

Uma abordagem Multiobjetivo para a Recomendação de Objetos de Aprendizagem no contexto Educacional

Title: A Multi-objective approach for Learning Objects Recommendation in the Educational context

Ramon Rocha Leite
Universidade Federal dos
Vales do Jequitinhonha e Mucuri
ramon.leite@ufvjm.edu.br

Alessandro Vivas Andrade
Universidade Federal dos
Vales do Jequitinhonha e Mucuri
alessandro.vivas@gmail.com

Fabiano Azevedo Dorça
Universidade Federal de Uberlândia
fabianodor@ufu.br

Cristiano Grijó Pitangui
Universidade Federal de São João del-Rei
pitangui.cristiano@ufsj.edu.br

Luciana Pereira de Assis
Universidade Federal dos
Vales do Jequitinhonha e Mucuri
lpassis@ufvjm.edu.br

Resumo

Existem grandes repositórios de conteúdos na Internet que podem ser utilizados como fonte de recursos para o e-learning. Para facilitar a utilização desses conteúdos, eles são organizados como Objetos de Aprendizagem (OAs), que além do conteúdo propriamente dito, possuem vários metadados que os descrevem. Devido ao grande volume de materiais disponíveis, torna-se difícil escolher aqueles OAs que melhor atendam às necessidades de cada indivíduo. Para se sugerir os OAs mais adequados, utilizam-se os Sistemas de Recomendação de OAs, responsáveis por encontrar e recomendar os itens mais úteis aos estudantes. Neste contexto, o presente trabalho propõe uma abordagem de otimização multiobjetivo do problema de recomendação de OAs. Nesse problema, tem-se um conjunto de conceitos a serem ensinados, de acordo com um Design Instrucional, um repositório de OAs, no qual cada OA aborda um ou mais conceitos, além de dependências pedagógicas que obrigam determinados conceitos a serem apresentados previamente para compreensão de outros. No problema proposto, não se buscam soluções que necessariamente cubram todos os conceitos estabelecidos. Na verdade, buscam-se por soluções que cumpram dois objetivos distintos, a saber: i) menor custo, dado pela soma do custo de cada OA presente na solução; ii) maior número de conceitos cobertos, respeitadas as dependências pedagógicas estabelecidas. Para resolução do problema, utilizou-se o NSGA-II, um Algoritmo Genético multiobjetivo implementado no framework MOEA. As instâncias do problema foram geradas artificialmente, simulando repositórios de 1000 OAs, cursos com 200 conceitos, com até 20 dependências. Os resultados obtidos abrangeram conjuntos de diferentes configurações de soluções, com números distintos de conceitos cobertos e custos das soluções, o que traz maiores possibilidades para que os conteúdos entregues estejam de acordo com os objetivos, necessidades e realidade dos alunos.

Palavras-chave: Objetos de Aprendizagem; Otimização Multiobjetivo; Sistemas de Recomendação; Projeto Instrucional.

Abstract

Currently, one may find large repositories on the Internet that can be used as a source of resources for e-learning. In order to facilitate the use of these contents, they are organized as Learning Objects (LOs), which, in addition to the

content itself, they hold several metadata to describe them. Due to the large volume of materials available, it becomes difficult to choose those LOs that best meet the needs of each individual. To suggest the most suitable LOs, we rely on Recommendation Systems, that are responsible to find and recommend the most useful items to students. In this context, the present work proposes a multiobjective optimization approach for the LOs recommendation problem. In this problem, there is a set of concepts to be taught, according to an Instructional Design, a repository of LOs, in which each LO addresses one or more concepts, and also pedagogical dependencies, that enforce certain concepts to be presented in advance to others. In this problem, we do not seek for solutions that necessarily cover all established concepts. In fact, we aim to obtain solutions that fulfill two distinct objectives, namely: i) lower cost, given by the sum of the cost of each LO present in the solution; ii) greater number of concepts covered, respecting the established pedagogical dependencies. To solve the problem, we used the NSGA-II, a multiobjective Genetic Algorithm implemented in the MOEA framework. The problem instances were artificially generated, simulating repositories of 1000 LOs, courses with 200 concepts, with up to 20 dependencies. The results obtained covered sets of different configurations of solutions, with different numbers of concepts covered and costs of the solutions, which brings greater possibilities to deliver content in accordance with the objectives, needs and reality of the students.

Keywords: *Learning Objects; Multi-objective Optimization; Recommender Systems; Instructional Design.*

1 Introdução

Os cursos têm demandado cada vez mais conteúdos (aqui também chamados de materiais) digitais educacionais, seja pelo crescimento do Ensino a Distância, ou mesmo pela utilização cada vez maior das ferramentas de Tecnologia da Informação e Comunicação (TICs) nos cursos presenciais. Segundo o Censo Escolar da Educação Superior (INEP, 2022, p.17), o número de ingressantes em cursos de graduação a distância no Brasil tem crescido, enquanto nos cursos presenciais houve ligeira queda desde 2015. O total de ingressantes nos cursos de graduação a distância representou 43,8% em 2019. Tal índice era de 17,4% em 2010.

Além do crescimento dos cursos não-presenciais, mudanças têm ocorrido em relação ao tipo de material utilizado nos mesmos. O Relatório da Associação Brasileira de Educação a Distância de 2018 (ABED, 2019) mostrou que, nos cursos a distância e semipresenciais, os livros impressos têm tido sua utilização reduzida, dando lugar a novos recursos educacionais digitais, como os *e-books*, *podcasts*, outros tipos de áudios, teleaulas e outros tipos de vídeos.

O emprego das TICs tem sido imprescindível mesmo nos cursos presenciais, para o processo de ensino-aprendizagem (Gill & Dalgarno, 2017). Essa mudança tecnológica no âmbito educacional gera a necessidade de se criar metodologias e estratégias para lidar com esta nova realidade, inclusive para produção dos conteúdos educacionais.

Há uma considerável quantia de conteúdo educacional disponível na Web. A Wikipédia, por exemplo, possui mais de 6 milhões de artigos em inglês, além de mais de 1 milhão de artigos em língua portuguesa (Wikipedia, 2020). Neste mesmo sentido, o YouTube, a maior plataforma de compartilhamento de vídeos *online*, é atualizada, a cada minuto, com cerca de 500 horas de conteúdo sobre as mais diversas áreas de conhecimento (Apps, 2020).

Uma significativa fração desses conteúdos disponíveis podem ser utilizados como recurso no âmbito educacional. O *e-Learning*, que Clark and Mayer (2016, p. 9) definem como a “instrução fornecida em um dispositivo digital, como um computador ou dispositivo móvel, que se destina a apoiar a aprendizagem”, tem ganhado importância, à medida que aumenta a quantidade de materiais disponíveis na *Web*, bem como a possibilidade de acesso a esses recursos, por meio da melhoria das conexões de internet e da capacidade dos dispositivos computacionais. No entanto, é muito difícil avaliar e escolher manualmente dentre todo o montante de conteúdos, quais vídeos, textos, e/ou imagens são os mais adequados para serem utilizados.

Em ambientes de vasta quantidade de materiais, são necessários mecanismos para selecionar e recomendar os conteúdos mais adequados aos usuários. Nesse contexto, são utilizados os Sistemas de Recomendação, os quais são responsáveis por encontrar e recomendar os itens mais úteis aos estudantes (Hassan & Hamada, 2016).

De modo a favorecer a sua utilidade, usualmente os conteúdos educacionais são organizados em Objetos de Aprendizagem (OAs). Um curso completo, ou uma única seção de aprendizagem, por vezes contempla múltiplos conceitos, podendo ser necessário também recomendar vários OAs para cobertura de todos os conceitos que o compõem. Assim, é complicado tratar a recomendação de vários OAs a partir de grandes repositórios, isso porque além de vários conceitos a serem contemplados, naturalmente haverá vários OAs cobrindo os mesmos conceitos.

De fato, há inúmeros fatores que devem ser analisados para se realizar uma recomendação

adequada. Do ponto de vista do estudante, é preciso considerar suas necessidades e preferências. Sob a ótica do educador, entretanto, não se pode descuidar da tarefa de contemplar os conceitos previstos, conforme estabelecido no *Design* Instrucional (DI) do curso ou das seções de aprendizagem consideradas.

Constantemente, um grupo de seções de aprendizagem relacionado a um assunto contém um número de conceitos a mais do que o aluno precisa ou está disposto a estudar. Nesse sentido, o DI pode prever a possibilidade de que não necessariamente todos os conceitos relacionados àquele assunto precisem ser estudados. Essa flexibilização pode ser admitida em um modelo de *Design* Instrucional Contextualizado (DIC) (A. Filatro & Piconez, 2004), no qual são admitidas mudanças *on-the-fly* em uma estrutura didática pré-concebida - nesse caso, o conjunto de conceitos (veja seção 2.2).

No entanto, deve-se frisar que a possibilidade supramencionada necessita de cuidados do ponto de vista pedagógico. Em geral, uma seção de aprendizagem é dividida em uma sequência de conceitos que segue uma lógica de aprendizagem. Dessa maneira, torna-se imprescindível, em alguns casos, que para um determinado conceito ser apresentado ao aluno, seus pré-requisitos estejam presentes. Isto posto, na possibilidade de haver a recomendação de um conjunto de OAs que não cubra a totalidade dos conceitos inicialmente previstos no DI de uma seção de aprendizagem, esse mesmo conjunto deve assegurar, no entanto, que os pré-requisitos de cada conceito daquela seção sejam atendidos, isto é, estejam cobertos por algum OA.

Passa a ser factível, então, recomendar um grupo de OAs que não cubra necessariamente todos os conceitos de uma seção de aprendizagem, mas que respeite a relação de pré-requisitos supracitada. Na verdade, pode-se recomendar diferentes conjuntos de OAs, os quais contemplem diferentes estruturas de aprendizagem do ponto de vista conceitual. Essa coleção de possibilidades permite ao aluno escolher, com o auxílio de um tutor ou mesmo de um Sistema de Recomendação, aquela configuração que melhor atenda aos seus anseios.

Nessa perspectiva, a proposta deste trabalho é apresentar um problema de otimização multi-objetivo para a recomendação de diferentes conjuntos de OAs para uma seção de aprendizagem, num contexto de *Design* Instrucional no qual não necessariamente todos os conceitos previstos precisam ser cobertos, respeitadas as dependências existentes entre alguns deles. No problema proposto, buscam-se soluções com o menor custo e a maior cobertura de conceitos possível.

O custo das soluções se dá pela soma de todos os OAs recomendados que façam parte da solução. Tal custo é calculado a partir de quão adequado é o tipo de mídia do OA para o perfil do aluno. Também engloba o cálculo do custo a avaliação dos OAs que outros usuários com mesmo perfil do aluno possam ter feito.

Tal abordagem se justifica pelo fato de apresentar não apenas uma, mas múltiplas possibilidades de solução, a partir dos objetivos de otimização considerados. Isso propicia o fornecimento de mais alternativas aos agentes envolvidos no processo de ensino-aprendizagem, no sentido de poderem escolher o conjunto de OAs que, além de atender as metas de aprendizado estabelecidas, possa melhor contemplar as expectativas e situações de contexto que porventura surjam.

Desta maneira, o objetivo deste trabalho consiste em propor uma abordagem multiobjetivo para o problema de recomendação de Objetos de Aprendizagem, implementando uma técnica heurística que possa gerar um conjunto de soluções para o problema.

Para o atendimento dos objetivos deste trabalho, utilizou-se o algoritmo genético NSGA-II, implementado no *framework* MOEA (*Multi Objective Evolutionary Algorithm*) (MOEA, 2020), para solucionar diversas instâncias artificiais do problema modelado. Neste sentido, obtiveram-se conjuntos de soluções mais diversos e numerosos para cursos com menos dependências entre conceitos. De forma geral, constatou-se que o NSGA-II pode ser aplicado para a solução do problema proposto, haja vista que foram geradas múltiplas soluções bem diversas entre si, em termos de custo e cobertura, para distintas instâncias do problema.

Este trabalho se organiza como segue. A seção 2 apresenta os conceitos fundamentais para o entendimento da presente pesquisa, bem como alguns trabalhos relacionados à mesma. A seção 3 apresenta o problema proposto, bem como discute a arquitetura do Sistema de Recomendação proposto para a solução de tal problema. A seção 4 apresenta a metodologia experimental adotada para a obtenção dos resultados. A seção 5 apresenta os resultados experimentais desta pesquisa. Por fim, a seção 6 apresenta as conclusões e perspectivas de trabalhos futuros.

2 Referencial Teórico

2.1 Objetos de Aprendizagem e Sistemas de Recomendação

Os Objetos de Aprendizagem (OAs) são definidos por IEEE (2020, p. 1) como “qualquer entidade, digital ou não, que possa ser utilizada para aprendizagem, educação ou capacitação”. Cada OA é geralmente composto pelo seu conteúdo propriamente dito, como também por meta-dados que descrevem os seus atributos, tais como nome, autor, nível de dificuldade, ano de criação, tipo de conteúdo (vídeo, texto, imagem, etc.), entre outros.

Os OAs podem ser utilizados como fonte de recursos educacionais no processo de ensino-aprendizagem. Nifoci (2013, p. 28), ao citar os repositórios sobre os quais os OAs são organizados, esclarece que sua criação tem por finalidade “apoiar cursos presenciais e à distância, focados para o ensino de determinado conteúdo”. Entre suas possíveis aplicações em um curso, Nifoci (2013, p. 28) cita o fato de poder ser “(...) um motivador para um novo assunto a ser abordado ou mesmo para dar fechamento a uma sequência de conhecimentos sobre determinado tema (...)”. No âmbito da EAD, modalidade crescente para a oferta de cursos conforme já apontado, os conteúdos educacionais digitais têm sido desenvolvidos de forma crescente sob a forma de OAs (Dutra, Tarouco, & Passerino, 2011).

Os Objetos de Aprendizagem são, de forma geral, organizados em repositórios, geralmente seguindo um determinado padrão de metadados que possibilita não somente a manipulação assertiva dos OAs, como também a interoperabilidade entre repositórios existentes. No campo educacional, alguns dos padrões mais conhecidos são IEEE LOM (*IEEE standard for learning object metadata*) (IEEE, 2020), IMS-CP (IMS, 2019), SCORM (ADL, 2022) e Dublin-CORE (DCM, 2020).

A aplicação de Sistemas de Recomendação no âmbito educacional tem sido estudada em diversas pesquisas. Entre elas, situam-se os Sistemas de Recomendação de Objetos de Aprendizagem. Muitas abordagens desses sistemas recomendam os OAs que melhor correspondem aos anseios do estudante (Santos, Andrade, Silva, & Imran, 2016). As técnicas mais comuns emprega-

das para esse fim são recomendação baseada em conteúdo e a filtragem colaborativa.

A recomendação baseada em conteúdo se vale de outros itens que um determinado usuário já acessou e avaliou, para então recomendar novos itens, a partir da análise de semelhança dos atributos que houver entre eles (Venkatesh & Sathyalakshmi, 2020). Por sua vez, a filtragem colaborativa consiste em prover a recomendação de um item a um usuário a partir de avaliações que usuários com perfil semelhante fizeram acerca daquele item (Sergis & Sampson, 2016).

Também existem outros métodos que lidam com o problema de se possuir pouca informação sobre o usuário, o que dificulta a adoção das técnicas supracitadas para a recomendação. Essa dificuldade de identificar as preferências de novos usuários é conhecida como *cold start*. Muitas vezes há abordagens híbridas, que combinam distintas técnicas para realizarem a recomendação, de modo a se valer dos pontos fortes de cada estratégia e atenuar as suas respectivas limitações.

Entre essas abordagens, pode-se mencionar a recomendação baseada em Ontologia, que utiliza um domínio específico de conhecimento no qual o usuário está inserido, para facilitar a identificação das suas preferências. Também há a recomendação por contexto, considerando, por exemplo, o horário e o dia em que se está utilizando o sistema. Existem outras abordagens que aplicam, dentre outras estratégias, Lógica *Fuzzy* (Sergis & Sampson, 2016), Redes Neurais (Yao, 1999), Algoritmo Genético (Katarya & Verma, 2018) e Computação Bioinspirada (Hassan & Hamada, 2016).

O mecanismo de recomendação de OAs proposto nesse trabalho é uma combinação entre diferentes estratégias. Inicialmente, para lidar com o *cold start*, estabelecem-se a adequabilidade dos OAs a um aluno a partir do seu Estilo de Aprendizagem. Em um segundo momento, utiliza-se a avaliação dos OAs por outros alunos, num processo de recomendação por filtragem colaborativa. Tal processo é detalhado na seção 3.

2.2 Design Instrucional

A utilização das ferramentas de Tecnologia da Informação e Comunicação (TICs) no processo de ensino-aprendizagem está em franca expansão. Diante dessa realidade, é crescente a necessidade de se buscar estratégias e metodologias para produção dos conteúdos e materiais que são utilizados nesse contexto, de modo a se atingir os objetivos e expectativas dos agentes envolvidos nesse processo, desde os alunos até os professores. Para se efetivar tal tarefa, podem ser empregados os modelos de *Design Instrucional* (DI).

A. Filatro and Piconez (2004, p. 2) descrevem *Design Instrucional* sendo “(..) compreendido como o planejamento do ensino-aprendizagem, incluindo atividades, estratégias, sistemas de avaliação, métodos e materiais instrucionais.”

Sob uma perspectiva teórica, Wiley (2002, p.7), ao citar (Reigeluth, 1999), define o *Design Instrucional* da seguinte maneira: “As teorias de *design* instrucional são orientadas ao *design*, descrevem métodos de instrução e as situações em que esses métodos devem ser usados, os métodos podem ser divididos em métodos de componentes mais simples e os métodos são probabi-lísticos.”

Ao se ver o DI como um processo, A. Filatro and Cairo (2015) distinguem sua abrangência em três níveis, a saber:

- macro: define diretrizes de ações de aprendizagem para um sistema educacional inteiro, por

exemplo, de toda uma instituição;

- meso: ações voltadas para uma dimensão mais específica, como um curso ou disciplina; e
- micro: trata das menores unidades de estudo que são propostas aos alunos.

Existem diversas naturezas de *Design* Instrucional. A. C. Filatro (2008) faz essa distinção em três diferentes tipos de DI: fixo, aberto e contextualizado.

Ao se falar em DI fixo, existe uma total divisão entre as etapas de planejamento e execução. Isso significa que o planejamento e produção de cada item que compõe o DI são completamente finalizados antes de se efetivar a ação de aprendizagem que será conduzida a partir daquele DI (A. Filatro & Cairo, 2015). É um modelo que traz pouca margem à personalização e está focado na reutilização dos conteúdos, uma vez que a localização e o sequenciamento dos mesmos são previamente conhecidos.

Por sua vez, o DI aberto trata o processo de ensino-aprendizagem como uma situação dinâmica e flexível. Segundo A. C. Filatro (2008, p. 212) no DI aberto, geralmente “(...) os artefatos são criados, refinados ou modificados durante a execução da ação educacional”. Neste sentido, é também chamado de *design on-the-fly*, pois é construído em grande parte no momento de sua implementação.

O modelo de *Design* Instrucional Contextualizado (DIC) apresenta um ponto intermediário entre abordagens anteriores, na medida em que admite um processo de ensino com mudanças *on-the-fly*, sem no entanto abrir mão de elementos previamente programados. Isso permite que um DI tenha premissas definidas, sem deixar de prover mecanismos que se adaptem às características dos agentes no processo educacional. Nesse sentido, A. Filatro and Piconez (2004, p. 4) definem o DIC como “a ação intencional de planejar, desenvolver e aplicar situações didáticas específicas que, valendo-se das potencialidades da Internet, incorporem, tanto na fase de concepção como durante a implementação, mecanismos que favoreçam a contextualização e a flexibilização”.

Quando tratado como um processo, o DI costuma ser dividido em etapas. Rodrigues, Rodrigues, and Dias (2014) dividem tais etapas da seguinte maneira:

- Análise: identificação das necessidades, metas e os objetivos instrucionais, considerando as limitações existentes;
- Projeto: definição do conteúdo, instrumentos de avaliação e até mesmo planejamento de aulas para se atingir os objetivos de aprendizagem;
- Desenvolvimento: produção dos materiais projetados na etapa anterior;
- Implantação: capacitação e ambientação dos agentes envolvidos no processo de ensino-aprendizagem com a meta efetivar a proposta de DI concebida; e
- Avaliação: acompanhamento do sistema que foi proposto e implantado, com a sua revisão e manutenção a partir do *feedback* obtido.

Existem também outros modos de se entender as etapas do DI. A. Filatro and Piconez (2004), por exemplo, reúnem o projeto e desenvolvimento em uma única etapa. Argumentam ainda que, no *Design* Instrucional Contextualizado, tais etapas ocorrem de modo recursivo.

O fato é que o DIC se mostra um modelo útil para guiar a produção de recursos didáticos digitais, uma vez que, conforme Moreira et al. (2019, p. 2)“(…) [o DIC] lida com situações didáticas que realçam a qualidade do contexto de aprendizagem no processo de planejamento, desenvolvimento e aplicação dessas situações”. O presente trabalho se vale desse princípio para propor um modelo de *Design* Instrucional flexível da perspectiva conceitual, que permita que nem todos os conceitos pertencentes a uma seção de aprendizagem precisem ser estudados pelos alunos.

2.3 Estilos de aprendizagem

Inúmeras ações são empregadas no processo de ensino-aprendizagem. Atividades individuais ou em grupos, simulações, apresentações, estudos de caso são algumas das possibilidades, que podem igualmente utilizar os mais variados tipos de materiais, por exemplo textos, imagens, jogos e arquivos de áudio e vídeo. Contudo, as pessoas possuem diferentes preferências com relação ao modo como se apropriam e processam as informações para construção de novos conhecimentos (Cury, 2000). Isso provoca distintos níveis de aprendizagem nas pessoas, a depender de quais estratégias e materiais são utilizados. De fato, a compatibilidade entre o Estilo de Aprendizagem do aluno e o Estilo de Ensino do professor pode impactar no nível de aprendizagem do aluno (Felder & Silverman, 1988).

Existem variados entendimentos do que seja Estilo de Aprendizagem (EA). Cerqueira (2000, p. 1) diz que os EAs “(...) relacionam-se à maneira pela qual as pessoas interagem com as condições de aprendizagem, abrangendo aspectos cognitivos, afetivos, físicos e ambientais que podem favorecer o processamento de informações”. Silva (2006, p. 45) os considera um subconjunto dos estilos cognitivos, resultado de fatores hereditários, educacionais, além da personalidade e da adaptação do indivíduo às demandas do ambiente. Entretanto, Schmitt and Domingues (2016, p.364), ao citar (Jacobsohn, 2003), dizem que o EA de uma pessoa pode se alterar ao longo do tempo, em função da sua maturidade.

O modelo de Felder-Silverman (Felder & Silverman, 1988) é um dos mais amplamente utilizados para determinação de Estilos de Aprendizagem. Ele trabalha com quatro dimensões, a saber: Processamento, Percepção, Recepção e Entendimento da Informação. Cada uma das dimensões possui 2 categorias, com características definidas da seguinte forma por (Schmitt & Domingues, 2016, p.371), ao citar (Felder & Spurlin, 2005):

- a) Ativo (esforço ao aprendizado, gosta de trabalhar em grupo) ou Reflexivo (aprende ao pensar, prefere trabalhar sozinho ou com um ou dois parceiros);
- b) Sensitivo (concreto, prático, voltado para fatos e procedimentos) ou Intuitivo (conceitual, inovador, orientado para teorias e significados subjacentes);
- c) Visual (prefere representações visuais do material apresentado, tais como imagens, diagramas e fluxogramas) ou Verbal (prefere escrita e explicações comentadas);
- d) Sequencial (processo de pensamento linear, aprende com passos incrementais) ou Global (processo de pensamento holístico).

Devido ao acréscimo da quantidade de repositórios de OAs, Bourkoku and El Bachari (2018) pontuam que uma das formas de personalização do ensino que tem sido desenvolvida para

lidar com essa realidade se dá através dos Sistemas de Recomendação de OAs. Neste contexto de customização, os mesmos autores indicam um conjunto de atividades e OAs que seriam mais adequados para cada uma das categorias do modelo de Felder-Silverman, conforme descrito na Tabela 1. Nela, a primeira coluna se refere às dimensões do Estilo de Aprendizagem, para a qual há um conjunto de estratégias de ensino sugeridas, indicada na segunda coluna. A terceira coluna apresenta possíveis tipos de OAs com os quais as estratégias de ensino podem ser empregadas.

Tabela 1: Sugestões de estratégias de ensino e tipos de OA para cada estilo de aprendizagem.

EA	Estratégia de Ensino sugerida	Tipo de Mídia do OA
Ativo	Simulação, Resolução de Problemas, Discussão em Grupo, <i>Brainstorming</i> , Experimentos, Perguntas e Respostas.	Fórum de discussão, Página Wiki, Blog, Chat, E-mail, Questões de Múltipla Escolha.
Reflexivo	Apresentação, Estudo de Caso.	E-book, texto escrito.
Sensitivo	Apresentação, Leitura de Texto, Resolução de Problemas, Jogos de Simulação, Perguntas e Respostas.	Fórum de discussão, Blog, Página Wiki, Animação, Gráfico, Figura
Intuitivo	Discussão em Grupo, Simulação, Jogos de Papéis, Estudo de Caso, Leitura	Mecanismo de Busca na Internet, Quiz, Questões de Múltipla Escolha
Visual	Simulação, Apresentação, Leitura de Texto	Fórum de Discussão, Página Wiki, Gráfico, Figura, Simulação, Vídeo
Verbal	Grupos de Discussão, <i>Brainstorming</i> , Perguntas e Respostas, Resolução de Problemas	Gravação de Áudio, Podcast
Sequencial	Apresentação, Perguntas e Respostas	E-book, Áudio
Global	Jogos de papéis, <i>Brainstorming</i> , Estudo de Caso	Blog, Página Wiki, Chat, E-mail, Questões de Múltipla Escolha.

Entretanto, nesse processo de seleção da abordagem de ensino mais adequada ao aluno, é necessário primeiramente determinar a qual EA ele está associado. Uma das alternativas para identificação dos Estilos de Aprendizagem do modelo Felder-Silverman é a utilização do Índice de Estilos de Aprendizagem de Felder-Soloman (ILS) (Soloman & Felder, 2005). Trata-se de um questionário composto por 44 perguntas, por meio do qual se busca identificar as categorias do Estilo de Aprendizagem do aluno em cada uma das quatro dimensões do modelo.

Desse modo, a teoria relacionada aos Estilos de Aprendizagem busca identificar as diferenças entre os estudantes em relação às suas especificidades no processo de ensino-aprendizagem. Conhecidas tais diferenças, o outro desafio é adequar as metodologias de ensino e conteúdos para prover a melhor experiência de acordo com as necessidades do estudante.

O presente trabalho utiliza a categorização dos Estilos de Aprendizagem proposto por (Felder & Silverman, 1988) para determinar o perfil do estudante. O sistema de recomendação se vale desse perfil para selecionar os tipos de OAs provavelmente mais adequados ao aluno, de acordo com o proposto por (Bourkhouk & El Bachari, 2018), assim como para estabelecer um mecanismo de filtragem colaborativa. Esse mecanismo se encontra detalhado na seção 3.

2.4 Trabalhos Relacionados

Há muitos trabalhos na literatura que tratam de recomendações de um conjunto de OAs para atender a um conjunto de necessidades de aprendizagem. Vários deles implementam propostas voltadas para grandes repositórios, como Wikipédia e YouTube.

De Medio, Gasparetti, Limongelli, and Sciarrone (2017) utilizam artigos da Wikipédia para desenvolver uma plataforma de construção de cursos, empregando um módulo que realiza a detecção automática de pré-requisitos entre as páginas da Wikipédia. As páginas selecionadas são ainda sequenciadas, o que ocorre por meio da associação de cada conceito a ser estudado com um tópico da Wikipédia. Os estilos de ensino de Grasha (Grasha, 1996) também são utilizados para se fazer o sequenciamento, sendo armazenado em um grafo, que pode ser editado pelo professor do curso. Os autores mencionam pontos a serem melhorados no sistema, entre os quais estão as complexidades de tempo e espaço, respectivamente, para construção e atualização dos grafos que representam os relacionamentos entre os conteúdos. Também destacam a possibilidade de estender o mecanismo proposto a outros repositórios, como Merlot ou Ariadne.

Pireva and Kefalas (2017) dedicam-se ao contexto do paradigma do *e-learning* em nuvem, implementando recomendação e sequenciamento de OAs. O sistema de recomendação de OAs baseia-se na clusterização hierárquica e filtra os OAs de acordo com o perfil e os objetivos dos alunos. Para cada estudante, determina-se o tópico que é o seu objetivo de aprendizagem, assim como seu conhecimento prévio, ambos indicados em um nível cognitivo da taxonomia de Bloom. A partir do ranqueamento dos OAs selecionados, obtém-se o caminho de aprendizagem personalizado por meio de um sequenciamento de OAs, de acordo com o interesse e o nível de conhecimento que cada aluno possui e pretende atingir. A abordagem proposta é empregada em um exemplo de curso da área de computação, o que demonstrou a sua aplicabilidade.

Júnior and Dorça (2018) também utilizam a Wikipédia como fonte de recursos de aprendizado a serem recomendados aos estudantes. Os autores constroem uma ontologia que possibilita a modelagem dos OAs e estudantes, os quais possuem um perfil definido de acordo com os Estilos de Aprendizagem do modelo Felder-Silverman (Felder & Silverman, 1988). O processo de recomendação foi formalizado como um problema de cobertura de conjuntos, no qual se procura selecionar um conjunto de OAs que cubra todos os conceitos requisitados, com o menor custo possível. O custo de um OA se dá pela comparação de distintos atributos desse OA em relação aos atributos de um OA ideal, os quais são definidos a partir de parâmetros determinados pelo professor do curso. Foi proposto um problema com alguns conceitos a serem cobertos. Experimentos realizados apontam que os OAs que compõem as melhores soluções, são mais similares ao OA ideal em relação aos parâmetros que possuem um peso maior.

Ao invés do enfoque em textos, Murad and Yang (2018) propõem a recomendação de Objetos de Aprendizagem cujos conteúdos estão organizados sob a forma de vídeos. Para tal, é apresentado um *framework* capaz de identificar o nível de conhecimento e perfil dos estudantes, e de posse dessas informações, recomendar vídeos que vão ao encontro das suas necessidades de aprendizado. A plataforma de vídeos inicialmente pensada para efetivação da proposta foi o *YouTube*. Inicialmente, os vídeos da referida plataforma são obtidos e então extraídos seus metadados. Os vídeos são classificados por meio de seus tópicos e subtópicos, pela utilização de técnicas de Aprendizagem de Máquina. Os perfis de estudantes são construídos a partir de informações de contexto, obtidas tanto por meio de *feedback* explícito do aluno, como também pela coleta de dados do comportamento do usuário. O trabalho ainda se encontrava em desenvolvimento, sendo que os autores estavam construindo o mecanismo de processamento e mineração de dados multimídia para utilizá-lo em aulas de cursos de engenharia.

Bourkhouk and El Bachari (2018) também implementam recomendação de OAs e sequenciamento dos mesmos, utilizando os Estilos de Aprendizagem propostos por (Felder & Silverman,

1988) para personalizarem o aprendizado dos alunos. Porém, esse modelo é dinamicamente atualizado à medida que o estudante utiliza o sistema. Para tanto utiliza-se Mineração de Dados nos *logs* gerados no sistema, referentes às ações e interações de cada usuário. A partir do perfil de determinado usuário, o sistema de recomendação sugere, por filtragem colaborativa, uma lista sequenciada de OAs que são considerados os mais apropriados para aquele perfil. O sistema proposto foi testado em um caso real, no qual se verificou boa aceitação dos alunos do cenário de aprendizagem personalizado em comparação ao modelo tradicional (no qual uma mesma sequência de aprendizagem é gerada para todos os alunos).

Venkatesh and Sathyalakshmi (2020) propõem um sistema de recomendação personalizado, implementado com um algoritmo de otimização de colônia de abelhas para construção da estrutura de recomendação, que emprega ainda o algoritmo de clusterização k-médias. Os testes são executados em um Sistema de Gerência de Aprendizagem (LMS) baseado no Moodle. O modelo de otimização busca identificar um caminho de aprendizado ideal para cada aluno, por meio de uma sequência de links que acessam OAs. O processo de recomendação é dividido em duas fases. Na primeira, as informações das sessões dos alunos são coletadas e agrupadas por técnicas de Mineração de Dados. Na segunda fase, ocorre a captura das preferências dos usuários nas sessões ativas quando a recomendação irá se efetivar, as quais são obtidas por intermédio das URLs que os estudantes acessam. Resultados obtidos em experimentos mostram que a abordagem proposta obteve melhores resultados que um algoritmo de busca gulosa.

Nota-se que há muitas pesquisas que buscam utilizar a grande quantidade de conteúdos disponíveis em repositórios *web* para empregá-los no *e-learning*. A recomendação dos OAs tem o objetivo de atingir da melhor maneira possível as necessidades de aprendizagem do aluno, seja do ponto de vista dos tópicos a serem abordados, como do tipo de material mais adequado para cada perfil de estudante, passando, em muitos casos, inclusive pelo sequenciamento desses conteúdos.

Porém, nas pesquisas realizadas, percebe-se que o foco da recomendação está principalmente em um único objetivo, que é o atendimento às metas de aprendizagem do aluno. A principal diferença do presente trabalho é que se adota uma abordagem multiobjetivo, em que a cobertura de todos conceitos do curso não é obrigatória, mas um objetivo a ser maximizado, em detrimento do custo geral da solução, que tende a aumentar à medida que mais OAs passam a compô-la.

Sob a ótica educacional, aponta-se que o *Design* Instrucional do curso flexibiliza a necessidade de que todos os conceitos sejam estudados. No entanto, o mesmo *Design* Instrucional também estabelece as relações de pré-requisitos entre alguns conceitos, que precisam ser respeitadas em cada solução considerada, mesmo quando nem todos os conceitos estiverem cobertos. Na verdade, tem-se uma relação de custo-benefício que permite ao aluno abrir mão de um curso totalmente completo em termos de conceitos, para escolher uma solução com menor custo, de acordo com a sua realidade, expectativa, prioridade e preferência.

3 O Problema de Recomendação de Objetos de Aprendizagem Multiobjetivo

3.1 Exemplo de aplicação

A seguir é apresentado um exemplo para compreensão do problema proposto. Para tanto, seja uma seção de aprendizagem, composta pelos conceitos a, b, c, d, e . Nesse exemplo, considera-se que o *Design Instrucional* dessa seção determina que o conceito c é um pré-requisito para o conceito d , o que significa dizer que é necessário apresentar c antes de d , para que o aluno tenha correta compreensão do que está sendo estudado.

Supõe-se existir um repositório de OAs que será utilizado como fonte de recursos educacionais para essa seção de aprendizagem, no qual os conceitos que cada OA cobre está indicado conforme a seguir: $OA_1 = \{b, c\}$, $OA_2 = \{e\}$, $OA_3 = \{a, d\}$, $OA_4 = \{d, e\}$, $OA_5 = \{a, c\}$, $OA_6 = \{b\}$, sendo o custo de cada OA calculado em 5, 3, 8, 7, 9 e 5 respectivamente, para um determinado estudante. Considera-se que esse mesmo estudante irá estudar a referida seção de aprendizagem a partir do repositório de OAs supramencionado. Para tal, podem-se recomendar distintos conjuntos de OAs do repositório, sendo uma possível solução $S_1 = \{OA_1, OA_2, OA_3\}$, que teria custo 16.

É interessante perceber que, em relação a S_1 , o conjunto de OAs não obedece necessariamente a sequência de apresentação dos conceitos da seção. O conceito a é coberto pelo OA_3 e os conceitos b e c pelo OA_1 , porém o conceito d é coberto também pelo mesmo OA_3 que cobriu a . Pressupõe-se, portanto, que os OAs estão organizados de maneira que seja possível, por meio do Sistema de Recomendação, identificar qual parte do OA se refere a cada conceito (de maneira semelhante às seções de uma página wiki). Desse modo, no exemplo apresentado, o aluno estuda o conceito a presente no OA_3 , em seguida acessa o OA_1 para estudar b e c , passando novamente a acessar OA_3 naquilo que estiver relacionado ao conceito d .

A solução $S_2 = \{OA_3, OA_4, OA_6\}$ por sua vez, não seria válida. Isso porque ela cobre o conceito d mas não cobre o conceito c , o qual é pré-requisito para d . A solução $S_3 = \{OA_5, OA_6\}$ de custo 13 seria válida porque, embora não cubra dois dos conceitos projetados para a seção de aprendizagem, respeita a relação de dependência estabelecida pelo *Design Instrucional*.

Ao se admitir a alternativa de existirem soluções que não cubram todos os conceitos, tem-se a possibilidade de optar por um curso menos completo, mas que possa estar mais próximo dos objetivos e da realidade do aluno. Por exemplo, um estudante que tenha tempo limitado para realizar um curso completo passa a ter a possibilidade de estudar algo mais sucinto, mas que possui um conjunto mínimo de conceitos cobertos e que é adequado à disponibilidade do aluno.

Entretanto, em face da limitação de conhecimento metacognitivo que o aluno possui, não é adequado que ele próprio escolha dentre todas as soluções qual é aquela que melhor lhe atenderá. Diante disso, na ausência de um tutor que auxilie o aluno nesse processo de escolha, o próprio Sistema de Recomendação poderá realizar esta seleção. Como indicação, por exemplo, o sistema pode realizar sua recomendação considerando a solução que apresente a menor proporção de custo em relação ao número de conceitos cobertos.

Também a respeito de S_2 , é importante notar que caso não houvesse a relação de pré-requisito especificada e a solução fosse válida, o conceito d estaria coberto por dois OAs na mesma solução, quais sejam, OA_3 e OA_4 . Nesse caso, caberia ao Sistema de Recomendação definir qual OA seria utilizado pelo aluno (de acordo com o critério de menor custo, por exemplo).

3.2 O Sistema de recomendação multiobjetivo

Mostra-se, na sequência, a estrutura do sistema de recomendação no qual está inserida a abordagem proposta. O sistema é composto basicamente por três módulos, conforme explicitado na Figura 1.

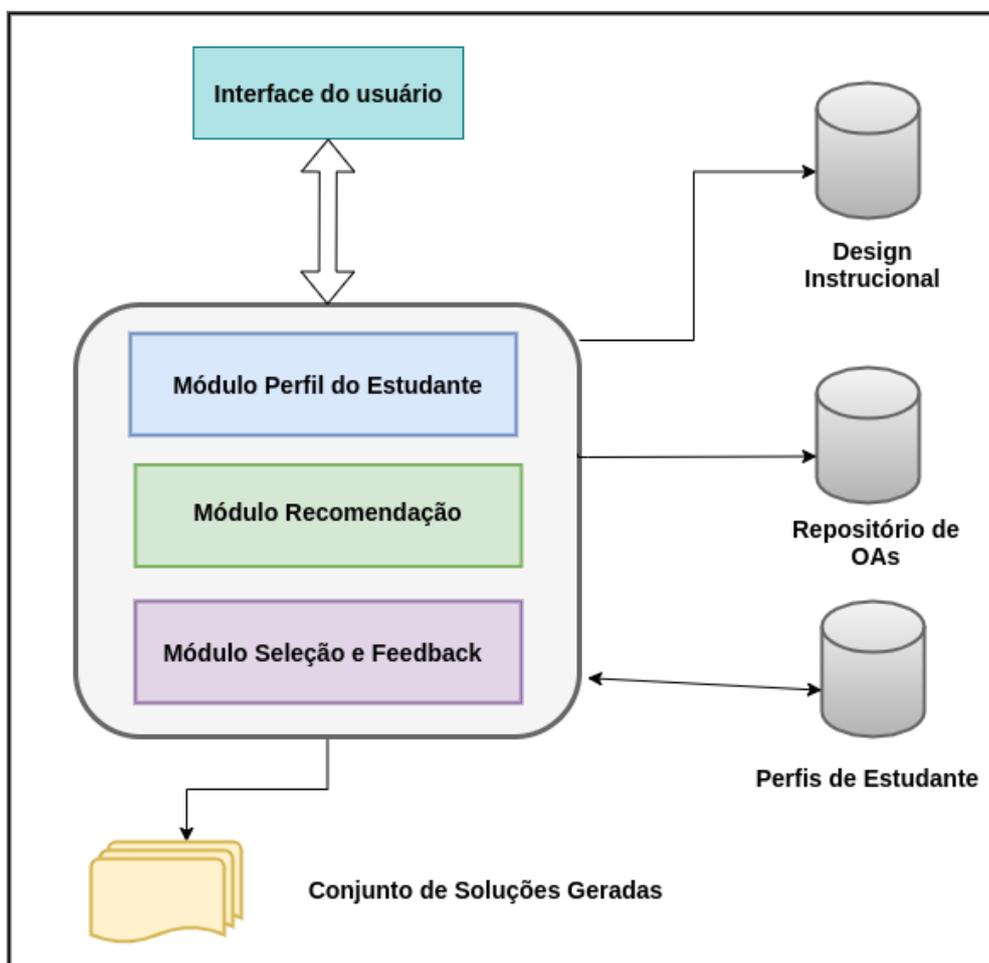


Figura 1: Estrutura do Sistema de Recomendação Proposto. Fonte: próprio autor.

O primeiro módulo é o de Perfil do Estudante. Esse perfil é determinado pelas informações do Estilo de Aprendizagem do aluno, através de sua classificação nas dimensões de aprendizagem de acordo com o modelo (Felder & Silverman, 1988). A determinação desse perfil de estudante se dá a partir da aplicação do questionário ILS (Felder & Spurlin, 2005). A determinação do Estilo de Aprendizagem é utilizada para determinar quais os tipos de OAs são mais adequados para o estudante, conforme indicado na seção 2.3. O critério de seleção dos OAs se dá a partir do custo que for estabelecido a cada um deles.

O segundo módulo é o de Recomendação propriamente dito, dividido em várias etapas, explicadas a seguir:

- Consulta ao *Design Instrucional* da seção de aprendizagem, com o intuito de obter quais os conceitos a compõem, bem como verificar as dependências existentes entre eles;

- Seleção de OAs: busca-se então no repositório de OAs aqueles que cobrem pelo menos um dos conceitos previstos, ou seja, aqueles os quais podem eventualmente ser recomendados;
- Atribuição de custo de cada um dos OAs selecionados na etapa anterior. Tal custo é calculado a partir de quão adequado é o tipo de média do OA (consultado a partir dos seus metadados) para o Estilo de Aprendizagem do aluno (determinado no módulo Perfil de Estudante). A avaliação que outros usuários com mesmo perfil já possam ter feito em cada um dos OAs também engloba o cálculo do custo. Esse cálculo se encontra pormenorizado na seção 3.3.
- Geração dos conjuntos de OAs com o auxílio do NSGA-II, a partir do vetor de custos de OAs para o estudante, gerado na etapa anterior. O cálculo de qualidade de cada solução gerada se dá a partir do somatório de custos de todos os OAs daquela solução, bem como da quantidade de conceitos que são cobertos pela mesma.

O terceiro módulo do sistema é o módulo de Seleção e *Feedback*, por meio do qual o sistema escolhe para o estudante, dentre as distintas soluções geradas pelo módulo de recomendação, aquela que será utilizada. A escolha se dá pela solução que apresente menor proporção do custo em relação ao número de conceitos cobertos. À medida que o estudante acessa e utiliza os OAs daquela solução, o sistema solicita a ele que faça também a avaliação do OA. Essa avaliação é utilizada para calcular o custo do OA para futuros alunos que venham a utilizar o sistema.

A Figura 1 apresenta a estrutura básica para o sistema de recomendação proposto. O estudante inicia o acesso por uma interface responsável por estabelecer a comunicação com o sistema. Por intermédio dela, o módulo responsável por determinar o perfil do aluno obtém as informações do estudante, e as adiciona ao conjunto de perfis de estudantes já existentes. Também é por meio da interface do usuário que o conjunto de soluções geradas é disponibilizado.

3.3 Cálculo do custo de um Objeto de Aprendizagem para cada aluno

Seja uma matriz $m \times n$, a qual representa o custo para cada um dos m Objetos de Aprendizagem (disponíveis para cobrir os conceitos de uma determinada seção de aprendizagem) para cada um dos n alunos com perfis cadastrados no sistema.

O custo de um OA para um aluno é composto pelo custo inicial li e custo final lf . O cálculo de li baseia-se na relação entre o Estilo de Aprendizagem do aluno no modelo Felder-Silverman (FS) e o tipo de média do OA, conforme indicado por (Bourkougou & El Bachari, 2018) e explicado na seção 2.3. Tal grandeza é calculada segundo a Equação 1.

$$li(OA_e) = 100 - \sum_{i=1}^4 p_i^e, \quad p_i^e \in \{0, 20\} \quad (1)$$

onde li é o custo inicial do OA em relação ao estudante e , p é o peso do OA em cada uma das i dimensões do modelo FS para e .

A Equação 1 avalia o tipo do OA em relação a cada uma das 4 dimensões do modelo FS (Felder & Silverman, 1988) na qual o estudante foi categorizado, conforme explicado na seção 2.3.

Para cada dimensão $i \in \{1, 2, 3, 4\}$ desse modelo, verifica-se se o tipo de média do OA considerado se mostra adequado à categoria em que o estudante e foi inserido. Caso afirmativo, p_i^e assume valor 20 e tem-se um decréscimo no custo total do OA em relação àquele estudante. Caso contrário, p_i^e assume valor 0 e o custo total não é reduzido.

Assim, o custo máximo li de um OA é 100 (quando ele não se mostra propício ao aluno em nenhuma das 4 dimensões do modelo FS), e no mínimo 20 (quando há sua adequabilidade ao estudante nas 4 dimensões do modelo), havendo um decréscimo de 80 unidades em relação ao custo máximo estabelecido.

O cálculo do custo final lf , por sua vez, baseia-se no conceito de filtragem colaborativa. Para sua definição, utiliza-se a Equação 2.

A Equação 2 considera os m' usuários com Estilos de Aprendizagem semelhantes ao do estudante e em questão, que já tenham avaliado o OA cujo custo está se calculando, conforme estrutura proposta na Figura 1 da seção 3.2. São considerados os alunos com perfil semelhante aqueles os quais foram categorizados da mesma maneira em cada uma das 4 dimensões do modelo de Felder-Silverman.

A avaliação do OA pelos alunos se dá a partir de uma nota r atribuída pelos usuários, a qual pode variar de 1 a 100, sendo 100 uma avaliação muito positiva do OA, e 1 uma avaliação muito negativa. Assim, o custo de um OA para um estudante que já avaliou esse OA é o valor resultante de $100-r$. Isso faz com que, quanto melhor seja a avaliação, menor seja o custo do OA relacionado ao aluno que o avaliou.

A Equação 2 apresenta o cálculo do custo final lf de um OA para um estudante e . Para tanto, considera-se a média do custo de cada um dos m' estudantes de mesmo EA que e . Integra essa média, com o mesmo peso da avaliação de um único aluno, o custo inicial li do próprio estudante, obtido pela equação 1. Caso ainda não haja nenhum outro aluno com mesmo EA que tenha avaliado o OA, apenas o custo li é considerado para obtenção do custo final.

$$lf(OA_e) = \frac{li(OA_e) + \sum_{i=0}^{m'} 100 - r_i}{m' + 1}, \quad r \in \{1, \dots, 100\}, \quad m' \geq 0 \quad (2)$$

onde lf é o custo final do OA em relação ao estudante e , m' é o número de estudantes com mesmo EA que avaliaram o OA, e r é a nota atribuída ao OA por cada dos m' estudantes.

4 Metodologia Experimental

4.1 Instâncias do Problema

As instâncias de problema utilizadas foram geradas artificialmente, conforme descrito na Tabela 2. A justificativa para a utilização de instâncias artificiais se deve ao fato deste trabalho estar em fase inicial de desenvolvimento, bem como devido à escassez de base de dados reais que possam ser utilizadas nessa pesquisa. Na tabela 2 são indicadas, ainda, outras informações sobre tais instâncias, quais sejam: o número de OAs, a probabilidade de cobertura de um conceito por um OA, e o número de conceitos e de dependências entre os mesmos.

A probabilidade de cobertura representa a probabilidade que cada OA possui de cobrir um determinado conceito, no momento em que é gerada a instância. Por exemplo, se a probabilidade de cobertura for 0,2, em um universo de 10 conceitos, cada OA cobriria, em média, 2 de cada um dos 10 conceitos.

As três instâncias de problemas possuem um universo de 1000 Objetos de Aprendizagem e 200 conceitos. Tais instâncias foram estabelecidas tendo como referência o *benchmark OR-Library*, especificamente a sua instância 4.10¹, a qual trata do Problema de Cobertura de Conjuntos de 200 linhas por 1000 colunas, também utilizada no trabalho de (Júnior & Dorça, 2018). Assim como com a cobertura dos conceitos por OA, e as relações de dependências entre os conceitos, os custos dos OAs, para os estudantes, foram gerados aleatoriamente. Neste sentido, tais custos foram estabelecidos aleatoriamente com valores inteiros entre 1 e 100.

A matriz de cobertura da instância G2 foi gerada com cada OA tendo uma probabilidade de 0,02 de cobrir cada conceito. Na instância G3, por sua vez, essa probabilidade de cobertura é de 0,05. Em ambas as instâncias foram criadas 20 dependências distintas entre conceitos da seção de aprendizagem, sendo os conceitos também escolhidos aleatoriamente para comporem as dependências.

Neste sentido, G2 e G3 se diferenciam na questão da matriz de cobertura de G3 ser mais densa que a matriz de cobertura de G2, uma vez que em G3, um mesmo OA cobre, em média, mais conceitos que em G2. Em F3, a probabilidade de cobertura também é de 0,05, porém esta instância possui apenas 10 dependências distintas entre os conceitos.

É importante destacar que um maior número de dependências entre conceitos é mais condizente com as situações reais no processo de ensino-aprendizagem, nas quais, na maioria das vezes, um determinado conceito exige um conhecimento prévio relacionado a um outro conceito. Neste sentido, a instância F3, com menor número de dependências, é utilizada como referência para fins comparação em relação ao resultados obtidos nas instâncias G2 e G3.

Tabela 2: Características das instâncias geradas para realização dos testes.

Instância	OAs	P Cobertura	Conteúdos	Dependências
G2	1000	0,02	200	20
G3	1000	0,05	200	20
F3	1000	0,05	200	10

4.2 Métodos de Inicialização da População do NSGA-II

O Problema de Recomendação de Objetos de Aprendizagem Multiobjetivo proposto neste trabalho, foi implementado no *framework* MOEA (*Multiobjective Evolutionary Algorithm*) (MOEA, 2020), que possui um conjunto de bibliotecas em Java para desenvolvimento e realização de experimentos com algoritmos evolucionários multiobjetivo. Para resolução do problema proposto, foi utilizado o algoritmo genético NSGA-II (Deb, Agrawal, Pratap, & Meyarivan, 2000), um dos algoritmos evolucionários multiobjetivo mais utilizados no campo da otimização.

No método de inicialização da população padrão do MOEA, são gerados valores aleatórios

¹Disponível em: <http://people.brunel.ac.uk/~mastjjb/jeb/orlib/files/scp410.txt>

para cada uma das variáveis de decisão de cada indivíduo (solução) da população. No problema em questão, cada OA é uma variável de decisão, que assume apenas dois possíveis valores: 1 se o OA está na solução, ou 0, caso contrário. Portanto, cada OA é aleatoriamente escolhido para compor uma solução. Isso gera diferentes combinações de soluções, onde em cada uma delas, em média, metade dos OAs estão presentes, haja vista que a probabilidade de ocorrência dos valores 0 ou 1 é de 0,5.

Este método de inicialização aleatória de soluções se mostrou ineficiente, pois, como apontado, em cada solução gerada, cerca de metade dos OAs de todo o repositório estará presente e, como cada OA geralmente cobre mais que um conceito, cada solução irá cobrir praticamente todos os conceitos da seção de aprendizagem. Neste sentido, por conter praticamente metade de todo o repositório de OAs, o custo de cada solução gerada por este método é muito alto. Dessa maneira, do ponto de vista do problema abordado, todos os indivíduos da população inicial gerados pelo método aleatório, possuem a mesma característica: a cobertura de quase todos os conceitos e um custo de solução elevado.

Tal característica, observada em testes preliminares, inviabilizou a utilização deste método para a geração de soluções com qualidade e diversidade desejáveis. Diante disso, foram propostos e implementados dois métodos de inicialização da população, conforme explicitado a seguir.

O primeiro método de geração da população inicial, denominado de Inicialização por Conceitos (Algoritmo 1), foca na cobertura de conceitos de cada solução. A motivação deste método é gerar uma população inicial com soluções que possuam as mais diversas quantidades de conceitos cobertos. Nesse sentido, é delimitado, para cada solução, o número de conceitos que ela deve cobrir. Este valor é determinado a partir do número de conceitos que não são dependentes de outros. A seguir, discutem-se os principais passos do método de Inicialização por Conceitos.

Considere uma seção de aprendizagem W com n conceitos e uma população inicial PI , de m soluções, que se queira gerar. Inicialmente, obtém-se o total de conceitos não-dependentes de outros, de acordo com o *Design* Instrucional da seção de aprendizagem. Este valor é armazenado em n' , conforme linha 2. Para cada uma das m soluções, é gerado um número aleatório t_p entre 1 e n' , que representa o número mínimo de conceitos cobertos pela solução, conforme linha 7. Em seguida, o laço das linhas 10 a 14 seleciona t_p conceitos não dependentes que comporão a solução.

É importante destacar que na linha 11, que ao se escolher um novo conceito, é verificado se o mesmo já fora escolhido para aquela solução. Caso afirmativo, uma nova escolha é realizada, de modo a garantir que distintos t_p conceitos sejam cobertos. Nessa etapa também não são selecionados conceitos que dependam de outros, com o intuito de reduzir o número de violações de restrições em cada solução gerada.

Na linha 12, seleciona-se aleatoriamente um determinado OA para cobrir o conceito selecionado na linha 11. É importante notar que, ao se selecionar aleatoriamente um determinado OA para cobrir um conceito, tal OA pode cobrir também outros conceitos, inclusive que não tenham sido selecionados previamente, e nem sejam selecionados posteriormente, podendo, inclusive, serem dependentes de outros conceitos que não estarão na solução. Desse modo, o que se tem é a garantia de que serão cobertos no mínimo - e não exatamente - o número aleatório de t_p conceitos definidos para aquela solução.

Uma vez selecionados os OAs para cobrirem todos os conceitos da solução, as linhas 15 e

16 adicionam esta solução a população inicial PI . Todo este procedimento é repetido para cada um das m soluções de PI , conforme indicado nas linhas 4 a 17.

Algorithm 1 Algoritmo Inicialização por Conceitos

Require: m (Tamanho da População), n (conceitos do curso), r (repositório dos OAs)

```

1:  $PI \leftarrow \emptyset$ ;
2:  $n' \leftarrow \text{Total Conceitos Não-Dependentes}(n)$ ;
3:  $i \leftarrow 0$ ;
4: repeat
5:    $i \leftarrow i + 1$ ;
6:    $P \leftarrow \emptyset$ ;
7:    $t_p \leftarrow \text{Tamanho Aleatório de Cobertura da Solução}(n')$ ;
8:    $j \leftarrow 0$ ;
9:    $c[] \leftarrow 0$ ;
10:  while  $j \leq t_p$  do
11:     $c[] \leftarrow \text{Escolhe Novo Conceito Não-dependente}(n, c[])$ ;
12:     $s[] \leftarrow \text{Seleção Aleatória de OA}(c[j], r)$ ;
13:     $j \leftarrow j + 1$ ;
14:  end while
15:   $P \leftarrow \text{Adiciona Solução}(s[])$ ;
16:   $PI \leftarrow PI \cup P$ ;
17: until  $i \leq m$ ;
18: return  $PI$ ;

```

O outro método de geração da população inicial, denominado de Inicialização por OAs (Algoritmo 2), utiliza a estratégia de selecionar aleatoriamente um conjunto de OAs para compor a solução, independentemente de quais conceitos eventualmente sejam cobertos. Esta é uma estratégia similar ao modo de inicialização aleatória do *framework* MOEA, todavia, na inicialização do MOEA, cerca de metade de todos os OAs do repositório, em média, estarão presentes em cada solução. Na abordagem ora proposta, o número de OAs em cada solução é limitado superiormente por um décimo do total do número de OAs no problema abordado. A seguir, discutem-se os principais passos do método de Inicialização por OAs.

Considere uma seção de aprendizagem W com n OAs e uma população inicial PI , de m soluções, que se queira gerar. A partir dos n OAs do repositório (linha 2), é determinado o número máximo n' de OAs que um solução poderá ter (linha 3) ao ser inicializada. Esse cálculo é determinado pela décima parte dos n OAs, arredondado para cima para o número inteiro mais próximo (teto), quando o referido valor é fracionado. Em seguida, para cada solução da população, é sorteado um valor entre 1 e n' , o qual representa a quantidade t_p de OAs que aquela solução possuirá (linha 8). Em seguida, no laço das linhas 11 a 14 são selecionados aleatoriamente os t_p OAs que comporão aquela solução.

Por fim, as linhas 15 e 16 adicionam a solução a população inicial PI . Todo este procedimento é repetido para cada um das m soluções de PI , conforme indicado nas linhas 4 a 17.

A partir de testes iniciais, notou-se que os métodos de inicialização mais simples e com rápida carga de busca não foram eficientes na geração de um conjunto inicial de soluções viáveis.

Algorithm 2 Algoritmo Inicialização por OAs**Require:** m (Tamanho da População), r (repositório dos OAs)

```

1:  $PI \leftarrow \emptyset$ ;
2:  $n \leftarrow$  Total de OAs do Repositório( $r$ );
3:  $n' \leftarrow \lceil \frac{n}{10} \rceil$ ;
4:  $i \leftarrow 0$ ;
5: repeat
6:    $i \leftarrow i + 1$ ;
7:    $P \leftarrow \emptyset$ ;
8:    $t_p \leftarrow$  Número de OAs da Solução( $n'$ );
9:    $j \leftarrow 0$ ;
10:   $v[] \leftarrow 0$ ;
11:  while  $j \leq t_p$  do
12:     $v[] \leftarrow$  Seleção Aleatória de Novo OA( $r$ );
13:     $j \leftarrow j + 1$ ;
14:  end while
15:   $P \leftarrow$  Adiciona Solução( $v[]$ );
16:   $PI \leftarrow PI \cup P$ ;
17: until  $i \leq m$ ;
18: return  $PI$ ;

```

Por esse motivo, foram empregados métodos mais robustos e custosos, detalhados nesta seção.

4.3 Parametrização e execução do NSGA-II

Para a parametrização do NSGA-II, realizaram-se testes preliminares com o objetivo de se observar o seu comportamento no problema modelado. Neste sentido, inicialmente utilizaram-se os parâmetros *default* no NSGA-II utilizados na própria documentação do MOEA. A partir do comportamento da técnica nos testes preliminares, os parâmetros foram divididos em dois grupos: aqueles que sofreram alterações nos testes finais e aqueles que foram mantidos com valor *default*, por influenciarem positivamente nas soluções obtidas.

Logo, os parâmetros que sofreram alterações foram o número de gerações, o tamanho da população inicial, e o método empregado em sua geração. Neste sentido, decidiu-se, após testes preliminares, reduzir o número de gerações, por não se ter verificado considerável influência desse parâmetro na qualidade das soluções. Por sua vez, o tamanho da população inicial foi aumentado, pelo fato de soluções com populações iniciais maiores terem apresentado cardinalidade maior em algumas das execuções dos testes preliminares.

Em relação aos métodos de inicialização da população, decidiu-se por não se utilizar o método de inicialização aleatório do MOEA, uma vez que a qualidade e diversidade das soluções obtidas pelo NSGA-II foi muito inferior em relação aos métodos de geração da população inicial propostos nos algoritmos 1 e 2, explicados na seção 4.2.

Por sua vez, os outros parâmetros, foram mantidos com seus valores *default*, a saber: taxa de cruzamento igual a 1, e taxa de mutação de $\frac{1}{n}$, sendo n o número de variáveis da população, e

método de seleção de indivíduos por torneio de tamanho 2.

A Tabela 3 apresenta as configurações adotadas para os testes realizados. Cada teste foi executado cinco vezes para cada uma das instâncias propostas (G2, G3 e F3), apresentadas na seção 4. Na tabela, o algoritmo 1 é denominado por “Seleção por Conceitos” e o algoritmo 2, por sua vez, por “Seleção por OAs”.

Tabela 3: Configurações do NSGA-II para os testes realizados.

Teste	Método de Inicialização	População	Número de Gerações
#1	Inicialização por Conceitos	150	2000
#2	Inicialização por OAs	150	2000
#3	Inicialização por Conceitos	300	1000
#4	Inicialização por OAs	300	1000

5 Resultados Experimentais

Cada um dos testes foi executado 5 vezes para cada uma das instâncias. Com esse total de amostras foi possível calcular os valores das métricas de cada uma das 4 configurações de testes. Os melhores resultados para cada métrica se encontram destacados em negrito na Tabela 4 e na Tabela 5. Para simplificar a notação, adota-se a sigla T1 para se referenciar ao Teste #1, T2 para se referenciar ao Teste #2, e assim por diante.

A Tabela 4 apresenta a média e o desvio-padrão dos resultados de tempo de execução, em milissegundos, de cada um dos testes para as instâncias consideradas, com o menor tempo para cada instância destacado em negrito. Percebe-se que T1 e T3, que utilizaram Inicialização por Conceitos (algoritmo 1), despenderam um tempo maior que os testes que utilizaram Inicialização por OAs com o (algoritmo 2). Mesmo ao se analisar isoladamente T1 e T3, percebe-se a grande influência do método de inicialização da população sobre o tempo de execução total de cada teste. De fato, T3 requereu um maior tempo de execução que T1, mesmo utilizando metade do número de gerações. Tal fato se justifica uma vez que T3 utiliza o dobro da população utilizada em T1.

Tabela 4: Média e desvio-padrão do tempo de execução dos testes, em milissegundos.

I	T1		T2		T3		T4	
	Média	DP	Média	DP	Média	DP	Média	DP
F3	103.451	6.835,25	26.228	1.113,34	179.755	11.285,72	23.121	1.521,79
G2	126.399	8.775,90	36.309	1.040,16	201.404	8.210,91	30.206	2.072,29
G3	113.289	16.443,37	32.860	2.277,98	186.670	8.140,93	28.089	903,31

A Tabela 5 apresenta a média e o desvio-padrão dos resultados de cardinalidade das soluções das 5 execuções para cada teste considerado. Os resultados com maior cardinalidade estão destacados em negrito. Percebe-se que os testes com maior população inicial (T3 e T4) obtive-

ram melhor desempenho, sendo que T4 se saiu melhor nas instâncias G3 e F3, cuja matrizes de coberturas são mais densas.

Tabela 5: Média e desvio-padrão da cardinalidade das soluções.

Instância	T1		T2		T3		T4	
	Média	DP	Média	DP	Média	DP	Média	DP
F3	10	0,84	16	4,44	16	1,58	19	1,92
G2	9	2	6	2,97	14	1,52	9	1,22
G3	6	2,07	8	2,07	9	1,3	10	2,59

O Gráfico 1 apresenta uma das execuções para a instância F3. Nela, é possível verificar o menor número de soluções em T1 (pontos em vermelho) em relação aos outros testes. T1 possui o método geração da população diferente de T2 e T4, e a metade da população inicial de T3.

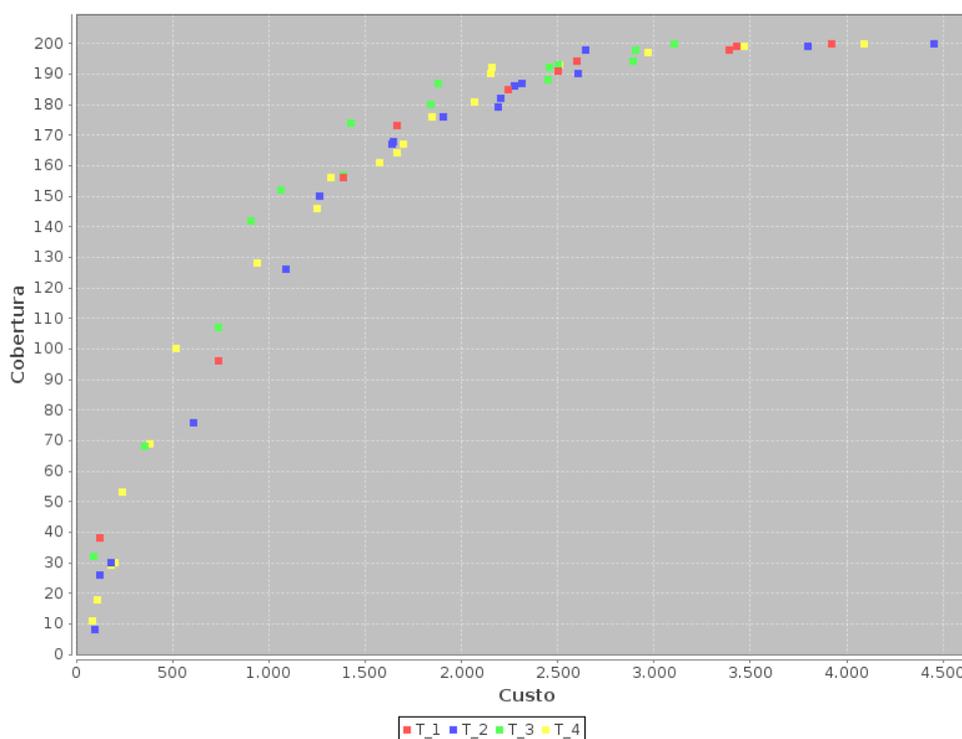


Gráfico 1: Soluções de uma execução dos testes na instância F3. Fonte: próprio autor..

O hipervolume também foi uma métrica utilizada para avaliação das soluções, pois é muito útil para comparar o desempenho de dois conjuntos de soluções. Tal métrica calcula o volume do espaço dominado por um conjunto de soluções em relação a um determinado ponto de referência W , considerando o valor obtido nas duas funções-objetivo, conforme exemplificado na Figura 2. Quanto melhores os resultados do conjunto de soluções, mais distantes eles estarão do ponto de referência e portanto maior será o volume dominado. Os resultados para tal métrica são apresentados na Tabela 6.

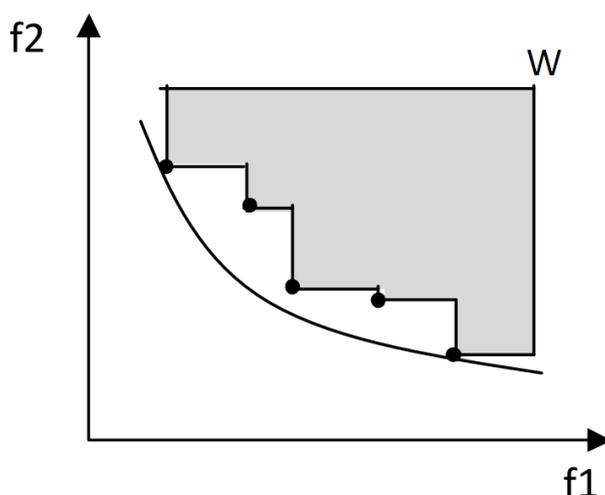


Figura 2: Cálculo do Hipervolume de uma solução multiobjetivo de minimização das funções F1 e F2. Fonte: (Assis, 2013).

Tabela 6: Média e desvio-padrão do hipervolume das soluções.

Instância	T1		T2		T3		T4	
	Média	DP	Média	DP	Média	DP	Média	DP
F3	0,79	0,29	0,93	0,05	0,82	0,07	0,95	0,02
G2	0,80	0,37	0,80	0,36	0,82	0,33	0,98	0
G3	0,57	0,45	0,47	0,43	0,84	0,19	0,95	0,03

O T4 apresentou os melhores valores de hipervolume para todas as instâncias. Isso demonstra que a maior cardinalidade que T3 obteve na instância G2 (Tabela 5) não se traduziu em qualidade das soluções. Ainda com relação ao hipervolume, nota-se o alto desvio-padrão dos testes T1 e T2, principalmente na instância G3, que possui matriz de cobertura menos esparsa e um número alto de dependências entre conceitos. Essa discrepância se dá pelo fato de algumas execuções desses testes terem obtido um pequeno número de soluções e, por conseguinte, um menor espaço dominado.

O Gráfico 2 apresenta uma das execuções para G2. Nela é possível notar que, apesar de mais numerosas, as soluções de T3 (em verde) encontram-se concentradas majoritariamente em uma única área do gráfico, com altos valores de cobertura e custo. Por outro lado, as soluções de T4 (em amarelo), embora menos numerosas, estão mais bem distribuídas ao longo do que seria a fronteira de Pareto, sobretudo em valores intermediários de cobertura, como 30 e 130, que oferecem diferentes configurações em termos de custo e conceitos cobertos.

As soluções obtidas também foram avaliadas em relação a métrica ε aditivo, ou ε_+ . Essa métrica calcula o menor valor necessário que o conjunto de soluções gerado precisa ser transladado para dominar um determinado conjunto de referência. Nesse caso, o conjunto de referência é formado pelas soluções não dominadas de todos os conjuntos gerados. Valores baixos desse indicador apontam para uma boa diversidade de soluções e boa proximidade entre a solução e o conjunto de referência. A Tabela 7 os resultados obtidos para a referida métrica.

O T4 também obteve melhor desempenho em relação ao ε_+ , nas três instâncias consideradas. Neste sentido, nota-se que valores para ε_+ de T4 são consideravelmente menores que os demais

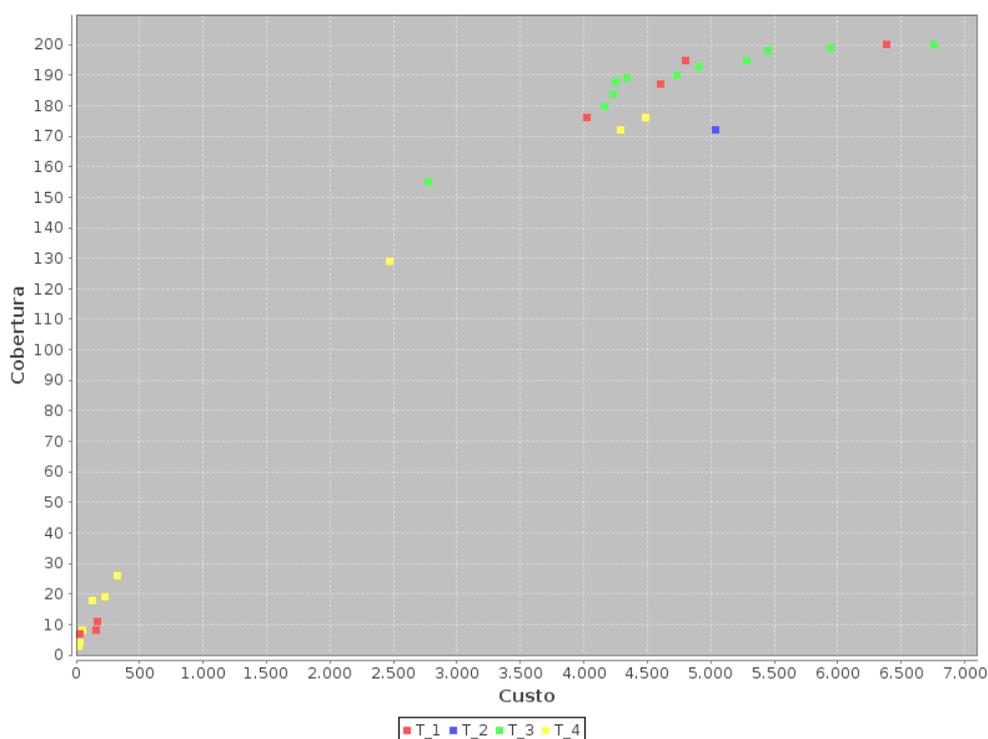


Gráfico 2: Soluções de uma execução dos testes na instância G2. Fonte: próprio autor..

testes, principalmente para as instâncias G2 e G3, que possuem um maior número de dependências entre os conceitos. Baixos valores do indicador ϵ_+ aditivo indicam que a solução de T4 está mais próxima do conjunto de melhores soluções encontradas, a qual engloba todas as soluções não-dominadas obtidas em todos os testes.

Tabela 7: Média e desvio-padrão do indicador ϵ_+ das soluções.

Instância	T1		T2		T3		T4	
	Média	DP	Média	DP	Média	DP	Média	DP
F3	19,27	29,54	5,51	4,14	15,40	7,37	2,90	2,46
G2	97,71	196,45	121,07	244,22	63,02	136,09	1,79	1,25
G3	28,27	31,33	35,20	29,42	9,29	13,26	2,00	1,80

O Gráfico 3 apresenta uma das execuções para G3. Nela é possível perceber que as soluções de T4 (em amarelo), embora ligeiramente dominadas por soluções de outros testes, estão um pouco mais distribuídas ao longo do espaço de possíveis soluções. Isso faz com que este conjunto de soluções precise ser “pouco” deslocado para dominar o conjunto de referência, o que reflete o seu baixo valor do indicador ϵ_+ .

Ademais, ao se analisar a Tabela 5, com o resultado de cardinalidade das soluções, bem como ao se comparar o gráfico de soluções de F3 (Gráfico 1) com os gráficos de soluções de G2 (Gráfico 2) e G3 (Gráfico 3), é possível notar que houve diminuição do número de soluções obtidas pelo NSGA-II nas instâncias com maior número de dependências (G2 e G3). É possível notar que tal decréscimo se acentua principalmente nas soluções com cobertura média, isto é, aquelas que

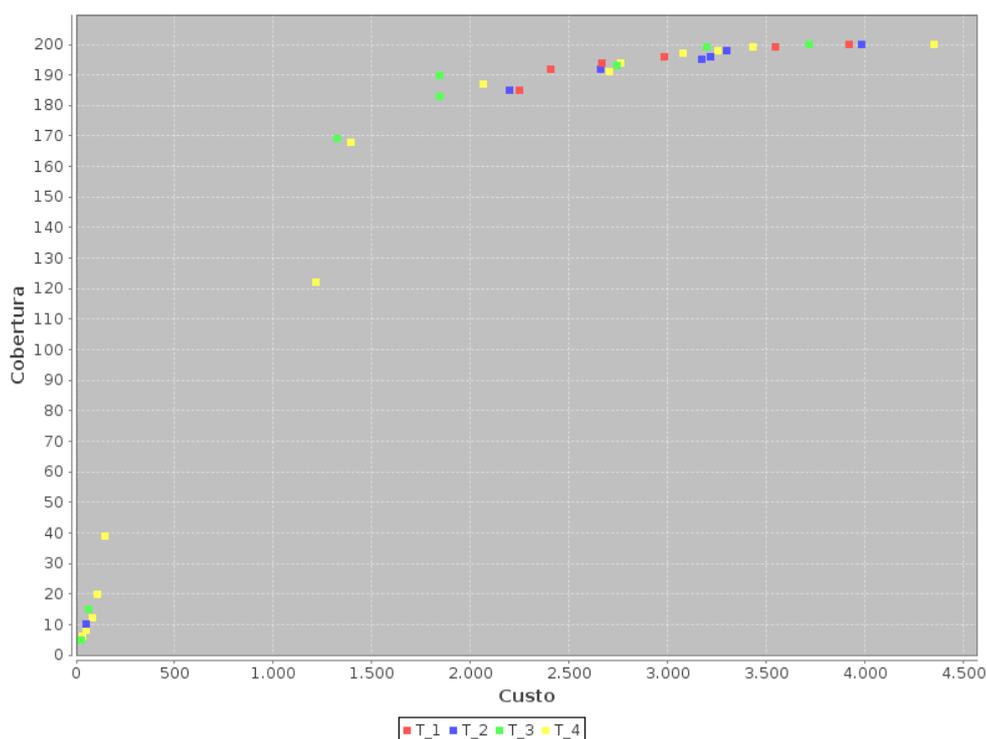


Gráfico 3: Soluções de uma execução dos testes na instância G3. Fonte: próprio autor..

cobrem entre 40 e 160 conceitos.

A existência de muitas dependências entre conceitos pode ter feito com que a maioria dos indivíduos da população inicial com coberturas médias não respeitasse pelo menos alguma das restrições do *Design* Instrucional. Com isso, formaram-se várias soluções inicialmente inviáveis que não tiveram sua inviabilidade revertida ao longo da execução do NSGA-II, acabando por serem descartadas. Tais restrições não afetaram de modo tão contundente as soluções com altos valores de cobertura, as quais atendem todas as dependências exigidas. Também não prejudicaram a geração de soluções com baixa cobertura, pelo fato dessas possivelmente serem formadas apenas por conceitos que não dependam de outros.

Os resultados obtidos a partir dos experimentos realizados indicam a possibilidade de utilização do NSGA-II para gerar diferentes configurações conceituais de uma seção de aprendizagem para um estudante, numa proposta de *Design* Instrucional contextualizado, na qual existem relações de dependências entre conceitos que devem ser respeitadas. No entanto, para haver uma diversidade maior de soluções, sobretudo naquelas com cobertura média, faz-se necessário métodos de inicialização da população que demandem maior custo computacional, de modo a garantir que todas as soluções inicialmente geradas sejam viáveis. Isso se torna mais imprescindível em problemas com um número maior de dependências entre conceitos.

6 Conclusão e Perspectivas Futuras

Este trabalho expôs o problema de recomendação de Objetos de Aprendizagem sob o ponto de vista de otimização multiobjetivo, para uma seção de aprendizagem cujo *Design* Instrucional Contextualizado permite que nem todos os conceitos inicialmente concebidos precisem ser cobertos, ressaltadas as relações de dependência existentes entre eles.

Os objetivos de otimização considerados foram o custo da solução e a sua cobertura. O custo da solução é determinado pela soma do custo de cada Objeto de Aprendizagem que a compõe. Por sua vez, o custo de cada Objeto de Aprendizagem é variável, dependendo da sua adequabilidade em relação ao Estilo de Aprendizagem do aluno, considerando ainda a avaliação daquele Objeto de Aprendizagem por outros estudantes com Estilo de Aprendizagem semelhante. A cobertura é calculada pela quantidade de conceitos do curso ou seção de aprendizagem almejada que a solução composta pelos OAs selecionados cobre, haja vista que a obrigatoriedade de se cobrir todos os conceitos foi relaxada, embora haja a necessidade da presença de um determinado conceito em uma solução caso haja outro conceito que dependa dele e que também esteja presente na solução.

As soluções geradas para o problema se deram a partir de instâncias geradas artificialmente, sendo utilizado o algoritmo NSGA-II para tal, implementado no *framework* MOEA. Distintos números de gerações e tamanhos de população inicial foram empregados. Foram utilizados ainda dois algoritmos de geração da população inicial para o NSGA-II. Um deles cria soluções a partir de valores aleatórios mínimos de cobertura que são estabelecidos. O outro método seleciona aleatoriamente um OA do repositório para fazer parte de uma solução, cujo número de OAs também é definido de modo randômico.

A partir dos resultados encontrados, conclui-se que o NSGA-II é capaz de ser aplicado no problema proposto, com boa diversidade de soluções em instâncias com poucas dependências estabelecidas entre conceitos. No entanto, para os cursos em que a quantidade de dependências é maior verificou-se uma diminuição na diversidade de soluções, sobretudo aquelas com valores médios de cobertura. Mostra-se necessário, portanto, o emprego de novas estratégias para gerar um conjunto de soluções mais diverso.

De todo modo, foram alcançados os objetivos propostos de apresentar uma abordagem multiobjetivo para o problema de recomendação de Objetos de Aprendizagem, bem como de implementar uma técnica heurística capaz de obter soluções para o mesmo.

Além disso, apresentou-se um modelo de Sistema de Recomendação que possa contemplar essa proposta e servir de ponto de partida para futuras pesquisas explorarem essa temática nos mais diferentes contextos educacionais. Ademais, a heurística implementada apresenta boas perspectivas para integrar um mecanismo de recomendação a ser utilizado em uma situação real pela comunidade de pesquisa na área educacional.

Há de se ressaltar também a perspectiva adotada para que o *Design* Instrucional do curso esteja relacionado ao processo de recomendação. De fato, a recomendação de OAs tem a finalidade de propiciar e auxiliar o estudante no aprendizado, o qual não deve estar dissociado do planejamento e metodologia necessários a esse processo, o que se dá a partir do DI. A busca por essa integração entre as ferramentas de TIC e as metodologias pedagógicas deve ser um contínuo esforço para um processo de ensino-aprendizagem mais efetivo.

Para trabalhos futuros, destaca-se a aplicação do problema proposto em um contexto real, que pode se dar a partir da construção de um repositório de objetos de aprendizagem a partir de conteúdos educacionais que estejam disponíveis em outros repositórios como a Wikipédia e o Youtube. Para isto, faz-se necessário a implementação do sistema de recomendação, conforme estrutura apresentada na seção 3.2. De fato, para validar a proposta de recomendação apresentada, é fundamental sua aplicação em um contexto educacional real.

Além disso, é preciso ainda testar o desempenho de outros algoritmos além do NSGA-II, tais como ϵ -NSGAI (Kollat & Reed, 2005), NSGAI (Deb & Jain, 2014) e IBEA (Zitzler & Künzli, 2004). O desempenho entre eles poderá ser melhor comparado se houver uma quantidade maior de testes executados, de forma a se obter uma amostra maior, e os resultados das métricas possam ser avaliados com análise de significância estatística. Outra ação importante é verificar a possibilidade de utilização de métodos exatos para resolução das instâncias testadas para o problema, de modo a verificar quão próximas da fronteira de Pareto Ótima estão as soluções geradas pela heurística implementada. Além disso, faz-se necessário a criação de métodos de geração da população inicial que, embora mais robustos e custosos computacionalmente, assegurem que as soluções iniciais geradas sejam viáveis. Isso permitiria maior diversidade de soluções quando o número de restrições do problema - nesse caso, dependências entre conceitos - for grande.

Uma outra possibilidade a ser explorada, no domínio do problema proposto, é garantir que os conceitos da seção de aprendizagem sejam ordenados, de modo a se ter uma sequência de aprendizagem, na qual o conjunto de OAs escolhidos respeitem essa ordenação. Essa é uma possibilidade que, embora traga maior complexidade para lidar com o problema, mostra-se pedagogicamente mais assertiva. Deve-se ainda investigar diferentes aspectos relacionados ao *design* instrucional dos cursos, que não apenas os conceitos e suas relações de dependência, os quais possam ser trabalhados e explorados numa perspectiva de otimização multiobjetivo.

Referências

- ABED, A. B. d. E. a. D. (2019). *Censo EAD.BR: relatório analítico da aprendizagem a distância no Brasil* (Relatório). São Paulo: Associação Brasileira de Educação a Distância. Recuperado em 2022-01-15 de http://abed.org.br/arquivos/CENSO_DIGITAL_EAD_2018_PORTUGUES.pdf.
- ADL, A. D. L. (2022). *SCORM - Sharable Content Object Reference Model* (Relatório). Advanced Distributed Learning Initiative. Recuperado em 2022-01-15 de <https://adlnet.gov/projects/scorm/>.
- Apps, B. o. (2020). *YouTube Revenue and Usage Statistics (2020) - Business of Apps*. Recuperado em 2020-07-27, de <https://www.businessofapps.com/data/youtube-statistics/>
- Assis, L. P. d. (2013). *Investigação de metaheurísticas aplicadas ao problema de roteamento de veículos multiobjetivo com coleta opcional*. Tese de doutorado, Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte. Recuperado em 2022-01-15, de <http://hdl.handle.net/1843/BUBD-9VKG9T>
- Bourkougou, O., & El Bachari, E. (2018, aug). Toward a Hybrid Recommender System for E-learning Personalization Based on Data Mining Techniques. *JOIV : International Journal on Informatics Visualization*, 2(4), 271. Recuperado em 2022-01-05, de <https://joiv.org/>

- [index.php/joiv/article/view/158](#) doi: [10.30630/joiv.2.4.158](#) [GS Search]
- Cerqueira, T. C. S. (2000). *Estilos de aprendizagem em universitários*. Tese de doutorado, Faculdade de Educação, Universidade Estadual de Campinas, Campinas. doi: [10.47749/T/UNICAMP.2000.184512](#). Recuperado em 2022-01-05, de <https://acervus.unicamp.br/index.html>
- Clark, R. C., & Mayer, R. E. (2016). *E-learning and the science of instruction: Proven guidelines for consumers and designers of multimedia learning*. Hoboken, NJ, USA: John Wiley & Sons. [GS Search]
- Cury, H. N. (2000). Estilos de Aprendizagem de Alunos de Engenharia. Em *Xxviii congresso brasileiro de ensino de engenharia*. Ouro Preto. Recuperado em 2022-01-05, de <http://www.abenge.org.br/cobenge/legado/arquivos/19/artigos/169.PDF> [GS Search]
- DCM, D. C. M. I. (2020). *DCMI Metadata Terms* (Relatório). Dublin Core Metadata Innovation. Recuperado em 2022-01-05, de <http://www.dublincore.org/documents/dcmi-terms/>
- Deb, K., Agrawal, S., Pratap, A., & Meyarivan, T. (2000). A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: NSGA-II. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 1917, 849–858. Recuperado em 2022-01-05, de https://link.springer.com/chapter/10.1007/3-540-45356-3_83 doi: [10.1007/3-540-45356-3_83](#) [GS Search]
- Deb, K., & Jain, H. (2014). An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, Part I: Solving problems with box constraints. *IEEE Transactions on Evolutionary Computation*, 18(4), 577–601. Recuperado em 2022-01-05, de <https://ieeexplore.ieee.org/abstract/document/6600851> doi: [10.1109/TEVC.2013.2281535](#) [GS Search]
- De Medio, C., Gasparetti, F., Limongelli, C., & Sciarrone, F. (2017). Automatic extraction and sequencing of wikipedia pages for smart course building. Em *21st international conference information visualisation (iv)* (pp. 378–383). Recuperado em 2022-01-05, de <https://ieeexplore.ieee.org/abstract/document/8108000> doi: [10.1109/iv.2017.75](#) [GS Search]
- Dutra, R. L. d. S., Tarouco, L. M. R., & Passerino, L. (2011, feb). Utilização de Objetos de Aprendizagem Abertos SCORM para dar suporte à Avaliação Formativa. *Revista Brasileira de Informática na Educação*, 18(03), 59. Recuperado em 2022-01-05, de <http://br-ie.org/pub/index.php/rbie/article/view/1280> doi: [10.5753/rbie.2010.18.03.59](#) [GS Search]
- Felder, R. M., & Silverman, L. K. (1988). Learning and teaching styles in engineering education. *Engineering education*, 78(7), 674–681. Recuperado em 2022-01-05, de <https://www.academia.edu/download/31039406/LS-1988.pdf> [GS Search]
- Felder, R. M., & Spurlin, J. (2005). Applications, reliability and validity of the index of learning styles. *International journal of engineering education*, 21(1), 103–112. Recuperado em 2022-01-05, de [https://wss.apan.org/jko/mls/Learning%20Content/ILS_Validation\(IJEE\).pdf](https://wss.apan.org/jko/mls/Learning%20Content/ILS_Validation(IJEE).pdf) [GS Search]
- Filatro, A., & Cairo, S. (2015). *Produção de Conteúdos Educacionais*. São Paulo, São Paulo: Saraiva Educação SA. [GS Search]
- Filatro, A., & Piconez, S. C. B. (2004). Design instrucional contextualizado. *São Paulo: Senac*, 27–29. Recuperado em 2022-01-05, de http://www.miniweb.com.br/atualidade/Tecnologia/Artigos/design_instrucional.pdf [GS Search]
- Filatro, A. C. (2008). *Learning design como fundamentação teórico-prática para o design instru-*

- cional contextualizado*. Tese de doutorado, Faculdade de Educação, Universidade de São Paulo, São Paulo. doi: [10.11606/T.48.2008.tde-12062008-142556](https://doi.org/10.11606/T.48.2008.tde-12062008-142556). Recuperado em 2022-01-05, de <http://www.teses.usp.br/teses/disponiveis/48/48134/tde-12062008-142556/>
- Gill, L., & Dalgarno, B. (2017, ago). A qualitative analysis of pre-service primary school teachers' TPACK development over the four years of their teacher preparation programme. *Technology, Pedagogy and Education*, 26(4), 439–456. Recuperado em 2022-01-05, de <https://www.tandfonline.com/doi/abs/10.1080/1475939X.2017.1287124> doi: [10.1080/1475939X.2017.1287124](https://doi.org/10.1080/1475939X.2017.1287124) [GS Search]
- Grasha, A. F. (1996). *Teaching with style: A practical guide to enhancing learning by understanding teaching and learning styles*. Pittsburg, PA, USA: Alliance publishers. [GS Search]
- Hassan, M., & Hamada, M. (2016, dez). Enhancing learning objects recommendation using multi-criteria recommender systems. Em *2016 IEEE International Conference on Teaching, Assessment, and Learning for Engineering (TALe)* (pp. 62–64). IEEE. Recuperado em 2022-01-05, de <http://ieeexplore.ieee.org/document/7851771/> doi: [10.1109/TALe.2016.7851771](https://doi.org/10.1109/TALe.2016.7851771) [GS Search]
- IEEE, S. A. (2020). *IEEE Standard for Learning Object Metadata* (Relatório). IEEE Standards Association. Recuperado em 2022-01-05, de <https://standards.ieee.org/ieee/1484.12.1/7699/>
- IMS, G. L. C. (2019). *IMS Global Learning Consortium*. Recuperado em 2019-04-09, de <https://www.imsglobal.org/>
- INEP, I. N. d. E. e. P. E. A. T. (2022). *Censo da Educação Superior 2020: notas estatísticas* (Relatório). Brasília: BRASIL. Recuperado em 2022-01-05, de https://download.inep.gov.br/publicacoes/institucionais/estatisticas_e_indicadores/notas_estatisticas_censo_da_educacao_superior_2020.pdf
- Jacobsohn, L. V. (2003). *A contribuição do e-learning no desenvolvimento de competências do administrador: considerando o estilo de aprendizagem do aluno de graduação*. Dissertação de mestrado, Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, São Paulo. doi: [10.11606/D.12.2003.tde-06012004-133938](https://doi.org/10.11606/D.12.2003.tde-06012004-133938). Recuperado em 2022-01-05, de <http://www.teses.usp.br/teses/disponiveis/12/12139/tde-06012004-133938/>
- Júnior, C. B., & Dorça, F. (2018, nov). Uma Abordagem para a Criação e Recomendação de Objetos de Aprendizagem usando um Algoritmo Genético, Tecnologias da Web Semântica e uma Ontologia. Em *Anais do xxix simpósio brasileiro de informática na educação (sbie 2018)* (Vol. 1, pp. 1533–1542). Sociedade Brasileira de Computação - SBC. Recuperado em 2022-01-05, de <https://br-ie.org/pub/index.php/sbie/article/view/8114> doi: [10.5753/c-bie.sbie.2018.1533](https://doi.org/10.5753/c-bie.sbie.2018.1533) [GS Search]
- Katarya, R., & Verma, O. P. (2018, set). Recommender system with grey wolf optimizer and FCM. *Neural Computing and Applications*, 30(5), 1679–1687. Recuperado em 2022-01-05, de <http://link.springer.com/10.1007/s00521-016-2817-3> doi: [10.1007/s00521-016-2817-3](https://doi.org/10.1007/s00521-016-2817-3) [GS Search]
- Kollat, J. B., & Reed, P. M. (2005). Comparison of Multi-Objective Evolutionary Algorithms for Long-Term Monitoring Design. Em *Proceedings of the 2005 world water and environmental resources congress* (pp. 1–11). American Society of Civil Engineers. Recuperado em 2022-01-05, de <https://ascelibrary.org/doi/10.1061/40792%28173%29359> doi: [10.1061/40792\(173\)359](https://doi.org/10.1061/40792(173)359) [GS Search]
- MOEA, F. (2020). *MOEA Framework: a Free and Open Source Java Framework for Multiobjec-*

- tive Optimization*. Recuperado em 2020-07-31, de <http://moeaframework.org/>
- Moreira, M. M., Araújo, , Torres, A. C. U., , Joye, A. L. d. M. M., ... Borges, H. (2019). Ensaio teórico sobre o design instrucional contextualizado e as estratégias didáticas na elaboração de material didático para EAD online. *EmRede - Revista de Educação a Distância*, 6(1), 43–52. Recuperado em 2022-01-05, de <http://www.repositorio.ufc.br/handle/riufc/44055> doi: 10.53628/emrede.v6.1.389 [GS Search]
- Murad, H., & Yang, L. (2018, out). Personalized e-learning recommender system using multimedia data. *International Journal of Advanced Computer Science and Applications*, 9(9), 565–567. Recuperado em 2022-01-05, de <https://pure.port.ac.uk/ws/portalfiles/portal/13244076/> doi: 10.14569/ijacsa.2018.090971 [GS Search]
- Nifoci, R. E. M. (2013). *Conhecimentos revelados por professores em um curso de formação continuada para a utilização de objetos de aprendizagem*. Dissertação de mestrado, Programa de Estudos Pós-Graduados em Educação Matemática, Pontifícia Universidade Católica de São Paulo, São Paulo. Recuperado em 2022-01-05, de <https://tede2.pucsp.br/handle/handle/10970>
- Pireva, K., & Kefalas, P. (2017, out). A recommender system based on hierarchical clustering for cloud e-learning. *Studies in Computational Intelligence*, 737, 235–245. Recuperado em 2022-01-05, de https://link.springer.com/chapter/10.1007/978-3-319-66379-1_21 doi: 10.1007/978-3-319-66379-1_21 [GS Search]
- Reigeluth, C. M. (1999). The elaboration theory: Guidance for scope and sequence decisions. Em *Instructional-design theories and models: A new paradigm of instructional theory* (Vol. 2, pp. 425–453). Mahwah, NJ, EUA: Lawrence Erlbaum Associates. [G Search]
- Rodrigues, P. A. A., Rodrigues, L. M., & Dias, L. C. M. (2014, jul). Do Design Instrucional Fixo ao Contextualizado: Análise de um Curso de Pós-Graduação Oferecido na Modalidade a Distância. Em *Sied:enped - simpósio internacional de educação a distância e encontro de pesquisadores em educação a distância*. Recuperado em 2022-01-05, de <http://www.sied-enped2014.ead.ufscar.br/ojs/index.php/2014/article/view/761> [GS Search]
- Santos, M., Andrade, F., Silva, J. M. C. d., & Imran, H. (2016, jul). Learning Object Recommendation System Evaluation. Em *2016 IEEE 16th international conference on advanced learning technologies (icalt)* (pp. 412–413). IEEE. Recuperado em 2022-01-05, de <http://ieeexplore.ieee.org/document/7757010/> doi: 10.1109/ICALT.2016.89 [GS Search]
- Schmitt, C. d. S., & Domingues, M. J. C. d. S. (2016, jul). Estilos de aprendizagem: um estudo comparativo. *Avaliação: Revista da Avaliação da Educação Superior (Campinas)*, 21(2), 361–386. Recuperado em 2022-01-05, de <http://dx.doi.org/10.1590/S1414-40772016000200004>
- Sergis, S., & Sampson, D. G. (2016, jan). Learning Object Recommendations for Teachers Based On Elicited ICT Competence Profiles. *IEEE Transactions on Learning Technologies*, 9(1), 67–80. Recuperado em 2022-01-05, de <http://ieeexplore.ieee.org/document/7109912/> doi: 10.1109/TLT.2015.2434824 [GS Search]
- Silva, D. M. d. (2006). *O impacto dos estilos de aprendizagem no ensino de contabilidade na FEA-RP/USP*. Dissertação de mestrado, Faculdade de Economia, Administração e Contabilidade de Ribeirão Preto, Universidade de São Paulo, Ribeirão Preto. doi: 10.11606/D.96.2006.tde-24012007-152550. Recuperado em 2022-01-05, de <http://www.teses.usp.br/teses/disponiveis/96/96133/tde-24012007-152550/>
- Soloman, B. A., & Felder, R. M. (2005). Index of learning styles questionnaire. *NC State Uni-*

- versity., 70. Recuperado em 2022-01-05, de <https://www.webtools.ncsu.edu/learningstyles/> [GS Search]
- Venkatesh, M., & Sathyalakshmi, S. (2020, fev). Smart learning using personalised recommendations in web-based learning systems using artificial bee colony algorithm to improve learning performance. *Electronic Government*, 16(1-2), 101–117. doi: 10.1504/EG.2020.105253 [GS Search]
- Wikipedia (2020). *Wikipedia, the free encyclopedia*. Recuperado em 2022-01-05, de https://en.wikipedia.org/wiki/Main_Page
- Wiley, D. A. (2002). *The Instructional Use of Learning Objects* (1.^a ed.; D. SelfHueston, Ed.). Bloomington, Indiana, EUA: Agency for Instructional Technology. Recuperado em 2022-01-05, de <https://members.aect.org/publications/InstructionalUseofLearningObjects.pdf> [GS Search]
- Yao, X. (1999, set). Evolving artificial neural networks. *Proceedings of the IEEE*, 87(9), 1423–1447. Recuperado em 2022-01-05, de <https://ieeexplore.ieee.org/abstract/document/784219> doi: 10.1109/5.784219 [GS Search]
- Zitzler, E., & Künzli, S. (2004). Indicator-Based Selection in Multiobjective Search. *Lecture Notes in Computer Science*, 3242, 832–842. Recuperado em 2022-01-05, de https://link.springer.com/chapter/10.1007/978-3-540-30217-9_84 doi: 10.1007/978-3-540-30217-9_84 [GS Search]