempenho e acurácia. Por outro lado, Agarwal et al. (2016) utilizam ABH, pois essa, assim como OEP e AG, pertencem a

uma classe de algoritmos não determinísticos cuja solução pode variar a cada execução. Assim, a qualidade da solução obtida depende da população inicial, dos parâmetros e operações escolhidos. AG e OEP requerem um conjunto de configurações. Além disso, a maioria das implementações de AG precisam de codificação cromossômica, que é diferente de um problema para outro. Por outro lado, ABH poderia ser implementada diretamente, precisando apenas de parâmetros, tais como, a função de *fitness* e o critério de parada. Essa abordagem ainda retorna um conjunto de soluções, isto é, retorna SCAs ordenadas cuja melhor solução está mais acima das outras. Esses dois últimos trabalhos, em conjunto com os de Acampora et al. (2011), mostram através de suas soluções que é válido explorar abordagens ainda não tão comuns na literatura de SCA.

4 ALGORITMO PRESA-PREDADOR PARA SOLUÇÃO DO PROBLEMA DE SCA

Um problema de otimização tem por objetivo encontrar a melhor combinação dentre um conjunto de soluções para se atingir um determinado objetivo. Assim, formular um problema matematicamente como um problema de otimização para solucioná-lo usando o raciocínio científico tornou-se útil em diversas aplicações (TILAHUN; ONG, 2015). Problemas de otimização normalmente estão relacionados ao tamanho de espaço de busca e à dificuldade computacional de se explorar todo esse espaço para obter a melhor solução. Nesse contexto, metaheurísticas se mostram, classicamente, como boas opções para tratar esses problemas (TALBI, 2009). Em geral, embora metaheurísticas não garantam a obtenção da melhor solução, tendem a encontrar um resultado razoavelmente satisfatório. Pode-se dizer que metaheurísticas são estratégias de alto nível para explorar espaços de busca usando diferentes métodos e servem a três propósitos principais: (1) resolver problemas rapidamente, (2) resolver problemas com espaços de busca relativamente grandes e (3) obter um algoritmo robusto (TALBI, 2009). Além disso, são geralmente simples de implementar e flexíveis.

Desde a introdução dos algoritmos evolucionistas, muitos algoritmos metaheurísticos foram desenvolvidos. A maioria desses algoritmos são inspirados por fenômenos naturais, por exemplo, em 1992, a OCF foi desenvolvida imitando o comportamento das formigas ao saírem de sua colônia para encontrar comida (DORIGO; BLUM, 2005). A OEP também foi desenvolvida na mesma década, em 1995 (KAMEYAMA, 2009), e é inspirada no comportamento social e cooperativo exibido por várias espécies, tais como pássaros e peixes. De fato, os anos 80 e 90 foram importantes para o desenvolvimento de algoritmos metaheurísticos (YANG; PRESS, 2010). Recentemente, uma série desses algoritmos foi introduzida. Estes incluem: o Algoritmo de Vagalumes (YANG; PRESS, 2010), que é inspirado no comportamento de vagalumes com relação ao efeito de atratividade baseado na intensidade de seu brilho; O algoritmo de Busca de Cuco (YANG; PRESS, 2010), que é inspirado no comportamento de pássaros da espécie Cuco que utilizam o parasitismo por colocarem seus ovos em ninhos de aves de outras espécies; o Modelo Evolucionário Humano, que é um método inteligente de otimização evolucionista que utiliza conhecimento

de consenso de especialistas com o objetivo de inferir os parâmetros mais adequados para alcançar a evolução de maneira inteligente (MONTIEL et al., 2007). O Algoritmo Presa-Predador (APP) é inspirado no comportamento entre animais, classificados como presas e predadores que vivem em um mesmo ecossistema e competem por recursos (TILAHUN; ONG, 2015). Tal metaheurística foi utilizada neste trabalho para tratar o problema da SCA e será discutida com mais detalhes nas seções que seguem.

Muitos dos problemas reais de otimização envolvem múltiplas medidas de desempenho (ou objetivos) que devem ser otimizados simultaneamente. No entanto, incluir múltiplos objetivos traz a tona a dificuldade de comparar apropriadamente duas soluções distintas (DEB, 2001). Isto é, de que maneira os resultados de cada objetivo devem ser combinados para decidir corretamente qual solução é melhor? De fato, a principal dificuldade reside nas principais técnicas de otimização, pois essas estão comumente relacionadas a problemas de um único objetivo, ou seja, problemas em que a satisfatoriedade de uma dada solução pode ser medida através de um valor escalar (DEB, 2001).

Como um único objetivo com várias restrições pode não representar adequadamente o problema da SCA, uma solução é modelá-lo com mais de um objetivo (MUHAMMAD et al., 2016). Portanto, neste trabalho foi utilizada uma função com cinco objetivos que são apresentados nas seções seguintes.

4.1 MOTIVAÇÃO PARA ESCOLHA DA METAHEURÍSTICA

O APP proposto por Tilahun & Ong (2015) foi escolhido neste trabalho para tratar o problema da SCA e, embora o APP seja uma metaheurística apresentada recentemente, é válido ressaltar que existem outras que incluem presa e predador em seu nome. Por exemplo, Haynes & Sen (1995) discutem sobre a evolução das estratégias comportamentais em predadores e presas com base na perseguição presa-predador. Esse trabalho considera que as presas estão dispostas em uma malha e que se movimentam a medida que o predador se aproxima. Isso difere do algoritmo proposto por Tilahun & Ong (2015), que não considera uma malha. Outro algoritmo é o Presa Predador Espacial proposto por Laumanns et al. (1998). Esse algoritmo se baseia em teoria dos grafos, onde cada presa é colocada em um vértice. Ao contrário do APP proposto por Tilahun & Ong (2015), o número de soluções pode crescer através das iterações e as operações de atualização da população são bastante diferentes, pois não existe morte no APP, mas a substituição de

uma solução existente. Além disso, o APP usa o predador como agente diversificador no espaço de soluções.

O AG e OEP são duas metaheurísticas comumente utilizadas para o problema da SCA, principalmente nos trabalhos que consideram o tipo de sequenciamento individual – como pode ser visto na Seção 3.3 e no trabalho de Al-Muhaideb & Menai (2011). O AG, assim como o APP, é um algoritmo de otimização populacional, porém, diferentemente do APP, as novas gerações não são afetadas pelo membro com pior desempenho. A OEP, assim como o APP, é uma metaheurística que imita algum aspecto real da natureza, porém essas diferem em algumas pontos básicos:

- Na OEP, a direção de cada partícula é atualizada de acordo com as posições das partículas, x_{best} e g_{best} , enquanto a atualização do APP depende das melhores soluções e também é feita por um membro com pior desempenho.
- Ao contrário do APP, a distância entre a melhor partícula e uma partícula comum não tem um impacto no processo de atualização do OEP.
- O OEP executa a atualização usando uma memória das melhores soluções, x_{best} e g_{best} . No APP não há nenhuma memória das iterações anteriores e depende unicamente do estado atual.

Tilahun & Ong (2015) comparam o APP com essas duas metaheurísticas utilizando cinco problemas distintos e o resultado indica que o APP alcança melhores resultados do que o AG e a OEP, dados os parâmetros apresentados no trabalho. Por esse motivo, este trabalho de dissertação parte da hipótese de que o APP também é uma metaheurística viável para o problema da SCA e segue a premissa de que esse pode ser uma solução melhor do que AG e OEP, dados os resultados de comparação de Tilahun & Ong (2015).

4.2 MODELAGEM DO PROBLEMA

A predação é uma relação ecológica entre organismos vivos que se alimentam de outros animais de outras espécies. Existem diferentes tipos de interação presa-predador baseado no tipo da presa e como o predador consome essa presa. Entretanto, o foco aqui está na interação carnívora entre animais. Os predadores procuram ativamente e perseguem as suas presas que, por sua vez, têm que tentar escapar correndo, se escondendo ou até

mesmo lutando. Muitas vezes as presas tendem a se juntar a outras na fuga e, como as presas mais rápidas e fortes tendem a ter mais chances de escapar do predador, as presas mais frágeis tentam se juntar a elas. Por isso, o predador tende a perseguir as presas mais fracas que estejam mais próximas e sozinhas. Abaixo será discutida a modelagem do problema da SCA inspirada na interação presa-predador, conforme o algoritmo proposto por Tilahun & Ong (2015).

As presas e o predador são indivíduos que aqui são representados a partir de um vetor de números binários. Esse vetor é a representação do repositório de materiais didáticos, ou seja, todos os materiais passíveis de escolha. O indivíduo pode ser visto como $s = \{x_1, x_2, \dots, x_{|M|-1}, x_{|M|}\}$, onde M representa o conjunto de materiais no repositório e x_i denota um valor binário que indica se o material $m_i \in M$ faz parte da solução (quando $x_i = 1$) ou não (quando $x_i = 0$).

Existem animais que naturalmente têm mais chance de sobrevivência, por exemplo, por serem mais velozes. Assim, pode-se dizer que cada animal tem a ele associado um valor de sobrevivência que indica a chance dele escapar do predador em uma interação. Portanto, a cada indivíduo $s \in S$ será associado um valor $SV(s)$ que é calculado a partir de uma função objetivo $f(s)$. Neste trabalho, a otimização está ligada a um problema de minimização, isto é, quanto menor for o valor de sobrevivência maior é a chance do indivíduo sobreviver. A minimização é dada por:

$$\min_{s \in S} f(s), \quad (4.1)$$

Considerando um conjunto S de soluções candidatas, s_j é dita como solução ótima global para o problema de minimização da Equação (4.1), se $s_j \in S$ tal que $f(s_j) \leq f(s_i), \forall s_i \in S$.

4.3 ALGORITMO PRESA-PREDADOR

Inicialmente é associado a todas as possíveis soluções um valor de sobrevivência de acordo com uma função objetivo. Em seguida, esses indivíduos são declarados como presas ou predador, onde o indivíduo com maior valor de sobrevivência (menor chance de sobreviver) é indicado como **predador** e as demais soluções candidatas são indicadas como presas. A presa que tem o menor valor de sobrevivência recebe o rótulo de **melhor presa** e cada uma das outras presas recebe o rótulo de **presa comum**.

Uma vez que as presas e o predador foram identificados, as presas precisam fugir do predador, se aliar a outras presas ou encontrar um esconderijo. A exploração do espaço de busca é feita pela interação entre presas e o predador: enquanto o predador está caçando as presa e elas tentam fugir, o que consiste na fase de diversificação da busca. A intensificação é feita pelas presas, especialmente pela presa com o melhor valor de sobrevivência, que faz uma pesquisa por locais que melhorariam seu valor de sobrevivência. A melhor presa é considerada aquela que encontrou um esconderijo e, assim, não é afetada pelo predador.

Dois fatores básicos são levados em consideração sobre o movimento dos indivíduos: (1) a direção na qual o movimento ocorrerá e (2) o comprimento do passo, que irá determinar quanto a presa ou predador irá caminhar naquela direção. No contexto deste trabalho, ao dizer que um indivíduo está indo na direção de outro, significa que suas configurações (distribuição de 0s e 1s) estão se tornando mais parecidas. Ou seja, indivíduos que estão no mesmo local são exatamente iguais. Para o cálculo da distância entre dois indivíduos representados por vetores, é utilizada a distância de *Hamming*¹. Para o contexto da metáfora presa-predador, a distância de *Hamming* trabalha de forma diretamente proporcional, ou seja, quanto maior seu valor, mais distante um indivíduo está do outro.

Geralmente, a direção a que uma presa comum irá se movimentar leva em consideração a localização das presas com melhor valor de sobrevivência. Nesse caso, é necessário identificar essas presas $\{s_1, s_2, \dots, s_p\}$. Naturalmente, as presas tendem a se reunir com presas que estão mais próximas a ela, ou seja, não apenas o valor de sobrevivência é considerado para a direção, mas também a distância. Além disso, também é considerado no movimento uma direção randômica y_r que irá diversificar a busca. Dada uma presa s_i , para cada presa s_j , com $i \neq j | SV(s_j) < SV(s_i)$, é calculado $CS(s_j) \in [0, 1]$, que indica a chance daquela presa ser seguida, dada pela Equação 4.2,

$$CS(s_j) = \frac{2 - \tau \frac{HD(s_j, s_i)}{m} + \eta \frac{SV(s_j)}{SV(s_i)}}{2} \quad (4.2)$$

onde $\tau \in [0, 1]$ representa o peso da distância para o movimento, $\eta \in [0, 1]$ representa o peso do valor de sobrevivência para o movimento, $HD(s_j, s_i)$ é a distância de *Hamming*

¹Na teoria da informação, a distância de *Hamming* entre duas *strings* de mesmo comprimento é o número de posições nas quais elas diferem entre si. Vista de outra forma, ela corresponde ao menor número de substituições necessárias para transformar uma *string* na outra, ou o número de erros que transformam uma na outra.

entre os indivíduos s_j e s_i e m indica a quantidade de componentes dos vetores que representam os indivíduos. A partir desses valores é criada uma roleta que será girada para cada passo de uma presa comum, indicando qual presa deverá ser seguida. A chance de uma presa s_j ser selecionada pela roleta é proporcional ao valor de $CS(s_j)$. Supondo que o CS tenha sido calculado para 3 presas, então a Figura 4.1 representa uma possível roleta gerada para esse exemplo.




Figura 4.1: Roleta criada a partir do valor CS.

Para cálculo da quantidade de passos que s_i irá dar em direção às melhores presas, é preciso considerar sua distância com relação ao predador, visto que, quanto mais próximo, mais rápido é necessário que a presa se movimente e vice-versa. Assim, tem-se a seguinte equação para a quantidade de passos $l_{max}(i)$:

$$l_{max}(i) = \frac{\lambda_{max}\varepsilon}{e^{\beta \frac{HD(s_i, s_{predador})}{m}}} \quad (4.3)$$

O parâmetro $\beta \in [0, 1]$ é um peso que representa a importância da distância entre a presa e o predador para com a quantidade de passos. Além disso, $\lambda_{max} \leq m$ é um parâmetro que indica a quantidade máxima de passos que poderia ser dada por qualquer indivíduo do conjunto de soluções e $\varepsilon \in [0, 1]$ é um valor gerado aleatoriamente.

Existe uma chance da presa não seguir nenhuma outra presa, pois sua preocupação no momento é apenas ir para um local que a deixe mais longe do predador. Para isso, é gerado um valor aleatório que irá determinar se a presa irá ou não seguir as outras. Caso essa verificação indique que a presa não irá seguir outras, então é gerada uma direção aleatória y_r que é comparada com sua direção complementar $-y_r$ com intuito de verificar

qual delas deixaria a presa mais longe do predador, isto é:

$$d_1 = HD(s_{predador}, y_r) \quad (4.4)$$

$$d_2 = HD(s_{predador}, -y_r) \quad (4.5)$$

Se $d_1 > d_2$ então y_r será considerada a direção aleatória que a presa irá fugir do contrário $-y_r$ será a direção escolhida.

O outro caso de movimentação de uma presa é quando não há outra presa melhor que ela, ou seja, não há uma presa com menor valor de sobrevivência. Nesse caso, essa presa irá fazer uma pesquisa, gerando locais aleatórios e verificando se em algum desses locais seu valor de sobrevivência é menor que o atual. Se houver um melhor local, então essa presa irá para ele. Do contrário, ela irá permanecer no seu local atual.

Por fim, o predador irá seguir a presa com pior valor de sobrevivência – por se tratar da presa mais frágil e, portanto, mais fácil de capturar – nesse caso apenas a quantidade de passos $l_{predador}$, dada pela Equação 4.6, é considerada, onde $\lambda_{min} \leq \lambda_{max} \leq m$ é um parâmetro que indica a quantidade mínima de passos que poderia ser dada por qualquer indivíduo do conjunto de soluções. Além disso, o predador também considera uma direção aleatória y_r em seu movimento.

$$l_{predador} = \lambda_{min}\varepsilon \quad (4.6)$$

A cada interação do APP, as presas e o predador são atualizados. Os passos do APP usado neste trabalho podem ser resumidos da seguinte maneira:

1. Gera soluções aleatórias
2. Calcula o valor de sobrevivência de cada solução
3. Identifica as presas e o predador
4. Realiza a movimentação de todos os indivíduos
5. Verifica se a condição de parada foi satisfeita. Caso contrário, volta ao passo 2

Nos algoritmos 1, 2 e 3 são detalhados os passos, anteriormente apresentados, a partir de pseudocódigo. Nestes, n indica o número de soluções, $fs \in [0, 1]$ determina a chance

da presa seguir as presas que são melhores que ela e I indica a quantidade de iterações do algoritmo, sendo esse o critério de parada.

Algoritmo 1: ALGORITMO PRESA PREDADOR

Entrada: $\lambda_{min}, \lambda_{max}, \eta, \beta, \tau, n, I, fs$

Saída: A melhor solução encontrada

início

 Gera conjunto aleatório de soluções iniciais; $S = \{s_i \mid i = 1, 2, 3, \dots, n\}$

para $k \leftarrow 1$ até I **faça**

 Calcula SV para cada integrante de S

$s_{predador} \leftarrow s_j \mid SV(s_j) \geq SV(s_i), \forall i = 1, \dots, n, i \neq j$

$P \leftarrow S - s_{predador}$

$S' \leftarrow \{\}$

para $p \leftarrow 1$ até $|P|$ **faça**

$s_p \leftarrow MovimentaPresa(S, s_p, s_{predador}, \lambda_{min}, \lambda_{max}, \eta, \beta, \tau, fs)$

$S' \leftarrow S' \cup \{s_p\}$

fim para

$s_{predador} \leftarrow MovimentaPredador(s_{predador}, \lambda_{min}, \lambda_{max}, S)$

$S \leftarrow S' \cup \{s_{predador}\}$

fim para

retorna $s_j \mid SV(s_j) \leq SV(s_i), \forall i \neq j$

fim

4.4 FUNÇÃO OBJETIVO

Considerando o objetivo principal deste trabalho, que busca gerar uma SCA que atenda as necessidades dos alunos, as seguintes características foram levadas em consideração: tempo de disponibilidade do aluno, nível de conhecimento, EA e objetivos de aprendizagem. Esses objetivos precisam ser considerados de maneira conjunta, onde a melhor solução será aquela que atenda a todos os critérios. Portanto, será utilizada a agregação de objetivos, que consiste em combinar diversas funções afim de encontrar um resultado equivalente a todas elas. Assim, a avaliação f de uma determinada solução será dada por:

$$f = \sum_{i=1}^n \omega_i f_i \quad (4.7)$$

onde f_i representa a avaliação da solução em relação a um determinado objetivo i e ω_i corresponde ao respectivo peso, para um total de n objetivos.

Chu et al. (2009) trataram a SCA como um problema Multi-Objetivo com 4 funções objetivo. Eles levaram em consideração os seguintes critérios: (1) Se os materiais consi-

Algoritmo 2: MOVIMENTAPRESA

Entrada: $S, s_p, s_{predador}, \lambda_{min}, \lambda_{max}, \eta, \beta, \tau, fs$
Saída: A presa após sua movimentação

início
 $A \leftarrow s_j \mid SV(s_j) < SV(s_i), \forall i = 1, 2, \dots, n, i \neq j$

// Verifica se s é a melhor presa

se $A = \{\}$ **então**

Gera k vetores randômicos $u_1, u_2, u_3, \dots, u_k$
 $U \leftarrow \{s_p\}$

Segue cada um dos vetores u_k com uma quantidade $\lambda_{min}\varepsilon$ de passos e armazena em U
 $s_p \leftarrow s_j \mid SV(s_j) \leq SV(s_i), \forall i = 1, 2, \dots, k + 1, j \neq p$
senão

Gera número aleatório $a \in [0, 1]$

//Verifica se presa seguirá as melhores

se $a \leq fs$ **então**

Cria roleta a partir da Equação 4.2

Calcula l_{max} através da Equação 4.3

Segue presas s_j geradas pela roleta em l_{max} passos

Gera direção aleatória y_r

Segue y_r com uma quantidade $\lambda_{min}\varepsilon$ de passos

senão

Gera direção aleatória $y_r \mid SV(y_r) \leq SV(s_p)$ Gera vetor $-y_r$

//complementar de y_r

Calcula distâncias d_1 e d_2 de acordo com as equações 4.4 e 4.5

se $d_1 \leq d_2$ **então**
 $y_r \leftarrow -y_r$
fim se

Segue y_r com uma quantidade $\lambda_{max}\varepsilon$ de passos

fim se
fim se
retorna s_p
fim

Algoritmo 3: MOVIMENTAPREDADOR

Entrada: $s_{predador}, \lambda_{min}, \lambda_{max}, S$
Saída: O predador após sua movimentação

início
 $s_{pior} \leftarrow s_j \mid SV(j) \geq SV(s_i), \forall i = 1, 2, \dots, n, i \neq j, s_j \neq s_p$

Segue s_{pior} com uma quantidade $\lambda_{min}\varepsilon$ de passos

Gera direção aleatória y_r

Segue y_r com uma quantidade $l_{predador}$ de passos dada pela Equação 4.6

retorna $s_{predador}$
fim

deram os conceitos que estão relacionados aos objetivos de aprendizagem do aluno, (2)

se os materiais estão de acordo com o nível de habilidade do aluno, (3) se os materiais

respeitam a limitação de tempo do aluno e (4) se os materiais estão equilibrados de acordo com os conceitos que estão relacionados aos objetivos de aprendizagem do aluno. É válido salientar que as funções utilizadas por Chu et al. (2009) foram abordadas em diversos trabalhos relacionados a SCA, tais como (DHEEBAN et al., 2010; LI et al., 2012; DEBBAH; ALI, 2014; HAFIDI; BENSEBAA, 2015), reforçando assim a validade da solução. Contudo, essas funções, por si só, não consideram nenhum parâmetro intrínseco do aluno, então, neste trabalho foi criada uma função objetivo que leva em consideração o EA do aluno baseado nas 4 dimensões do FLSM. Cada EA do aluno é associado a três atributos da dimensão do material didático de acordo com o LOM: Tipo, Tipo de Interatividade e Nível de Interatividade. À medida que as características de um material didático se afasta do EA do aluno são agregadas penalidades à solução.

Na próxima seção são apresentados os parâmetros utilizados por cada uma das funções objetivas utilizadas por este trabalho.

4.4.1 PARÂMETROS

Seja A o conjunto de alunos de um dado curso, M o conjunto de materiais didáticos disponíveis no curso e C o conjunto de conceitos que o curso pretende abordar, tem-se os seguintes parâmetros dos alunos:

- $H_{c_j}^{a_k}$, representa o grau de habilidade do aluno $a_k \in A$ com relação a um conceito $c_j \in C$
- $E_{c_j}^{a_k}$ representa os objetivos de aprendizagem esperado por um aluno $a_k \in A$ com relação a um conceito $c_j \in C$, onde $E_{c_j}^{a_k} = 1$ se o conceito c_j deve ser entregue ao aluno a_k e $E_{c_j}^{a_k} = 0$ caso contrário
- $T_{inf}^{a_k}$, representa o limite inferior de tempo esperado de duração do curso para o aluno $a_k \in A$
- $T_{sup}^{a_k}$, representa o limite superior de tempo esperado de duração do curso para o aluno $a_k \in A$
- $EA_{ar}^{a_k}$, representa o valor na dimensão Ativo/Reflexivo do FLSM do aluno $a_k \in A$
- $EA_{si}^{a_k}$, representa o valor na dimensão Sensorial/Intuitivo do FLSM do aluno $a_k \in A$

- $EA_{vv}^{a_k}$, representa o valor na dimensão Visual/Verbal do FSLSM do aluno $a_k \in A$
- $EA_{sg}^{a_k}$, representa o valor na dimensão Sequencial/Global do FSLSM do aluno $a_k \in A$

Em seguida, são apresentados os parâmetros dos materiais didáticos:

- D^{m_i} , representa o grau de dificuldade do material didático $m_i \in M$
- $R_{c_j}^{m_i}$ representa os conceitos $c_j \in C$ cobertos por um material didático $m_i \in M$. Onde $R_{c_j}^{m_i} = 1$ se o material didático m_i cobre o conceito c_j e $R_{c_j}^{m_i} = 0$ caso contrário.
- $T_{est}^{m_i}$ representa o tempo estimado de aprendizagem de cada material didático $m_i \in M$
- α_{m_i} indica se o material didático $m_i \in M$ é do EA ativo se $\alpha_{m_i} > 0$, do EA reflexivo se $\alpha_{m_i} < 0$ ou neutro se $\alpha_{m_i} = 0$
- β_{m_i} indica se o material didático $m_i \in M$ é do EA sensorial se $\beta_{m_i} > 0$, do EA intuitivo se $\beta_{m_i} < 0$ ou neutro se $\beta_{m_i} = 0$
- γ_{m_i} indica se o material didático $m_i \in M$ é do EA visual se $\gamma_{m_i} > 0$, do EA verbal se $\gamma_{m_i} < 0$ ou neutro se $\gamma_{m_i} = 0$
- θ_{m_i} indica se o material didático $m_i \in M$ é do EA sequencial se $\theta_{m_i} > 0$, do EA global se $\theta_{m_i} < 0$ ou neutro se $\theta_{m_i} = 0$

Além desses, x_i representa um valor binário relacionado a uma solução candidata, onde $x_i = 1$ caso o material $m_i \in M$ faça parte da solução $s \in S$ e $x_i = 0$ caso contrário, conforme apresentado na Seção 4.2.

Considerando esses parâmetros, nas próximas subseções são apresentadas as funções objetivos que compõem a função objetivo utilizada para o problema tratado no escopo deste trabalho.

4.4.2 COBERTURA DOS CONCEITOS

Esta função objetivo visa verificar os conceitos que estão sendo cobertos pela sequência de materiais didáticos avaliada.

Chu et al. (2009) apresentaram uma função que calcula a diferença média entre os conceitos que estão sendo entregues por cada um dos materiais didáticos e os objetivos

de aprendizagem de um aluno. Essa função objetivo pode ser interpretada da seguinte maneira: (1) sempre que um material didático da sequência cobre um conceito que não faz parte dos objetivos de aprendizagem do aluno, uma penalidade é associada à sequência e (2) quando um material didático da sequência não cobre algum conceito que faz parte dos objetivos de aprendizagem do aluno, também são associadas penalidades para cada conceito não coberto. Entretanto, como a avaliação está sendo feita a partir de cada material, e não da solução completa, existem casos que a melhor solução acaba por não ser selecionada. Tal característica não é adequada, uma vez que, frequentemente, os materiais didáticos não vão cobrir todos conceitos de qualquer sequência curricular – principalmente se esses materiais consideram as ideias de Objetos de Aprendizagem (OA), onde, de forma a promover o reuso e a interoperabilidade, tendem a ser atômicos (WILEY, 2000).

A partir dessa análise, a função utilizada neste trabalho irá considerar a sequência como um todo, prezando por sequências que entregam exatamente os conceitos que fazem parte do objetivo de aprendizagem do aluno. As penalidades são associadas à quantidade de conceitos sobressalentes entregues pela sequência de materiais e também à quantidade de conceitos faltantes, sendo ainda mais severa, pois não cumpre com os objetivos de aprendizagem do aluno. Considerando R^{m_i} o conjunto de conceitos que o material $m_i \in M$ cobre, E^{a_k} o conjunto de conceitos que fazem parte dos objetivos de aprendizagem do aluno $a_k \in A$ e σ um peso (≥ 1) associado a penalidade por se ter conceitos faltante, a função objetivo relacionada aos conceitos é dada por:

$$O_1 = |R^{m_i}| - |R^{m_i} \cap E^{a_k}| + \sigma(|E^{a_k}| - |R^{m_i} \cap E^{a_k}|) \quad (4.8)$$

4.4.3 DIFICULDADE

Diferente do artigo Chu et al. (2009), a função relacionada a dificuldade do material didático levará em consideração o nível de habilidade do aluno relacionado a cada um dos conceitos e não apenas um valor de habilidade genérico. Portanto, ao analisar se um material deve ser entregue ao aluno, sua dificuldade será comparada com a média da habilidade do aluno nos conceitos cobertos pelo material e que constam nos objetivos de

aprendizagem do aluno. Portanto:

$$O_2 = \sum_{i=1}^{|M|} x_i \left| D^{m_i} - \frac{\sum_{j=1}^{|C|} R_{m_i}^{c_j} E_{c_j}^{a_k} H_{c_j}^{a_k}}{\sum_{j=i}^{|C|} R_{m_i}^{c_j} E_{c_j}^{a_k}} \right| \frac{1}{\sum_{i=1}^{|M|} x_i} \quad (4.9)$$

4.4.4 TEMPO TOTAL DO CURSO

O tempo total do curso deve estar entre o limite inferior e superior do tempo esperado pelo aluno (CHU et al., 2009):

$$O_3 = \left(\max \left(T_{inf}^{a_k} - \sum_{i=1}^{|M|} T_{est}^{m_i} x_i, 0 \right) + \max \left(0, \sum_{i=1}^{|M|} T_{est}^{m_i} x_i - T_{sup}^{a_k} \right) \right) \quad (4.10)$$

4.4.5 BALANCEAMENTO DOS MATERIAIS

Para evitar a situação de que os conceitos de aprendizado cobertos pelo curso não estejam equilibrados, a função abaixo é usada para equilibrar o peso dos conceitos de aprendizado relevantes (CHU et al., 2009):

$$O_4 = \sum_{j=1}^{|C|} E_{c_j}^{a_k} \left| \sum_{i=1}^{|M|} x_i R_{c_j}^{m_i} - \frac{\sum_{i=1}^{|M|} \sum_{j=1}^{|C|} x_i R_{c_j}^{m_i}}{\sum_{j=1}^{|C|} E_{c_j}^{a_k}} \right| \quad (4.11)$$

4.4.6 ESTILO DE APRENDIZAGEM

Aos materiais didáticos foram associados quatro valores, que estão de acordo com cada dimensão do FLSM. Esses valores podem ser positivos, negativos ou zero e indicam a tendência do material para uma das opções de cada dimensão. Por exemplo, se o valor da dimensão **Participação** for positivo indica que o material tende a ser ativo, caso seja negativo indica que o material didático tende a ser reflexivo e caso seja zero indica que o material didático não apresenta uma tendência para nenhuma das opções. Esses valores são calculados a partir da contagem de pontos, de acordo com cada dicotomia, utilizando a Tabela 4.1 (MÉNDEZ et al., 2016). Essa Tabela mostra a relação entre os atributos do IEEE-LOM e os EAs do FLSM. Para determinar se os metadados são relevantes ou não para cada EA, é colocado um valor 1 ou 0 conforme seja aplicável. Por exemplo,

se o tipo de um material didático for “Exercício”, esse será conveniente para ao aluno com EA “Ativo” (representado pela alternativa A da Tabela), enquanto não se aplica a um aluno “Reflexivo” (representado pela alternativa B), então a coluna A na linha do material didático do tipo “Exercício” haverá o valor 1 enquanto na coluna B da mesma linha é alocado o valor 0. Diferentemente do que é apresentado por Méndez et al. (2016), neste trabalho é considerada a intensidade relacionada ao Nível de Interatividade “Ativo”, de forma que os valores podem variar de 0 a 4 nesse EA. O cálculo dos valores é feito da seguinte maneira: supondo um material dos tipos “Exercício” e “Diagrama” que tenha um nível de interatividade “Baixo” e que apresente um tipo de interatividade “Misto”. Ao analisar o EA da dimensão Participação, verifica-se que na linha do tipo “Exercício” tem-se o valor 1 na coluna A somando 1 ponto para o EA “Ativo” já na linha do tipo “Diagrama” tem-se o valor 1 na coluna B somando 1 ponto para o EA “Reflexivo”. Verificando o nível de interatividade na linha do valor “Baixo”, tem-se o valor 1 na coluna A somando mais 1 ponto para o EA “Ativo”. Por fim, no tipo de interatividade “Misto”, soma-se mais 1 ponto para ambos os EAs. Ao final, o EA “Ativo” somou 3 pontos contra 2 pontos do EA “Reflexivo” e, portanto, esse material será considerado “Ativo” com valor de $\alpha_{m_i} = 3 - 2$, ou seja, $\alpha_{m_i} = +1$. Esse mesmo raciocínio é utilizado para as outras dimensões.

Por outro lado, tem-se o EA dos alunos, que foram divididos em seis valores inteiros, exceto o 0, variando de -3 a 3, onde os valores negativos são para os EAs “Reflexivo”, “Intuitivo”, “Verbal” e “Global” e os valores positivos são para os EAs “Ativo”, “Sensorial”, “Visual” e “Sequencial”. Os valores -3 e +3 são para aqueles alunos que apresentaram uma preferência intensa por um EA. Os valores -2 e +2 são para aqueles alunos que apresentam uma preferência moderada por um EA e, por fim, os valores -1 e +1 são para aqueles alunos que não apresentaram uma preferência relevante por um EA. A partir dessas informações e considerando a função a seguir:

$$sgn(p) = \begin{cases} -1, & \text{se } p < 0 \\ 0, & \text{se } p = 0 \\ +1, & \text{se } p > 0 \end{cases}$$

Possíveis metadados	Ativo / Re-flexivo		Sensorial / Intuitivo		Visual / Verbal		Sequencial / Global	
	A	B	A	B	A	B	A	B
Tipo								
Exercício	1	0	1	0	0	0	1	0
Simulação	1	1	1	1	1	0	1	0
Questionário	1	0	0	1	0	0	0	0
Diagrama	0	1	0	1	1	0	1	1
Figura	0	1	0	1	1	0	0	1
Gráfico	0	1	1	0	1	0	0	1
Apresentação	0	1	1	1	1	1	1	1
Tabelas	0	1	1	0	1	0	0	1
Texto narrativo	0	1	1	1	0	1	1	1
Experimento	1	0	1	0	0	0	1	0
Declaração de Problemas	0	1	1	0	0	0	0	0
Nível de Interatividade								
Muito baixo	0	0						
Baixo	1	0						
Médio	2	0						
Alto	3	0						
Muito alto	4	0						
Tipo de Interatividade								
Ativo	1	0						
Expositivo	0	1						
Misto	1	1						

Tabela 4.1: Tabela para mapeamento de EA dos materiais didáticos.

tem-se a seguinte função para a dimensão Participação:

$$F_1 = \frac{\sum_{i=1}^{|M|} x_i |3 * \text{sgn}(\alpha_{m_i}) - EA_{ar}^{a_k}|}{\sum_{i=1}^{|M|} x_i} \quad (4.12)$$

Para a dimensão Percepção:

$$F_2 = \frac{\sum_{i=1}^{|M|} x_i |3 * \text{sgn}(\beta_{m_i}) - EA_{si}^{a_k}|}{\sum_{i=1}^{|M|} x_i} \quad (4.13)$$

Para a dimensão Apresentação:

$$F_3 = \frac{\sum_{i=1}^{|M|} x_i |3 * sgn(\gamma_{m_i}) - EA_{vv}^{a_k}|}{\sum_{i=1}^{|M|} x_i} \quad (4.14)$$

Para a dimensão Organização:

$$F_4 = \frac{\sum_{i=1}^{|M|} x_i |3 * sgn(\theta_{m_i}) - EA_{sg}^{a_k}|}{\sum_{i=1}^{|M|} Nx_i} \quad (4.15)$$

Portanto, a função objetivo relacionada ao EA é a média das penalidades de cada uma das funções:

$$O_5 = \frac{\sum_{i=1}^4 F_i}{4} \quad (4.16)$$

5 AVALIAÇÃO

Para avaliar esta proposta, foram realizados experimentos para analisar o comportamento da abordagem e sua qualidade. O comportamento da abordagem foi analisado através de uma série de experimentos com dados gerados em laboratório, enquanto a qualidade da abordagem foi avaliada através de um experimentos com dados reais. Vale ressaltar que não existe na literatura de SCA um *benchmark* para comparação entre diferentes abordagens. Por este motivo, foi definida e estruturada uma base de avaliação para análise desta abordagem. A base está disponível¹ para uso de outros pesquisadores.

5.1 BASE PARA AVALIAÇÃO DE SCA

Apesar da literatura indicar que há uma grande variedade de repositórios de materiais didáticos, isso não se mostrou válido a partir das buscas feitas para esta pesquisa. Diversos materiais são criados e disponibilizados a todo instante, porém, normalmente, não são indexados de forma a facilitar a busca e utilização. Então, apesar da SCA ser um problema muito discutido, existe a dificuldade de encontrar dados para aplicar as soluções propostas, sobretudo bases de dados onde os materiais didáticos estejam associados a um conjunto de metadados. Assim, cada autor avalia sua solução a partir de um conjunto de dados com diferentes características, além de, ao final do processo, não disponibilizar os dados dessa base para utilização, o que dificulta muito a comparação entre as abordagens. Mediante isso, foi necessária a criação de uma base de dados.

A base criada possui como tema conceitos básicos da área de Computação. A coleção de materiais foi composta de:

- Vídeos educacionais disponibilizados em repositórios como o YouTube e Videoaula@RNP²;
- Materiais didáticos disponibilizados nas disciplinas de graduação dos cursos de Ciência da Computação e Sistemas de Informação oferecidos pela UFJF, em sua maior parte materiais confeccionados para cursos à distância oferecidos pela universidade.

¹<https://github.com/ufjf-dcc/LAPIC3-benchmark>

²<http://www.videoaula.rnp.br/portal/home>

- Outros materiais de interesse disponibilizados na Web por professores universitários de outras instituições.

Para compor a base de testes, os materiais foram selecionados de acordo com algumas características importantes para o problema de SCA: tempo de aprendizado, dificuldade, representação (textos, imagens, vídeos etc.), tipo (questionário, apresentações, simulação, textos narrativos etc), nível de interatividade e tipo de interatividade. Essa seleção de materiais teve como objetivo construir uma base heterogênea de dados que atenda aos diversos perfis de alunos. Os materiais selecionados para a base foram editados de forma a remover conteúdos irrelevantes, como propagandas ou trechos que não abordavam conceitos dentro do escopo definido para a base. De maneira similar, alguns materiais foram agregados para compor um único conceito.

Ao todo, foram selecionados 278 materiais didáticos que foram associados a diferentes conceitos básicos da Computação. Nesse conjunto, foram identificados 30 conceitos básicos e foram interligados, por especialistas, a partir de uma ordem linear de pré-requisitos, ou seja, cada conceito dependia de um conceito anterior e servia como base para um conceito posterior (excetuando o primeiro e último conceito). A maioria das representações dos materiais selecionados foram textos e vídeos.

Cada um dos materiais didáticos selecionados foi associado a um arquivo de metadados baseado no padrão IEEE-LOM. A principal dimensão utilizada do padrão foi a “Educativa”, que contém as informações de idioma, dificuldade, tipo, tipo de interatividade, nível de interatividade e tempo típico de aprendizagem. A Figura 5.1 apresenta um exemplo de preenchimento desses dados para um material didático.

O preenchimento desses metadados foi feito a partir de um consenso entre um grupo de até oito especialistas, os quais receberam uma série de materiais e preencheram todas as dimensões. Para os casos em que não houve consenso entre os especialistas, foi realizada uma votação.

Essa base de dados se mostra viável para trabalhar o problema da SCA, pois apresenta as diversas restrições que são abordadas pela maioria dos trabalhos, vide os parâmetros apresentados na Seção 3.3.

```

<educational>
  <typicalLearningTime>
    <duration>PT6M22S</duration>
  </typicalLearningTime>
  <language>pt-BR</language>
  <interactivityType>
    <source>LOMv1.0</source>
    <value>expositive</value>
  </interactivityType>
  <learningResourceType>
    <source>LOMv1.0</source>
    <value>narrative text</value>
  </learningResourceType>
  <learningResourceType>
    <source>LOMv1.0</source>
    <value>figure</value>
  </learningResourceType>
  <learningResourceType>
    <source>LOMv1.0</source>
    <value>diagram</value>
  </learningResourceType>
  <interactivityLevel>
    <source>LOMv1.0</source>
    <value>very low</value>
  </interactivityLevel>
  <difficulty>
    <source>LOMv1.0</source>
    <value>easy</value>
  </difficulty>
</educational>

```

Figura 5.1: Exemplo da dimensão Educacional do IEE-LOM preenchida.

5.2 ANÁLISE DO COMPORTAMENTO DA ABORDAGEM

Avaliar heurísticas e metaheurísticas não é uma tarefa simples, principalmente se tratando de abordagens com grande fator de aleatoriedade. Assim, normalmente são utilizados métodos empíricos de avaliação. Nesta seção, são apresentados resultados de testes de convergência e de tempo de execução relacionados à utilização do APP na geração da SCA. Para essa avaliação, foram utilizados dados sintéticos de cursos compostos por 100, 200 e 300 materiais didáticos que cobriam 15 conceitos diferentes e dados de um aluno fictício. Nestes testes foram avaliados os valores das funções objetivo, a quantidade de iterações do algoritmo e o tamanho da população.

Primeiramente, avaliando o tempo de execução, foram utilizadas populações s de tamanho 10, 20 e 30 presas, com até 7500 iterações (parâmetro q), onde cada teste foi executado 10 vezes e a média foi utilizada para o resultado final. Os demais parâmetros foram escolhidos empiricamente: $\lambda_{min} = 4$, $\lambda_{max} = \frac{|M|}{4}$, chance de seguir presas melhores $fs = 0.8$, $\eta = 1$, $\tau = 1$ e $\beta = 1$. O gráfico na Figura 5.2 apresenta os resultados para a base de dados de 300 materiais didáticos e demonstra que o aumento da população impacta diretamente no acréscimo do tempo, sendo esse um resultado já esperado a medida que mais presas precisam ser consideradas na movimentação. Além disso, o aumento é

proporcional entre os tempos de execução para cada tamanho da população em um mesmo número de iteração, demonstrando que a solução é escalável. Os mesmo comportamentos são apresentados pelas outras quantidade de materiais didáticos.




Figura 5.2: Comparação de tempo de execução variando o tamanho da população para uma base de dados contendo 300 materiais didáticos.

Ainda, é possível perceber, a partir do gráfico na Figura 5.3, que a medida que o repositório de materiais didáticos aumenta, o tempo de execução também aumenta desproporcionalmente, onde a distância do tempo de execução entre o repositório com 300 materiais didáticos e o repositório com 200 é maior que a distância entre repositório com 200 materiais e repositório com 100.




Figura 5.3: Comparação de tempo de execução entre bases de dados contendo 100, 200 e 300 materiais didáticos.

Passando a analisar a convergência do algoritmo através dos valores calculados pela função objetivo (valor de *fitness*) utilizada neste trabalho, considere os gráficos das Figuras 5.4, 5.5 e 5.6. É possível perceber que, a medida que a base de dados aumenta, mais iterações são necessárias para aproximar do possível melhor valor de *fitness*, afinal o espaço de busca é maior, gerando mais combinações. A partir dos tamanhos de população testados, não foi possível notar uma diferença considerável ao aumentar o tamanho da população, pois, mesmo selecionando pequenos trechos desses gráficos, há uma grande mudança de comportamento na ordem que as curvas são apresentadas, vide o gráfico da Figura 5.7.

5.3 ANÁLISE DA QUALIDADE DA ABORDAGEM

Com objetivo de avaliar a qualidade da abordagem, foi conduzido um experimento em um curso real a partir de um ambiente online de aprendizagem. O experimento consistiu na oferta de um curso de Introdução à Computação, ministrado em seis semanas, tendo um conjunto de conceitos ministrados a cada semana. O curso foi oferecido para alunos do Departamento de Ciência da Computação, principalmente alunos dos cursos de Licenciatura em Computação, Sistemas de Informação e Ciência da Computação no período de dezembro de 2017 e março de 2018. Para participar, não era necessário qualquer tipo de conhecimento prévio. O curso foi voltado principalmente para ingressantes desses cursos,




Figura 5.4: Curva de convergência para base de dados contendo 100 materiais didáticos.




Figura 5.5: Curva de convergência para base de dados contendo 200 materiais didáticos.

embora não limitados apenas a esses, e seu objetivo foi oferecer aos participantes um melhor entendimento da área que estão se especializando, além de servir como auxílio às disciplinas que eles já cursaram ou virão a cursar.

5.3.1 CARACTERIZAÇÃO DOS PARTICIPANTES

O curso foi oferecido como um curso de extensão gratuito na UFJF e os participantes se inscreveram voluntariamente. Foram convidados 128 alunos do curso de Licenciatura em Computação (curso oferecido na modalidade de EaD), do curso de bacharelado em Sistemas de Informação e dos primeiros períodos do curso de bacharelado em Ciência da




Figura 5.6: Curva de convergência para base de dados contendo 300 materiais didáticos.




Figura 5.7: Trecho da curva de convergência para base de dados contendo 300 materiais didáticos.

Computação da UFJF ingressantes em 2017.

Inicialmente, foi oferecido aos interessados um formulário online de inscrição com objetivo de capturar suas informações básicas, tais como, nome, curso e contato. Além disso os inscritos deveriam aceitar um termo que informava sobre a utilização dos dados do curso em uma pesquisa de mestrado, indicando que os dados pessoais não seriam divulgados. Em seguida, os inscritos receberam um questionário que buscava medir conhecimentos prévios relacionados a cada um dos conceitos do curso. O curso foi dividido em 30 conceitos e para cada um desses conceitos foram selecionadas 5 exercícios com diferentes dificuldades. A partir de uma breve descrição do conteúdo de cada conceito, o inscrito

deveria indicar um número entre 1 e 5 que representava seu conhecimento sobre aquele assunto. Posteriormente, os exercícios sobre aquele conceito eram selecionados de acordo com o grau de conhecimento indicado pelo inscrito. Os exercícios serviram como agente de validação do conhecimento prévio indicado, pois, a partir das respostas aos exercícios, o grau de conhecimento aferido pelo sistema seria atribuído aos dados do inscrito.

Por fim, foi oferecido aos inscritos o questionário ILS (*Index of Learning Style*) (SOLOMON; FELDER, 1999) para capturar o EA baseado no FSLSM – foi utilizada a versão traduzida para o idioma português³. Nos gráficos que seguem, é possível verificar a distribuição dos alunos de acordo com cada uma das dimensões do FSLSM. O gráfico 5.8 apresenta a distribuição dos alunos em relação à dimensão de Participação do FSLSM e mostra que os alunos ficaram bem distribuídos entre os EAs desta dimensão, sendo que a maioria deles não apresentam uma preferência explícita por uma das dimensões.




Figura 5.8: Distribuição dos alunos de acordo com a dimensão Participação do FSLSM.

Os alunos demonstraram uma certa inclinação para o EA Sequencial (5.9), sendo que muitos deles apresentam uma preferência moderada nesse sentido. Ainda, houve uma grande inclinação para o EA Visual (5.10), onde muitos apresentam uma preferência moderada e intensa nesse sentido. Por fim, no EA Sensorial (5.11) muitos apresentam uma preferência moderada e intensa nesse sentido.

³<https://github.com/marcelomachado/FSLSM/blob/master/ILS-Portuguese.pdf>




Figura 5.9: Distribuição dos alunos de acordo com a dimensão Organização do FSLSM.




Figura 5.10: Distribuição dos alunos de acordo com a dimensão Apresentação do FSLSM.

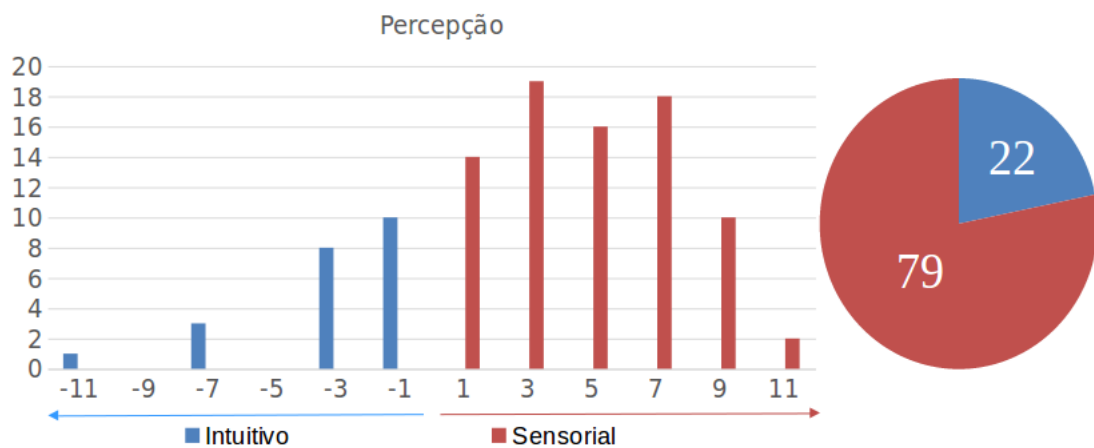


Figura 5.11: Distribuição dos alunos de acordo com a dimensão Percepção do FSLSM.

5.3.2 DEFINIÇÃO DOS GRUPOS DO EXPERIMENTO

Ao final do processo de preenchimento dos questionários iniciais do curso, apenas 88 alunos preencheram todos os questionários completamente. Esses alunos foram divididos em dois grupos. O primeiro grupo – que será chamado de “Grupo 1” – é composto por 27 alunos que receberam materiais a partir de uma seleção feita pelos professores que garantiram ao menos que os conceitos do curso eram cobertos. O segundo grupo – que será chamado de “Grupo 2” – é composto por 61 alunos que receberam a SCA a partir da adaptação proposta por este trabalho.

Para selecionar os integrantes de cada grupo, esses foram selecionados aleatoriamente, mas dentro de algumas regras criadas de forma a garantir a diversidade dentro dos grupos e a mesma proporção dessa diversidade dentro de cada grupo. Primeiramente, foram utilizadas as pontuações médias obtidas a partir do questionário de conhecimento prévio. Em seguida, foi considerado o EA com intuito de ter alunos diversificados em cada um dos grupos, além de ter alunos com perfil parecido em ambos os grupos. O gráfico da Figura 5.12 mostra a distribuição de cada grupo de acordo com a pontuação (1 a 5) que obtiveram no questionário de conhecimento prévio.

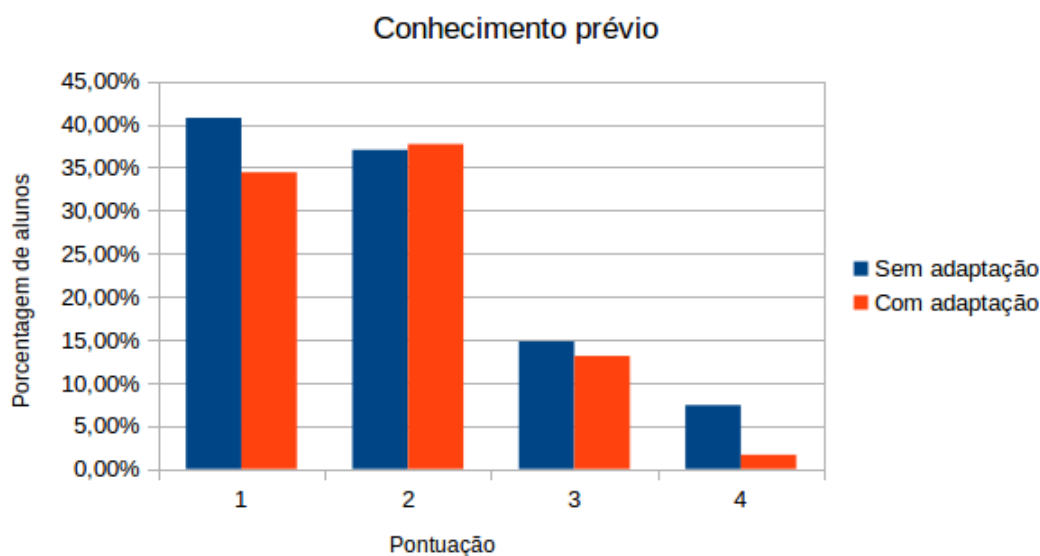


Figura 5.12: Distribuição dos alunos de cada grupo de acordo com a pontuação no questionário de conhecimento prévio.

Além desses dois grupos, ainda foi levado em consideração outro grupo – que será chamado de “Grupo 3” – composto por 40 alunos que não responderam ou responderam

parcialmente os questionários. Esse grupo também não recebeu materiais didáticos a partir da adaptação proposta por este trabalho, afinal, não haviam dados suficientes para tal adaptação. Esse grupo foi considerado para manter um número maior de participantes no experimento, visto que há perdas ao longo do curso.

5.3.3 COLETA DOS DADOS

O curso foi dividido em seis semanas que trataram, respectivamente, dos assuntos História da Computação e dos Computadores, Lógica e Sistemas Numéricos, Fundamentos em Algoritmos, Fundamentos de Banco de Dados e Engenharia de Software, Fundamentos em Sistemas Operacionais e Organização de Computadores e Redes de Computadores. Ao longo de cada semana de curso, os materiais eram disponibilizados aos alunos, os quais tinham cinco dias para estudo e um dia para responder o questionário de avaliação. O questionário de avaliação abrangia questões sobre os conceitos abordados durante a semana e era o mesmo para todos os grupos. Os Grupos 1 e 3 recebiam materiais definidos no começo da disciplina pelo professor, enquanto o Grupo 2 recebia materiais selecionados pelo APP.

Além da pontuação obtida por cada aluno nos questionários, os alunos respondiam uma pesquisa de satisfação em relação aos materiais atribuídos para aquela semana. Essa pesquisa foi composta por 4 questões que poderiam ser respondidas com as opções “discordo completamente”, “discordo”, “não tenho opinião”, “concordo” e “concordo completamente”. As questões foram relacionadas aos objetivos propostos para seleção dos materiais didáticos. Para avaliar o nível de dificuldade foi utilizado o questionamento “Os níveis de dificuldade dos materiais didáticos fornecidos foram apropriados ao meu nível de conhecimento”. Para avaliar o tempo de estudo foi utilizada a questão “O tempo total de estudo dos materiais didáticos fornecidos foram de acordo com meu tempo de disponibilidade para o curso”. Para avaliar se os materiais didáticos cobriam os conceitos do curso foi utilizada a questão “Os materiais didáticos fornecidos me deram total auxílio para que eu pudesse responder o questionário da semana”. Para avaliar o EA, foi utilizada a questão “Os elementos (por exemplo, elementos gráficos, exemplos, exercícios e etc) dos materiais fornecidos foram de acordo com a maneira que costumo aprender mais facilmente”.

Também foram capturadas as informações de desistência de alunos de acordo com cada semana do curso. Para isso, era verificado se o aluno não respondeu ao questionário da

semana.

5.3.4 RESULTADOS E ANÁLISE

Para ser aprovado no curso, os alunos precisavam obter o equivalente a 60% da pontuação total. Assim, espera-se que a maioria dos alunos que recebeu a adaptação sejam pelo menos aprovados no curso, indicando que os materiais didáticos entregues foram suficientes nesse quesito. Porém, afim de verificar a qualidade do entendimento os alunos foram divididos de acordo com conceitos A, B, C, D e E, tal que:

- A – Ótimo – 90% ou mais da pontuação máxima
- B – Muito bom – entre 80% e 90% da pontuação máxima
- C – Bom – entre 70% e 80% da pontuação máxima
- D – Razoável - entre 60% e 70% da pontuação máxima
- E – Insatisfatório - menos de 60% da pontuação máxima

Ao final do curso, 50 alunos responderam todos os 6 questionários disponibilizados e, portanto, esse será o principal conjunto de avaliação. Desses alunos, 14 são do grupo Grupo 1, 32 são do grupo Grupo 2 e 2 são do grupo Grupo 3. Apesar disso, os demais alunos também tiveram chance de aprovação e seus resultados também são apresentados de acordo com cada semana do curso. Os resultados consideraram os grupos de alunos apresentados na Seção 5.3.2 e podem ser vistos nas Figuras 5.13 e 5.14. O grupo complementar foi descartado desta análise por conter apenas 2 alunos.




Figura 5.14: Resultado dos alunos que receberam adaptação.




Figura 5.13: Resultados dos alunos que não receberam adaptação.

Os gráficos indicam que a maioria dos alunos foi aprovada no curso, sendo que no Grupo 2 isso foi ainda mais expressivo. É interessante notar que não apenas a proporção de aprovados do grupo com adaptação foi maior que a do grupo sem adaptação, mas também a qualidade do entendimento, visto que 50% dos alunos obtiveram um conceito de “Muito bom” a “Ótimo”, enquanto no grupo sem adaptação esse valor foi de 29% sem ao menos um aluno ter alcançado notas superiores a 90% da pontuação máxima.

Para verificar os resultados dos alunos de acordo com cada semana do curso, se faz necessário entender a quantidade de alunos que responderam aos questionário (Tabela 5.1).

	Grupo 1	Grupo 2	Grupo 3	Total
Semana 1	24	54	19	97
Semana 2	23	49	12	84
Semana 3	20	46	16	82
Semana 4	17	46	12	75
Semana 5	19	45	15	79
Semana 6	16	42	13	71

Tabela 5.1: Quantidade de alunos que responderam os questionários semanais separados por grupos.

A partir da Tabela 5.2, é possível verificar o desempenho dos alunos de acordo com cada uma das semanas. É possível perceber o mesmo comportamento apresentado pelos 50 alunos citados anteriormente, isto é, em todas as semanas o desempenho da maioria dos alunos que recebeu adaptação foi suficiente para a aprovação relacionada ao conteúdo da semana, além disso, a maioria dos alunos teve conceito “Muito bom” ou “Ótimo” e apresentou melhores resultados que os outros grupos. O Apêndice A apresenta esses

resultados na forma de gráficos.

Semana	Conceito	Grupo 1	Grupo 2	Grupo 3
Semana 1	A	0,00%	16,67%	10,53%
	B	20,83%	9,26%	5,26%
	C	25,00%	18,52%	21,05%
	D	29,17%	27,78%	21,05%
	E	25,00%	27,78%	42,11%
Semana 2	A	4,35%	20,41%	16,67%
	B	17,39%	16,33%	25,00%
	C	17,39%	14,29%	0,00%
	D	13,04%	22,45%	16,67%
Semana 3	E	47,83%	26,53%	41,67%
	A	5,00%	26,09%	5,56%
	B	30,00%	21,74%	27,78%
	C	10,00%	17,39%	22,22%
Semana 4	D	40,00%	19,57%	27,78%
	E	15,00%	15,22%	16,67%
	A	23,53%	32,61%	25,00%
	B	23,53%	23,91%	25,00%
	C	23,53%	17,39%	16,67%
Semana 5	D	17,65%	15,22%	25,00%
	E	11,76%	10,87%	8,33%
	A	21,05%	28,89%	6,67%
	B	21,05%	24,44%	40,00%
	C	26,32%	15,56%	13,33%
Semana 6	D	10,53%	11,11%	0,00%
	E	21,05%	20,00%	40,00%
	A	18,75%	52,38%	31,03%
	B	37,50%	23,81%	24,14%
	C	37,50%	14,29%	37,93%
	D	6,25%	2,38%	6,90%
	E	0,00%	7,14%	0,00%

Tabela 5.2: Resultados dos alunos de cada grupo por semana.

De acordo com a Tabela 5.1 e as quantidades de alunos iniciais em cada grupo, é possível fazer um levantamento de desistência considerando cada semana, isto é, verificar a quantidade de alunos que não responderam aos questionários. A Tabela 5.3 apresenta esses resultados por grupo e demonstra claramente que o Grupo 3 foi o que teve maior índice de desistência. Uma possível justificativa para esse acontecimento é o desinteresse inicialmente apresentado por esses alunos, que não responderam os questionários iniciais do curso. Os alunos do Grupo 2 foram os que apresentaram o menor número de desistências, indicando que a adaptação também pode ter contribuído para um maior fator de motivação. Reforçando esses resultados, vale-se ainda analisar a quantidade de alunos que

responderam todas as avaliações do curso, sendo 51,85% do Grupo 1, 52,46% do Grupo 2 e apenas 5% do Grupo 3.

	Grupo 1	Grupo 2	Grupo 3
Semana 1	11,11%	11,47%	52,50%
Semana 2	14,81%	19,67%	70,00%
Semana 3	25,92%	24,59%	60,00%
Semana 4	37,03%	24,59%	70,00%
Semana 5	29,62%	26,22%	62,50%
Semana 6	40,74%	31,14%	67,50%

Tabela 5.3: Desistência dos alunos de cada grupo por semana.

Às alternativas do questionário de satisfação, foram associados valores inteiros que variam de -2 a 2, tal que a satisfação aumenta do menor valor para o maior. Afim de uma comparação justa, foram considerados os alunos que responderam todos os questionários, resultando em um montante de 46 alunos. Ao somar os valores respondidos de acordo com cada um dos quesitos avaliados, tem-se um valor que indicará a intensidade de satisfação média de cada quesito. Assim, são consideradas as Figuras 5.15, 5.16 e 5.17. De maneira geral, mesmo nos grupos que não receberam adaptação, a satisfação foi positiva, sendo menos intensa no Grupo 3. Ainda, o quesito mais insatisfatório foi o dos conceitos, podendo esse estar relacionado ao rendimento dos alunos que já sabiam suas notas antes de responder aos questionários de satisfação. Com relação ao Grupo 2, é válido reparar uma grande faixa de satisfação em todos os quesitos por volta da pontuação 5, sendo o tempo de aprendizagem o quesito mais satisfatório.

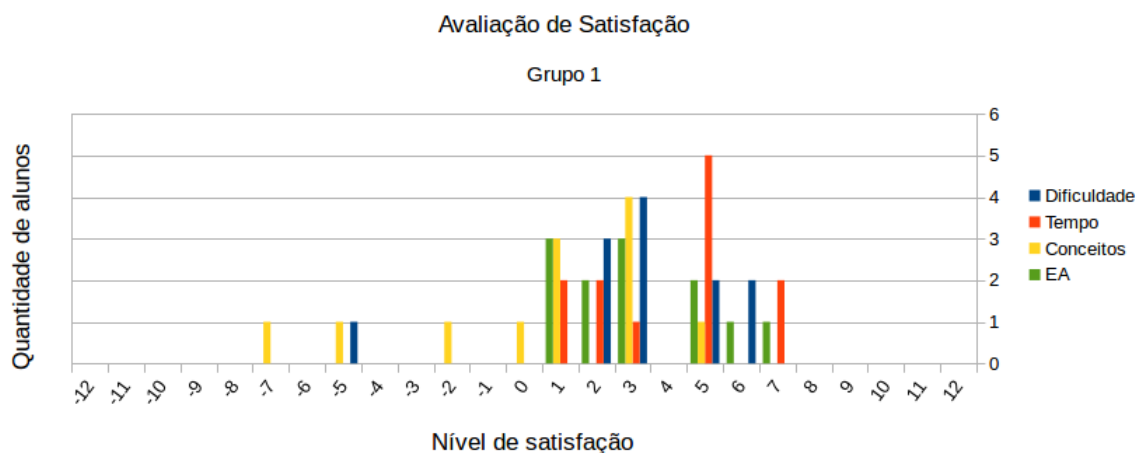


Figura 5.15: Resultados dos alunos que não receberam adaptação.




Figura 5.16: Resultados dos alunos que não receberam adaptação.




Figura 5.17: Resultados dos alunos que não receberam adaptação.

6 CONCLUSÕES

O desenvolvimento tecnológico dos últimos anos permitiu que a EaD se tornasse uma realidade que cada vez mais atrai adeptos. Para efetiva utilização dos sistemas de *e-Learning*, ainda se faz necessário tratar diversos desafios que norteiam a área. Esses desafios estão associados, principalmente, à forma que o conteúdo didático é entregue ao aluno, pois, de maneira geral não considera suas necessidades e características. Nesse contexto, o *e-Learning* adaptativo busca, a partir de vários níveis de adaptabilidade, oferecer aos alunos uma experiência pessoal e única, com o objetivo final de maximizar o desempenho de aprendizagem. Um dos níveis considerados mais interessantes nesse âmbito considera a entrega de uma sequência de materiais didáticos – Sequência Curricular Adaptativa (SCA) – que atenda a diversos parâmetros dos alunos.

Encontrar a melhor SCA, a partir de um repositório contendo materiais distintos em diversos âmbitos, foi considerado como o problema a ser tratado prezando, principalmente, as informações fornecidas pelos alunos. Uma vez que esse é considerado um problema de otimização combinatória da classe NP-Difícil, foi utilizada uma metaheurística evolucionista. A metaheurística utilizada foi o Algoritmo Presa-Predador, a qual ainda não havia sido explorada pela literatura de SCA.

Buscando considerar os diversos parâmetros dos alunos e da base de conhecimento a função objetivo utilizada pelo APP foi constituída pela agregação de cinco objetivos, são eles: (1) entregar uma SCA cujo os conceitos cobertos pelos materiais didáticos estejam de acordo com os objetivos de aprendizagem dos alunos, (2) entregar uma SCA cuja dificuldade dos materiais didáticos considere o conhecimento prévio do aluno, (3) entregar uma SCA que esteja de acordo com o tempo de disponibilidade do aluno (4) entregar uma SCA que esteja balanceada de acordo com os conceitos entregues pelos materiais didáticos e (5) entregar uma SCA que considere características intrínsecas do aluno. Para esse último objetivo foi utilizado o EA a partir FLSM e assim foi criada uma função que considera a intensidade de preferência do aluno por um determinado EA desse modelo.

Mostrar que era possível utilizar o APP para o problema de encontrar a melhor SCA que considerasse, sobretudo os diversos parâmetros intrínsecos e extrínsecos do aluno é a principal hipótese deste trabalho. De forma a validar essa hipótese foi conduzido um

experimento que consistiu na oferta de um curso de Introdução à Computação a uma turma real composta inicialmente por 128 alunos. Foi necessária a criação de uma base de dados a ser utilizada por esse experimento, pois não foram encontradas bases de dados estruturadas para utilização, visto que a maioria dos experimentos nesta área são feitos a partir de dados sintéticos ou de bases criadas com características específicas a pesquisa que, além disso, não são disponibilizadas. Os inscritos do curso foram avaliados a partir de questionários de conhecimento prévio e de captura do EA a partir do ILS. Com os resultados desses questionários os alunos foram divididos em 3 grupos, chamados de Grupo 1, Grupo 2 e Grupo 3, onde o Grupo 1 e 3 receberam materiais escolhidos pelo professor do curso e o Grupo 2 receberam os materiais a partir da adaptação proposta feita a partir do APP – o Grupo 3 é composto por alunos que não responderam ou responderam parcialmente os questionários iniciais e por isso foram separados.

No decorrer do curso, os alunos foram avaliados por questionários que era comum a todos os grupos. A partir da análise dessas avaliações, foi possível perceber que os alunos que receberam adaptação obtiveram resultados positivos no quesito aprovação, seja na avaliação final (com 97% de aprovação) ou na avaliação de acordo com cada semana do curso, sendo assim comprovada a principal hipótese desta pesquisa. Além disso, a partir da divisão das notas dos alunos em conceitos A, B, C, D e E notou-se a qualidade do entendimento desses alunos com relação aos conceitos do curso, haja vista que a maioria dos alunos obteve conceitos “Muito bom” ou “Ótimo”. Foi possível perceber ainda que o Grupo 2 foi o que teve a menor taxa de desistência, indicando que a adaptação a partir da SCA pode atuar como agente de motivação à permanência de cursos da modalidade de EaD. O Grupo 3 foi o que apresentou a maior taxa de desistência sendo esse um resultado esperado já que inicialmente os alunos apresentaram um perfil de desinteresse no momento em que não responderam aos questionários iniciais.

6.1 CONTRIBUIÇÕES

A partir dos resultados apresentados, que confirmaram a hipótese deste trabalho, a principal contribuição é a criação de uma solução para a geração automática de uma SCA que considere as características do aluno, utilizando uma modelagem baseada nas ideias do APP. Essa contribuição está diretamente associada à definição de objetivos que tratam com maior detalhes as informações extrínsecas e intrínsecas dos alunos, tais como, o co-

nhecimento prévio, o tempo de disponibilidade, os objetivos de aprendizagem e o EA do aluno. Demonstrar que a adaptação interfere positivamente no processo de aprendizagem também é uma contribuição positiva, afinal os alunos que receberam a adaptação, de maneira geral, foram os que apresentaram os melhores resultados relacionados às notas nas avaliações e a permanência no curso.

Para que o experimento com uma turma real de alunos fosse possível, foi necessária a criação de uma base real de materiais didáticos a partir de um padrão de OAs (IEEE-LOM). A disponibilização dessa base permitirá que outros trabalhos a utilizem para desenvolvimento desta linha de pesquisa, facilitando comparações entre as soluções propostas.

Por se tratar de uma metaheurística relativamente nova, o APP ainda foi pouco utilizado na literatura. Portanto, Tilahun & Ong (2015) indicam como um dos seus trabalhos futuros a utilização do APP em problemas reais para confirmar a validade da solução. Embora o APP não tenha sido comparado com outras metaheurísticas de acordo com a SCA, esse se mostrou passível de utilização em um caso real avaliado a partir do curso proposto. Além disso, este trabalho propôs uma modelagem binária para a solução que pode ser estendida para problemas semelhantes.

6.2 TRABALHOS FUTUROS

Trabalhar com a geração da SCA é apenas uma parte de um grande processo que busca melhorar a qualidade dos cursos ofertados a partir de sistemas de *e-Learning*. Se tratando particularmente da SCA, esta pesquisa pretende ser continuada de forma a investigar e incluir novos critérios no processo de otimização, tais como, a qualidade de conexão e informações do dispositivo de acesso. Dessa forma, a representação do material pode ser levada em consideração. Por exemplo, dada uma conexão de acesso considerada lenta, talvez a entrega de uma imagem fosse mais interessante do que a de um vídeo. Ainda, se o aluno está acessando a plataforma a partir de um dispositivo móvel, é possível acessar informações de sensores que indicariam, por exemplo, se o aluno está em um veículo, então a entrega de um arquivo de áudio talvez faça mais sentido do que a entrega de um arquivo de texto.

Se tratando da metaheurística utilizada, pretende-se fazer um estudo mais completo dos parâmetros utilizados, além de tentar melhorar sua convergência e eficiência a partir

da variação da solução, a qual pode considerar mais predadores, mais presas que buscam primariamente a intensificação, limitar a quantidade de presas que deveriam ser seguidas, além de técnicas de inteligência artificial que são empregadas em outras metaheurísticas, por exemplo, o *path-relinking*. Ainda nesse contexto, é pretendida a comparação de eficiência com relação a outras metaheurísticas que foram utilizadas para o mesmo problema, por exemplo o AG e OEP.

Devido aos últimos estudos (KIRSCHNER, 2017; HUSMANN; O'LOUGHLIN, 2018) relacionados a não utilização do EA na seleção de materiais didáticos é necessário um estudo mais aprofundado de forma a investigar se o EA deve ser completamente descartado ou se ainda há casos que eles sejam passíveis de utilização em *e-Learning* adaptativo. Os mesmos estudos apontam como positiva a utilização de habilidades cognitivas e, portanto, em trabalhos futuros esse pode ser um critério considerado para geração da SCA.

REFERÊNCIAS

- ACAMPORA, G.; GAETA, M.; LOIA, V. Hierarchical optimization of personalized experiences for e-learning systems through evolutionary models. **Neural Computing and Applications**, Springer, v. 20, n. 5, p. 641–657, 2011.
- AGARWAL, S.; GOYAL, M.; KUMAR, A.; RAJALAKSHMI, K. Intuitionistic fuzzy ant colony optimization for course sequencing in e-learning. In: IEEE. **Contemporary Computing (IC3), 2016 Ninth International Conference on**, 2016. p. 1–6.
- AL-AZAWEI, A.; BADI, A. State of the art of learning styles-based adaptive educational hypermedia systems (ls-baehss). **International Journal of Computer Science & Information Technology**, Academy & Industry Research Collaboration Center (AIRCC), v. 6, n. 3, p. 1, 2014.
- AL-MUHAIDEB, S.; MENAI, M. E. B. Evolutionary computation approaches to the curriculum sequencing problem. **Natural Computing**, Springer, v. 10, n. 2, p. 891–920, 2011.
- BHASKAR, M.; DAS, M. M.; CHITHRALEKHA, T.; SIVASATYA, S. Genetic algorithm based adaptive learning scheme generation for context aware e-learning. **International Journal on Computer Science and Engineering**, v. 2, n. 4, p. 1271–1279, 2010.
- BRASIL, A. C. E. Relatório analítico da aprendizagem a distância no brasil 2016. 2016. Disponível em: <http://www.abed.org.br/site/pt/midiateca/censo_ead/1449/2017/09/censoead.br_2016/2017>.
- BRUSILOVSKY, P. Adaptive and intelligent technologies for web-based education. **International Journal of Artificial Intelligence in Education (IJAIED)**, v. 13, n. 4, p. 159–172, 2003.
- CHAKRAVERTY, S.; HANS, S.; MITTAL, V. Aco-driven personalized e-learning with perspectives and learning aims. In: **Proceedings of the International Conference on E-learning, E-business, Enterprise Information Systems, & E-government**, 2012. p. 359–365.

- CHEN, C.-M. Intelligent web-based learning system with personalized learning path guidance. **Computers & Education**, Elsevier, v. 51, n. 2, p. 787–814, 2008.
- CHU, C.-P.; CHANG, Y.-C.; TSAI, C.-C. Pc2pso: personalized e-course composition based on particle swarm optimization. **Applied Intelligence**, Springer, v. 34, n. 1, p. 141–154, 2009.
- COFFIELD, F.; MOSELEY, D.; HALL, E.; ECCLESTONE, K. et al. Learning styles and pedagogy in post-16 learning: A systematic and critical review. **Learning and Skills Research Centre London**, 2004.
- CONKLIN, J.; ANDERSON, L. W.; KRATHWOHL, D.; AIRASIAN, P.; CRUIKSHANK, K. A.; MAYER, R. E.; PINTRICH, P.; RATHS, J.; WITTROCK, M. C. A taxonomy for learning, teaching, and assessing: A revision of bloom's taxonomy of educational objectives complete edition. **Educational Horizons**, v. 83, n. 3, p. 153–159, 2005.
- DEB, K. Multi-objective optimization using evolutionary algorithms. **John Wiley & Sons**, v. 16, 2001.
- DEBBAH, A.; ALI, Y. M. B. Solving the curriculum sequencing problem with dna computing approach. **International Journal of Distance Education Technologies (IJ-DET)**, IGI Global, v. 12, n. 4, p. 1–18, 2014.
- DHARSHINI, A. P.; CHANDRAKUMARMANGALAM, S.; ARTHI, G. Ant colony optimization for competency based learning objects sequencing in e-learning. **Applied Mathematics and Computation**, Elsevier, v. 263, p. 332–341, 2015.
- DHEEBAN, S.; DEEPAK, V.; DHAMODHARAN, L. Improved personalized e-course composition approach using modified particle swarm optimization with inertia-coefficient. **learning**, Citeseer, v. 1, n. 6, 2010.
- DORIGO, M.; BLUM, C. Ant colony optimization theory: A survey. **Theoretical computer science**, Elsevier, v. 344, n. 2-3, p. 243–278, 2005.
- DURAND, G.; BELACEL, N.; LAPLANTE, F. Graph theory based model for learning path recommendation. **Information Sciences**, Elsevier, v. 251, p. 10–21, 2013.

- DWIVEDI, P.; BHARADWAJ, K. K. Effective resource recommendations for e-learning: A collaborative filtering framework based on experience and trust. In: **Computational Intelligence and Information Technology**, 2011. p. 166–170.
- DWIVEDI, P.; BHARADWAJ, K. K. Effective trust-aware e-learning recommender system based on learning styles and knowledge levels. **Journal of Educational Technology & Society**, JSTOR, v. 16, n. 4, p. 201, 2013.
- DWIVEDI, P.; KANT, V.; BHARADWAJ, K. K. Learning path recommendation based on modified variable length genetic algorithm. **Education and Information Technologies**, Springer, p. 1–18, 2017.
- ERDT, M.; FERNANDEZ, A.; RENSING, C. Evaluating recommender systems for technology enhanced learning: a quantitative survey. **IEEE Transactions on Learning Technologies**, IEEE, v. 8, n. 4, p. 326–344, 2015.
- FELDER, R. M.; BRENT, R. Understanding student differences. **Journal of engineering education**, Wiley Online Library, v. 94, n. 1, p. 57–72, 2005.
- FELDER, R. M.; SILVERMAN, L. K. et al. Learning and teaching styles in engineering education. **Engineering education**, v. 78, n. 7, p. 674–681, 1988.
- FELDER, R. M.; SPURLIN, J. Applications, reliability and validity of the index of learning styles. **International journal of engineering education**, v. 21, n. 1, p. 103–112, 2005.
- GHAUTH, K. I.; ABDULLAH, N. A. Learning materials recommendation using good learners' ratings and content-based filtering. **Educational technology research and development**, Springer, v. 58, n. 6, p. 711–727, 2010.
- GRAF, S.; VIOLA, S. R.; LEO, T.; KINSHUK. In-depth analysis of the felder-silverman learning style dimensions. **Journal of Research on Technology in Education**, Taylor & Francis, v. 40, n. 1, p. 79–93, 2007.
- GUO, Q.; ZHANG, M. Implement web learning environment based on data mining. **Knowledge-Based Systems**, Elsevier, v. 22, n. 6, p. 439–442, 2009.

- GUTIÉRREZ, S.; PARDO, B. Sequencing in web-based education: approaches, standards and future trends. In: **Evolution of Teaching and Learning Paradigms in Intelligent Environment**, 2007. p. 83–117.
- HAFIDI, M.; BENSEBAA, T. Architecture for an adaptive and intelligent tutoring system that considers the learner's multiple intelligences. **International Journal of Distance Education Technologies (IJDET)**, IGI Global, v. 13, n. 1, p. 1–21, 2015.
- HAUGER, D.; KÖCK, M. State of the art of adaptivity in e-learning platforms. In: **LWA**, 2007. p. 355–360.
- HAYNES, T.; SEN, S. Evolving behavioral strategies in predators and prey. In: SPRINGER. **International Joint Conference on Artificial Intelligence**, 1995. p. 113–126.
- HNIDA, M.; IDRISSE, M. K.; BENNANI, S. Adaptive teaching learning sequence based on instructional design and evolutionary computation. In: IEEE. **Information Technology Based Higher Education and Training (ITHET), 2016 15th International Conference on**, 2016. p. 1–6.
- HUANG, M.-J.; HUANG, H.-S.; CHEN, M.-Y. Constructing a personalized e-learning system based on genetic algorithm and case-based reasoning approach. **Expert Systems with Applications**, Elsevier, v. 33, n. 3, p. 551–564, 2007.
- HUSMANN, P. R.; O'LOUGHLIN, V. D. Another nail in the coffin for learning styles? disparities among undergraduate anatomy students' study strategies, class performance, and reported varied learning styles. **Anatomical sciences education**, Wiley Online Library, 2018.
- JEBARI, K.; MOUJAHID, A. E.; BOUROUMI, A.; ETTOUHAMI, A. Genetic algorithms for online remedial education based on competency approach. In: IEEE. **Multi-media Computing and Systems (ICMCS), 2011 International Conference on**, 2011. p. 1–6.
- KAMEYAMA, K. Particle swarm optimization-a survey. **IEICE transactions on information and systems**, The Institute of Electronics, Information and Communication Engineers, v. 92, n. 7, p. 1354–1361, 2009.

- KAPLAN, A. M.; HAENLEIN, M. Higher education and the digital revolution: About moocs, spocs, social media, and the cookie monster. **Business Horizons**, Elsevier, v. 59, n. 4, p. 441–450, 2016.
- KARDAN, A. A.; AZIZ, M.; SHAHPASAND, M. Adaptive systems: a content analysis on technical side for e-learning environments. **Artificial Intelligence Review**, Springer, v. 44, n. 3, p. 365–391, 2015.
- KARDAN, A. A.; EBRAHIM, M. A.; IMANI, M. B. A new personalized learning path generation method: Aco-map. **Indian Journal of Scientific Research**, Global Academic Society, v. 5, n. 1, p. 17, 2014.
- KARPOVA, M.; SHMELEV, V.; DUKHANOV, A. An automation of the course design with use of learning objects with evaluation based on the bloom taxonomy. In: IEEE. **Application of Information and Communication Technologies (AICT), 2015 9th International Conference on**, 2015. p. 138–142.
- KHAMPARIA, A.; PANDEY, B. Knowledge and intelligent computing methods in e-learning. **International Journal of Technology Enhanced Learning**, Inderscience Publishers (IEL), v. 7, n. 3, p. 221–242, 2015.
- KIRSCHNER, P. A. Stop propagating the learning styles myth. **Computers & Education**, Elsevier, v. 106, p. 166–171, 2017.
- KOBSA, A. Generic user modeling systems. **User modeling and user-adapted interaction**, Springer, v. 11, n. 1-2, p. 49–63, 2001.
- LAUMANN, M.; RUDOLPH, G.; SCHWEFEL, H.-P. A spatial predator-prey approach to multi-objective optimization: A preliminary study. In: SPRINGER. **International Conference on Parallel Problem Solving from Nature**, 1998. p. 241–249.
- LI, J.-W.; CHANG, Y.-C.; CHU, C.-P.; TSAI, C.-C. A self-adjusting e-course generation process for personalized learning. **Expert Systems with Applications**, Elsevier, v. 39, n. 3, p. 3223–3232, 2012.
- LOPES, R. da S.; FERNANDES, M. A. Adaptive instructional planning using workflow and genetic algorithms. In: IEEE. **Computer and Information Science, 2009. ICIS 2009. Eighth IEEE/ACIS International Conference on**, 2009. p. 87–92.

- MACHADO, M.; SOUZA, J.; BARRÉRE, E. Geração de sequências curriculares adaptativas baseada em computação evolucionária: Estado da arte e tendências. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**, 2017. v. 28, n. 1, p. 1137.
- MANOCHEHR, N.-N. et al. The influence of learning styles on learners in e-learning environments: An empirical study. **Computers in Higher Education Economics Review**, Economics Network, University of Bristol, v. 18, n. 1, p. 10–14, 2006.
- MARCOS, L. de; MARTINEZ, J.-J.; GUTIÉRREZ, J.-A.; BARCHINO, R.; HILERA, J.-R.; OTON, S.; GUTIÉRREZ, J.-M. Genetic algorithms for courseware engineering. **International Journal of Innovative Computing, Information and Control**, v. 7, n. 7, p. 1–27, 2011.
- MASSA, L. J.; MAYER, R. E. Testing the ati hypothesis: Should multimedia instruction accommodate verbalizer-visualizer cognitive style? **Learning and Individual Differences**, Elsevier, v. 16, n. 4, p. 321–335, 2006.
- MÉNDEZ, N. D. D.; MORALES, V. T.; VICARI, R. M. Learning object metadata mapping with learning styles as a strategy for improving usability of educational resource repositories. **IEEE Revista Iberoamericana de Tecnologías del Aprendizaje**, IEEE, v. 11, n. 2, p. 101–106, 2016.
- MONTIEL, O.; CASTILLO, O.; MELIN, P.; DÍAZ, A. R.; SEPÚLVEDA, R. Human evolutionary model: A new approach to optimization. **Information Sciences**, Elsevier, v. 177, n. 10, p. 2075–2098, 2007.
- MUHAMMAD, A.; ZHOU, Q.; BEYDOUN, G.; XU, D.; SHEN, J. Learning path adaptation in online learning systems. In: IEEE. **Computer Supported Cooperative Work in Design (CSCWD), 2016 IEEE 20th International Conference on**, 2016. p. 421–426.
- PIRES, J. M.; COTA, M. P. A new learning cognitive architecture using a statistical function and genetic algorithms: An intelligent new e-learning model. In: IEEE. **e-Learning (econf), 2015 Fifth International Conference on**, 2015. p. 1–8.

- PREMLATHA, K.; GEETHA, T. Learning content design and learner adaptation for adaptive e-learning environment: a survey. **Artificial Intelligence Review**, Springer, v. 44, n. 4, p. 443–465, 2015.
- PUSHPA, M. Aco in e-learning: Towards an adaptive learning path. **International Journal on Computer Science and Engineering**, Engg Journals Publications, v. 4, n. 3, p. 458, 2012.
- RIAD, B.; ALI, S.; MOURAD, H.; HAMID, S. An adaptive learning based on ant colony and collaborative filtering. In: **Proceedings of the World Congress on Engineering**, 2012. v. 2, p. 851–855.
- SANTOS, H. dos; CECHINEL, C.; ARAÚJO, R.; BRAUNER, D. Recomendação de objetos de aprendizagem utilizando filtragem colaborativa: Uma comparação entre abordagens de pré-processamento por meio de clusterização. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**, 2015. v. 26, n. 1, p. 1127.
- SCOTT, E.; RODRÍGUEZ, G.; SORIA, Á.; CAMPO, M. Are learning styles useful indicators to discover how students use scrum for the first time? **Computers in Human Behavior**, Elsevier, v. 36, p. 56–64, 2014.
- SEKI, K.; MATSUI, T.; OKAMOTO, T. An adaptive sequencing method of the learning objects for the e-learning environment. **Electronics and Communications in Japan (Part III: Fundamental Electronic Science)**, Wiley Online Library, v. 88, n. 3, p. 54–71, 2005.
- SHARMA, R.; BANATI, H.; BEDI, P. Adaptive content sequencing for e-learning courses using ant colony optimization. In: SPRINGER. **Proceedings of the International Conference on Soft Computing for Problem Solving (SocProS 2011) December 20-22, 2011**, 2012. p. 579–590.
- SHMELEV, V.; KARPOVA, M.; DUKHANOV, A. An approach of learning path sequencing based on revised bloom's taxonomy and domain ontologies with the use of genetic algorithms. **Procedia Computer Science**, Elsevier, v. 66, p. 711–719, 2015.

- SHUTE, V.; TOWLE, B. Adaptive e-learning. **Educational psychologist**, Taylor & Francis, v. 38, n. 2, p. 105–114, 2003.
- SOLOMON, B. A.; FELDER, R. M. Index of learning styles. **Raleigh, NC: North Carolina State University. Available online**, 1999.
- TALBI, E.-G. **Metaheuristics: from design to implementation**, 2009.
- TAN, X.-h.; SHEN, R.-m.; WANG, Y. Personalized course generation and evolution based on genetic algorithms. **Journal of Zhejiang University SCIENCE C**, Springer, v. 13, n. 12, p. 909–917, 2012.
- TILAHUN, S. L.; ONG, H. C. Prey-predator algorithm: A new metaheuristic algorithm for optimization problems. **International Journal of Information Technology & Decision Making**, World Scientific, v. 14, n. 06, p. 1331–1352, 2015.
- VALASKI, J.; MALUCELLI, A.; REINEHR, S. Revisão dos modelos de estilos de aprendizagem aplicados à adaptação e personalização dos materiais de aprendizagem. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**, 2011. v. 1, n. 1.
- VAZQUEZ, J. M. M.; RAMIREZ, J. A. O.; GONZALEZ-ABRIL, L.; MORENTE, F. V. Designing adaptive learning itineraries using features modelling and swarm intelligence. **Neural Computing and Applications**, Springer, v. 20, n. 5, p. 623–639, 2011.
- VIOLA, S. R.; GRAF, S.; LEO, T. et al. Analysis of felder-silverman index of learning styles by a data-driven statistical approach. In: **IEEE. Multimedia, 2006. ISM'06. Eighth IEEE International Symposium on**, 2006. p. 959–964.
- VOSS, G. B.; NUNES, F. B.; HERPICH, F.; MEDINA, R. D. Ambientes virtuais de aprendizagem e ambientes imersivos: um estudo de caso utilizando tecnologias de computação móvel. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**, 2013. v. 24, n. 1, p. 12.
- WAN, S.; LYU, C. Adaptive course generation based on evolutionary algorithm. In: **IEEE. Information Science and Technology (ICIST), 2014 4th IEEE International Conference on**, 2014. p. 168–171.

- WANG, F.-H. Personalized recommendation for web-based learning based on ant colony optimization with segmented-goal and meta-control strategies. In: IEEE. **Fuzzy Systems (FUZZ), 2011 IEEE International Conference on**, 2011. p. 2054–2059.
- WANG, S.-L.; WU, C.-Y. Application of context-aware and personalized recommendation to implement an adaptive ubiquitous learning system. **Expert Systems with applications**, Elsevier, v. 38, n. 9, p. 10831–10838, 2011.
- WANG, T.-I.; WANG, K.-T.; HUANG, Y.-M. Using a style-based ant colony system for adaptive learning. **Expert Systems with applications**, Elsevier, v. 34, n. 4, p. 2449–2464, 2008.
- WILEY, D. A. **Learning object design and sequencing theory**. Tese (Doutorado) — Brigham Young University, 2000.
- WONG, L.-H.; LOOI, C.-K. A survey of optimized learning pathway planning and assessment paper generation with swarm intelligence. **Intelligent Tutoring Systems in E-learning Environments: Design, Implementation and Evaluation, Hershey: IGI Global**, p. 285–302, 2010.
- XIE, H.; ZOU, D.; WANG, F. L.; WONG, T.-L.; RAO, Y.; WANG, S. H. Discover learning path for group users: A profile-based approach. **Neurocomputing**, Elsevier, v. 254, p. 59–70, 2017.
- YANG, X.-S.; PRESS, L. Nature-inspired metaheuristic algorithms second edition. Luni-ver Press United Kingdom, 2010.
- ZAINA, L.; BRESSAN, G.; CARDIERI, M.; JÚNIOR, J. R. e-lors: Uma abordagem para recomendacao de objetos de aprendizagem. **Revista Brasileira de Informática na Educação**, v. 20, n. 1, p. 04, 2012.
- ZAINA, L. A.; BRESSAN, G. Classification of learning profile based on categories of student preferences. In: IEEE. **Frontiers in Education Conference, 2008. FIE 2008. 38th Annual**, 2008. p. F4E–1.

Apêndice A - GRÁFICOS DE RESULTADOS POR SEMANA

Este capítulo de apêndice apresenta os gráficos de desempenho dos alunos de acordo com as avaliações entregues em cada uma das semanas do curso de Introdução à Computação. A partir dos gráficos de barra, é possível notar a distribuição de notas de cada grupo de alunos. Os gráficos de pizza demonstram os alunos de cada um dos grupos de acordo com os conceitos A, B, C, D e E. De forma geral, os alunos do Grupo 2 (com adaptação) apresentam os melhores resultados.




Figura A.1: Resultados dos alunos relacionado a Fundamentos de Sistemas Operacionais e Organização de Computadores.




Figura A.2: Resultados dos alunos relacionado a História da Computação e dos Computadores.




Figura A.3: Resultados dos alunos relacionado a Redes de Computadores.

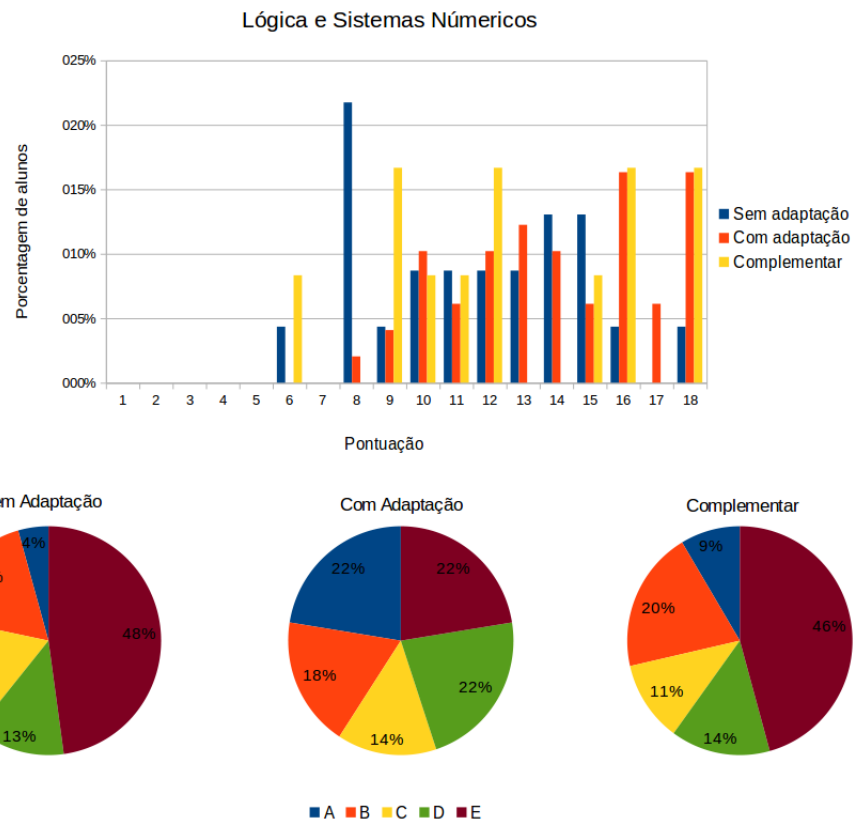


Figura A.4: Resultados dos alunos relacionado a Lógica e Sistemas Numéricos.

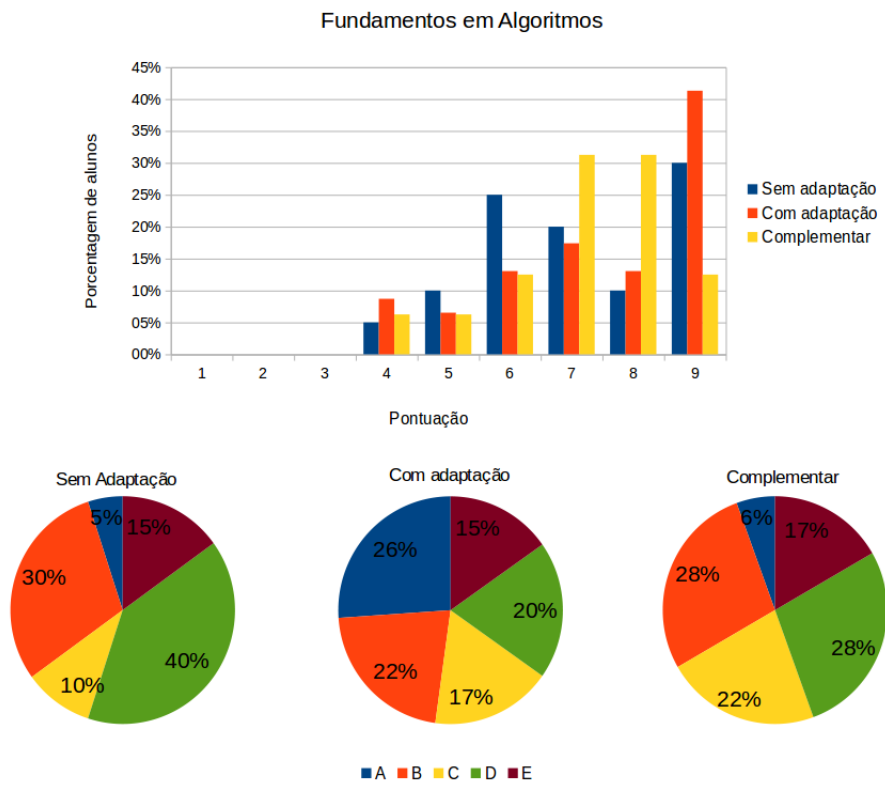


Figura A.5: Resultados dos alunos relacionado a Fundamentos em Algoritmos.

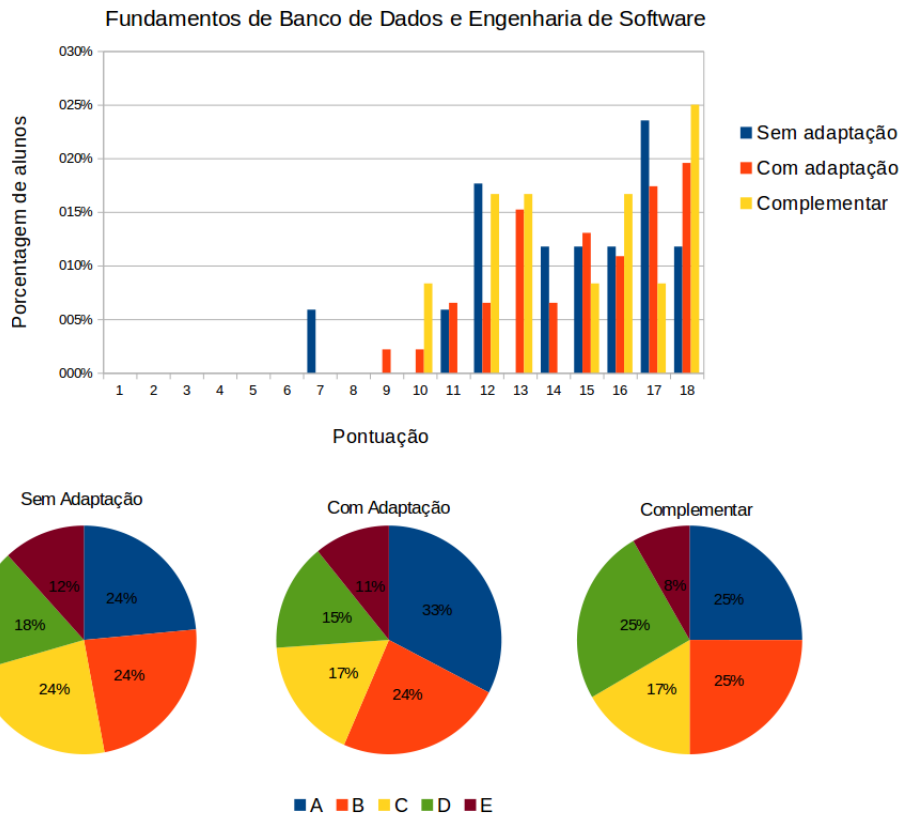


Figura A.6: Resultados dos alunos relacionado a Fundamentos de Banco de Dados e Engenharia de Software.