
**Uma Abordagem Híbrida Apoiada por
Algoritmo Bioinspirado e Tecnologias de Web
Semântica para Recomendação Personalizada
de Objetos de Aprendizagem**

Cleon Xavier Pereira Júnior



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

Uberlândia
2021

Cleon Xavier Pereira Júnior

**Uma Abordagem Híbrida Apoiada por
Algoritmo Bioinspirado e Tecnologias de Web
Semântica para Recomendação Personalizada
de Objetos de Aprendizagem**

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

Área de concentração: Ciência da Computação

Orientador: Fabiano Azevedo Dorça

Coorientador: Rafael Dias Araújo

Uberlândia

2021

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

P436 2021	<p>Pereira Júnior, Cleon Xavier, 1991- Uma Abordagem Híbrida Apoiada por Algoritmo Bioinspirado e Tecnologias de Web Semântica para Recomendação Personalizada de Objetos de Aprendizagem [recurso eletrônico] / Cleon Xavier Pereira Júnior. - 2021.</p> <p>Orientador: Fabiano Azevedo Dorça. Coorientador: Rafael Dias Araújo. Tese (Doutorado) - Universidade Federal de Uberlândia, Pós-graduação em Ciência da Computação. Modo de acesso: Internet. Disponível em: http://doi.org/10.14393/ufu.te.2021.463 Inclui bibliografia. Inclui ilustrações.</p> <p>1. Computação. I. Dorça, Fabiano Azevedo, 1979-, (Orient.). II. Araújo, Rafael Dias, 1986-, (Coorient.). III. Universidade Federal de Uberlândia. Pós-graduação em Ciência da Computação. IV. Título.</p> <p style="text-align: right;">CDU: 681.3</p>
--------------	--

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091


UNIVERSIDADE FEDERAL DE UBERLÂNDIA

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


ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Ciência da Computação				
Defesa de:	Tese, 16/2021, PPGCO				
Data:	22 de julho de 2021	Hora de início:	14h	Hora de encerramento:	18h
Matrícula do Discente:	11623CCP001				
Nome do Discente:	Cleon Xavier Pereira Júnior				
Título do Trabalho:	Uma Abordagem Híbrida Apoiada por Algoritmo Bioinspirado e Tecnologias de Web Semântica para Recomendação Personalizada de Objetos de Aprendizagem				
Área de concentração:	Ciência da Computação				
Linha de pesquisa:	Inteligência Artificial				
Projeto de Pesquisa de vinculação:	-				

Reuniu-se, por videoconferência, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Ciência da Computação, assim composta: Professores Doutores: Renan Gonçalves Cattelan - FACOM/UFU, Márcia Aparecida Fernandes - FACOM/UFU, Sergio Crespo Coelho da Silva Pinto - UFF, Isabel Dillmann Nunes - UFRN/IMD, Rafael Dias Araújo - FACOM/UFU (coorientador) e Fabiano Azevedo Dorça - FACOM/UFU orientador do candidato.

Os examinadores participaram desde as seguintes localidades: Sergio Crespo Coelho da Silva Pinto - Rio das Ostras/RJ; Isabel Dillmann Nunes - Natal/RN; Renan Gonçalves Cattelan, Márcia Aparecida Fernandes, Rafael Dias Araújo e Fabiano Azevedo Dorça - Uberlândia/MG. O discente participou da cidade de Uberlândia/MG.

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

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

Aprovado.

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

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

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Fabiano Azevedo Dorça, Professor(a) do Magistério Superior**, em 23/07/2021, às 09:17, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Renan Gonçalves Cattelan, Professor(a) do Magistério Superior**, em 23/07/2021, às 09:32, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Márcia Aparecida Fernandes, Professor(a) do Magistério Superior**, em 23/07/2021, às 09:43, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Rafael Dias Araújo, Professor(a) do Magistério Superior**, em 23/07/2021, às 11:13, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Sergio Crespo Coelho da Silva Pinto, Usuário Externo**, em 26/07/2021, às 16:12, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Isabel Dillmann Nunes, Usuário Externo**, em 20/08/2021, às 18:52, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **2915326** e o código CRC **4C4F7552**.

*Dedico este trabalho aos meus pais,
que sempre me incentivaram para o caminho da educação.*

Agradecimentos

Sem me preocupar com ordem de importância, pois todos contribuíram para o meu trabalho em algum momento, começo agradecendo meus orientadores e ex orientadoras durante esses anos, sendo eles/as: Ana Paula Laboissière Ambrósio (*in memoriam*), Fabiano Azevedo Dorça, Márcia Aparecida Fernandes e Rafael Dias Araújo.

Agradeço os amigos que já caminhavam comigo mesmo antes do doutorado e que nunca hesitaram em me dar forças sempre que precisei. Aqui destaco meus/minhas amigos/as de formação e de profissão: Julio Cesar Batista Pires, Lucas de Almeida Ferreira, Marcos Alves Vieira, Raissa dos Santos Vieira e Walquíria Fernandes Marins.

Agradeço ao meu companheiro de pesquisa, colega de trabalho, amigo e esposo Newarney Torrezão da Costa que me deu força e suporte para eu conseguir chegar até esta etapa do trabalho.

Agradeço aos colegas de trabalho do Instituto Federal Goiano Campus Campos Belos e IF Goiano Campus Iporá. Aqui também faço um destaque especial aos/às amigos/as que acompanharam minha trajetória no doutorado e me motivaram a não desistir, sendo eles/as: Celyce Lula, João Rufino, Karine Dias, Lívia Mancine e Luciana Recart.

Deixo meus agradecimentos aos docentes da UFU pelo conhecimento transmitido através de disciplinas. Não posso deixar de agradecer aos técnicos administrativos que sempre tentaram me atender e solucionar minhas demandas. E, claro, também agradeço aos amigos que fiz por lá, esses que quero continuar caminhando ao lado. Aqui gostaria de enfatizar o apoio que recebi do Claudiney Tinoco e da Sara Melo.

Agradeço aos/às estudantes que já passaram pela minha vida desde meu início na docência até a data de defesa deste trabalho. Todos e todas me marcaram de alguma forma e este trabalho tem um pouquinho de cada. Destaco meus agradecimentos aos/às estudantes que colaboraram diretamente com essa pesquisa como voluntários/as. Também destaco o nome de dois estudantes que tive o prazer de orientar e que foram bem importantes para meu crescimento: João Pedro Barros Ferreira e Pedro de Torres Maschio.

Por fim, agradeço a Deus.

“Os oprimidos não obterão a liberdade por acaso, mas a procurando em sua práxis e reconhecendo que é necessário lutar para consegui-la.”
(Paulo Freire)

Resumo

A área de Sistemas Adaptativos e Inteligentes para a Educação (SAIE) está em constante evolução e esforça-se na aplicação de tecnologias recentes, buscando criar ambientes de aprendizagens personalizados. Para o desenvolvimento de SAIE, técnicas de Inteligência Artificial (IA) são bastante exploradas e comumente combinadas com teorias pedagógicas. Este trabalho visa contribuir para a área de IA aplicada à educação, a partir de uma abordagem que faz uso de tecnologias de Web Semântica e um algoritmo bioinspirado para realizar recomendação personalizada de Objetos de Aprendizagem (OA), utilizando Filtragem Baseada em Conteúdo (FBC). Diferente de abordagens já propostas, esta pesquisa combina repositórios de Ambiente Virtual de Aprendizagem (AVA) e materiais disponibilizados na Web (Youtube e Wikipedia) com o propósito de cobrir tópicos de um determinado conteúdo com materiais em formatos distintos. Com relação aos materiais da Web, esses são recuperados e estruturados em forma de OA. A abordagem desenvolvida nesta pesquisa foi implementada no AVA Classroom eXperience (CX) e foi criado um recurso de extensão para o Moodle. Foram realizados experimentos com esta abordagem. Um dos experimentos comparou três algoritmos bioinspirados com duas bases de dados distintas e, após análise, concluiu que o algoritmo genético apresenta desempenho satisfatório. Outros experimentos objetivaram analisar a opinião de estudantes com relação à recomendação. Os estudantes avaliaram positivamente a recomendação que levou em consideração o nível de conhecimento e ofertou materiais adicionais a partir de um determinado conteúdo. Outro experimento considerou três processos de recomendação distintos na intenção de observar possibilidades de preferências. As recomendações levaram em consideração o uso e não uso de estilos de aprendizagem no processo. A média geral da avaliação foi relativamente melhor desconsiderando o uso dos estilos de aprendizagem, porém não houve significância estatística.

Palavras-chave: Sistemas de Recomendação. Objeto de Aprendizagem. Filtragem Baseada em Conteúdo. Inteligência Artificial.

Abstract

The Adaptive and Intelligent Educational Systems (AIES) area is constantly evolving and is working to apply recent technologies to create personalized learning environments. For AIES development, Artificial Intelligence (AI) techniques are widely explored and commonly combined with pedagogical theories. This work aims to contribute to the area of AI applied to education, by presenting an approach that uses Semantic Web technologies and a bio-inspired algorithm to perform personalized recommendation of Learning Objects (LO), using Content-Based Filtering (CBF). In this research, we combine Virtual Learning Environment (VLE) repositories and materials available on the Web (Youtube and Wikipedia) to cover topics of a given content with materials in different formats. Regarding the materials on the Web, these are retrieved and structured as LO. We implemented the approach in the Classroom eXperience (CX) VLE and also created an extension for Moodle. Experiments were conducted with this implementation. One experiment compared three bio-inspired algorithms with two different databases and, after analysis, concluded that the genetic algorithm performs satisfactorily. Other experiments aimed to analyze the students' opinions regarding the recommendation. Students positively evaluated the recommendation that took into account their level of knowledge and offered additional material from a given content. Another experiment considered three different recommendation processes to observe preference possibilities. The recommendations took into consideration the use and non-use of learning styles in the process. The overall average rating was relatively better disregarding the use of learning styles, but there was no statistical significance.

Keywords: Recommendation Systems. Learning Object. Content Based Filtering. Artificial Intelligence.

Lista de ilustrações

Figura 1 – Camadas da Web Semântica, adaptada de Berners-Lee et al. (2006). . .	34
Figura 2 – Consulta SPARQL	36
Figura 3 – Visão Geral da Abordagem	52
Figura 4 – Parte do questionário ILS incluído no AVA CX.	54
Figura 5 – Parte do questionário ILS incluído no AVA Moodle.	55
Figura 6 – Visualização do nível de desempenho do estudante.	55
Figura 7 – Tela de cadastro de um recurso didático no CX.	56
Figura 8 – Visão Geral da Ontologia	62
Figura 9 – Recomendação de conteúdo a partir do desempenho	63
Figura 10 – Exemplo de uma Matriz Binária e seu Vetor de Custo.	67
Figura 11 – Apresentação para estudantes.	69
Figura 12 – Apresentação para estudantes no CX.	70
Figura 13 – Apresentação para estudantes no Moodle.	70
Figura 14 – Exemplo de Rede Bayesiana representando probabilidade de conheci- mento em alguns conceitos.	71
Figura 15 – Desempenho dos algoritmos para uma entrada de tamanho 200x1000 .	76
Figura 16 – Desempenho dos algoritmos para uma entrada de tamanho 10x200 . .	77
Figura 17 – Desempenho para a instância 200x1000 com população de tamanho 10.	79
Figura 18 – Desempenho para a instância 10x200 com população de tamanho 10. .	80
Figura 19 – Recomendação utilizando o conhecimento a ser adquirido e os Estilos de Aprendizagem.	82
Figura 20 – Exemplo de recomendação de materiais do Youtube e da Wikipedia. . .	83
Figura 21 – Distribuição dos estudantes por EA na base analisada.	84
Figura 22 – Quantidade de recomendações distintas e Objetos de Aprendizagem (OA), de acordo com o número de palavras-chave, por conteúdo de uma aula.	86
Figura 23 – Rede Bayesiana representando conceitos de programação procedural em Python.	88

Figura 24 – Etapas de execução do experimento 4.	89
Figura 25 – Exemplo de um conteúdo com possibilidades distintas de recomendação.	90
Figura 26 – Avaliação do estudante com relação ao nível de conhecimento.	91
Figura 27 – Gráfico comparativo das preferências de recomendação e de materiais.	93
Figura 28 – Gráfico de avaliação geral sobre os materiais e o desempenho.	93
Figura 29 – Exemplo de conteúdo com 03 recomendações distintas de materiais adicionais.	96
Figura 30 – Tela de avaliação dos itens.	97
Figura 31 – Perfil dos voluntários na pesquisa com relação aos Estilos de Aprendi- zagem (EA)	98
Figura 32 – Primeira parte de respostas ao questionário Recommender systems’ Quality of user experience (ResQue)	100
Figura 33 – Segunda parte de respostas ao questionário ResQue	101
Figura 34 – Fases da RSL. Adaptado de (VIEIRA, 2016)	122

Lista de tabelas

Tabela 1 – Resultado da consulta SPARQL.	37
Tabela 2 – Síntese dos trabalhos correlatos	48
Tabela 3 – Estruturação do Youtube e Wikipedia no padrão IEEE-LOM.	57
Tabela 4 – Recurso do IEEE-LOM associado ao FSLSM. Adaptado de Araújo (2017)	59
Tabela 5 – Recurso da extensão CLEO associado ao FSLSM. Adaptado de Araújo (2017)	60
Tabela 6 – Tipo de Interatividade do padrão IEEE-LOM associado ao FSLSM. Adaptado de Araújo (2017)	60
Tabela 7 – Nível de Interatividade do padrão IEEE-LOM associado ao FSLSM. Adaptado de Araújo (2017)	61
Tabela 8 – Exemplo de entrada de dados para o processo de recomendação.	61
Tabela 9 – Exemplo de classificação probabilística do EA de estudante.	62
Tabela 10 – Comparativo da execução dos algoritmos bioinspirados para problema de recomendação.	78
Tabela 11 – Critérios de inclusão e exclusão dos usuários.	84
Tabela 12 – Conteúdo de aulas selecionados para o experimento.	85
Tabela 13 – Participantes da pesquisa por disciplina	95
Tabela 14 – Critérios de inclusão e exclusão dos usuários na pesquisa.	97
Tabela 15 – Resultado da aplicação do questionário ResQue	99
Tabela 16 – <i>String</i> de busca para a seleção de artigos	123
Tabela 17 – Critérios de exclusão e inclusão	123
Tabela 18 – Número de publicações por base nas etapas do processo de execução. .	124
Tabela 19 – Trabalhos incluídos na RSL.	125

Lista de siglas

APP Algoritmo Presa Predador

API Application Programming Interface

AVA Ambientes Virtuais de Aprendizagem

AG Algoritmo Genético

CAAE Certificado de Apresentação de Apreciação Ética

CEP Comitê de Ética em Pesquisa

CLEO Customized Learning Experience Online

CX Classroom eXperience

DCMI Dublin Core Metadata Initiative

DP Desvio Padrão

EA Estilos de Aprendizagem

FSLSM Felder and Silverman Learning Styles Model

FOAF Friend Of A Friend

FBC Filtragem Baseada em Conteúdo

FC Filtragem Colaborativa

FH Filtragem Híbrida

IA Inteligência Artificial

IE Informática na Educação

IEEE Institute of Electrical and Electronic Engineers

IM Inteligências Múltiplas

ILS Index of Learning Styles

JPSO Jumping Particle Swarm Optimization

JSON JavaScript Object Notation

LOM Learning Object Metadata

MOOC Massive Open Online Courses

ME Modelo do Estudante

OA Objetos de Aprendizagem

OWL Ontology Web Language

PCC Problema de Cobertura por Conjuntos

PLN Processamento de Linguagem Natural

PSO Particle Swarm Optimization

SPARQL Simple Protocol and RDF Query Language

QP Questão de Pesquisa

REA Recursos Educacionais Abertos

RDF Resources Description Framework

RDFS Resource Description Framework Schema

RSL Revisão Sistemática da Literatura

ResQue Recommender systems' Quality of user experience

REST REpresentational State Transfer

SR Sistemas de Recomendação

SCP Set Covering Problem

SAIE Sistemas Adaptativos e Inteligentes para a Educação

SUS System Usability Scale

SWRL Semantic Web Rule Language

TCLE Termo de Consentimento Livre e Esclarecido

XML eXtensible Markup Language

Sumário

1	INTRODUÇÃO	25
1.1	Motivação	27
1.2	Objetivos e Questões de Pesquisa	29
1.3	Organização do Texto	30
2	FUNDAMENTAÇÃO TEÓRICA	31
2.1	Metadados de Objetos de Aprendizagem	31
2.2	Web Semântica e Ontologias	33
2.3	Processo de Adaptatividade na Educação	37
2.4	Ambientes de Recomendação Educacionais e Técnicas Adotadas	39
2.5	Algoritmos para Recomendação Personalizada	40
3	TRABALHOS CORRELATOS	43
4	ABORDAGEM DESENVOLVIDA	51
4.1	Visão geral	51
4.2	Interface	53
4.3	Módulo de Estruturação de OA	57
4.4	Módulo Adaptativo	58
4.5	Módulo de Recomendação	63
4.6	Modelo do Estudante	71
4.7	Síntese do Capítulo	72
5	EXPERIMENTOS E ANÁLISE DOS RESULTADOS	73
5.1	Experimento 1: Algoritmo de recomendação	74
5.1.1	Método	74
5.1.2	Resultados e análise	75
5.2	Experimento 2: Avaliação da Abordagem	80
5.2.1	Método	81

5.2.2	Resultados e análise	81
5.3	Experimento 3: Uso de AVA para recomendar materiais extras	83
5.3.1	Método	83
5.3.2	Resultados e análise	85
5.4	Experimento 4: Análise da recomendação	87
5.4.1	Método	87
5.4.2	Resultados e análise	91
5.5	Experimento 5: Avaliação da recomendação	95
5.5.1	Método	95
5.5.2	Resultados e análise	98
6	CONSIDERAÇÕES FINAIS	103
6.1	Principais Contribuições	103
6.2	Limitações e Trabalhos Futuros	105
6.3	Contribuições em Produção Bibliográfica	106
	REFERÊNCIAS	109

APÊNDICES 119

APÊNDICE A	– USO DE FILTRAGEM BASEADA EM CONTEÚDO PARA RECOMENDAÇÃO DE MATERIAIS EDUCACIONAIS: UMA REVISÃO SISTEMÁTICA DA LITERATURA	121
A.1	Introdução	121
A.2	Metodologia	122
A.2.1	Planejamento	122
A.2.2	Execução	123
A.3	Resultados da RSL	124
A.4	Considerações Finais	129
APÊNDICE B	– REGRAS DE INFERÊNCIA SWRL	131
APÊNDICE C	– QUESTIONÁRIO 1	135
APÊNDICE D	– QUESTIONÁRIO 2	137
APÊNDICE E	– QUESTIONÁRIO 3	139

Introdução

O uso da tecnologia para suporte educacional tem se tornado uma realidade. O ensino atual pode contar com Ambientes Virtuais de Aprendizagem (AVA) como apoio às diversas modalidades da educação. Nesse aspecto, estudar tecnologias para aprimorar a educação e facilitar a entrega de conteúdo relevante para os aprendizes deve estar em paralelo com a evolução computacional, de tal forma que o ensino ocorra cada vez mais personalizado às necessidades individuais.

Os Sistemas Adaptativos e Inteligentes para a Educação (SAIE) colaboram para obtenção de êxito na busca do ensino personalizado. Nesses sistemas, a aplicação de Inteligência Artificial (IA) é recorrente e visa, dentre outros cenários, buscar uma individualização dos caminhos de aprendizagem (BRUSILOVSKY; PEYLO, 2003; COLCHESTER et al., 2017). Observando os SAIE, verifica-se que a IA contribui nas diferentes etapas do processo de adaptação, isto é, na busca em ofertar uma aprendizagem de acordo com as necessidades individuais do estudante. Alguns exemplos do uso de IA para adaptatividade em SAIE são na modelagem automática do estudante (BERNARD et al., 2016) e na recomendação personalizada (PONTES et al., 2014).

Com relação ao processo de recomendação personalizada, que ocorre nos SAIE, esse tem apresentado avanços significativos, sendo que um dos motivos que os permitem personalizar o processo de recomendação é a grande quantidade de dados disponíveis (DRACHSLER et al., 2015). *Massive Open Online Courses (MOOC)* são exemplos em geração de dados, pois cursos nesse formato possuem um alto número de aprendizes conectados que, além de fornecer informações pessoais, ainda geram dados de comportamento de estudantes no ambiente.

Conforme afirmam Drachsler et al. (2015), existe um crescimento de exploração de dados de estudantes que são relevantes e têm colaborado para o processo de personalização da aprendizagem. Mesmo havendo uma melhoria nesse processo, observa-se que materiais na Web, em diferentes formatos, também mantém uma constante expansão e não costumam ser explorados em SAIE. Uma vez que há uma alta quantidade de materiais na Web, é importante que a recomendação de conteúdos relevantes à aprendizagem

não seja limitada somente a repositórios de OA, por vezes específicos de uma plataforma (MEDIO et al., 2019).

Apesar da necessidade emergente em explorar materiais da Web como fonte de aprendizagem, a geração de conteúdos educacionais a partir desses recursos para uma recomendação personalizada exige um esforço. Desafios atuais consistem em associar as duas fontes (dados de estudantes e materiais da Web) na intenção de gerar aprendizagem personalizada aos estudantes, através dos SAIE.

Tecnologias de Web Semântica podem ser um dos caminhos interessantes para tratar essa demanda. Além de facilitar no processo de reúso e compartilhamento de recursos, tais tecnologias apresentam uma extensão para a Web tradicional, trazendo significado para o conteúdo disponibilizado online. A DBPedia¹, por exemplo, é um bom resultado dos esforços com o uso da Web Semântica. Existindo um padrão dos conteúdos (facilitado pela Web Semântica), o processo de recomendação consiste em encontrar o melhor conteúdo que vá facilitar a aprendizagem do indivíduo (BELDJOURI; SERIDI; KARABADJI, 2018).

Em SAIE, recursos educacionais são constantemente recomendados em forma de OA. Recomendar os melhores OA, a partir de uma necessidade do estudante, não é uma atividade trivial. Por vezes, a atividade pode ser associada à classe de problemas de busca e otimização, conforme apresenta Belizário Júnior e Dorça (2018). Nesse caso, o problema se torna NP-difícil (BERNHARD; VYGEN, 2008). Soluções utilizando algoritmos bioinspirados (principalmente que levam em consideração meta-heurísticas) costumam ser viáveis nessas circunstâncias, pois o problema envolve um processo de busca e seleção. Além disso, uma das estratégias utilizadas pelos Sistemas de Recomendação (SR) para prover recursos ao usuário é conhecida por Filtragem Baseada em Conteúdo (FBC) (LOPS; GEMMIS; SEMERARO, 2011). Para essa estratégia, a recomendação é realizada buscando selecionar itens que mais se assemelham ao perfil do usuário. No contexto educacional, quando aplicada a FBC para recomendação de OA, espera-se encontrar os recursos que mais se aproximam do perfil do estudante que foi selecionado para receber a recomendação.

Além disso, outro desafio observado com relação aos módulos de recomendação de OA está ligado à alta acoplagem desses com um sistema específico. Nota-se que esta acoplagem não permite uma aplicação em outros ambientes educacionais (DRACHSLER et al., 2015). Alguns AVA, por exemplo o Moodle², possuem código-fonte aberto e permitem modificações, agregação de módulos, dentre outros. Para isso, abordagens genéricas, fracamente acopladas a um determinado sistema, tornam-se mais interessantes para atender necessidades atuais.

Observando o cenário atual da pesquisa em computação aplicada à educação e, no

¹ <https://wiki.dbpedia.org/>

² <https://moodle.org/>

intuito de colaborar com a pesquisa de IA aplicada, este trabalho explora o processo de recomendação personalizada de OA, utilizando FBC, através do desenvolvimento de uma abordagem que é capaz de recuperar materiais da Web e recomendar em formato de OA, a partir das necessidades individuais dos aprendizes. Além disso, a abordagem desenvolvida não é de uso exclusivo do ambiente utilizado como teste, evitando problemas de alta acoplagem, já apontados na literatura.

1.1 Motivação

O interesse por sistemas de recomendação personalizada é algo inerente à computação. Com o crescente número de dados, o serviço personalizado tem sido mais frequente e oferece maior precisão ao atender às necessidades de cada usuário. Esse tipo de serviço já está associado ao cotidiano dos usuários, através, principalmente, do comércio eletrônico (PAPPAS et al., 2017). Na área de educação, os esforços em pesquisas que possam levar a um serviço personalizado vêm ocorrendo (MANOUSELIS et al., 2011). Há um grande foco na análise de dados para identificar perfis de aprendizes e realizar uma melhor prática de recomendação (BODILY; VERBERT, 2017).

Por outro lado, atualmente a Web possui um acervo imensurável de conteúdo. Com rápidas buscas é possível encontrar materiais em formato de vídeos, imagens, textos e áudios de um determinado conceito. Esse acervo é, em muitos casos, acessado através de páginas da Web, não sendo necessariamente desenvolvidas para o processo de aprendizagem. Além disso, as máquinas de busca, como o Google, que trazem esses materiais, estão mais preocupadas com a relevância do domínio do conteúdo, número de palavras-chave correspondentes, segurança, frequência de acessos, dentre outros³. Fatores ligados aos estilos de aprendizagem do usuário e conhecimentos prévios, por exemplo, não são levados em consideração.

Trabalhos prévios mostram que as buscas por páginas da Web têm retornado mais resultados que a busca limitada aos repositórios de OA (MEDIO et al., 2019). Através dessas pesquisas, é possível observar a necessidade de explorar recursos Web no processo de recomendação. Além disso, a personalização no processo de recomendação ainda tem focado somente em uma variável do estudante, que por vezes são os estilos de aprendizagem (NAFEA; SIEWE; HE, 2019; MORILLO-PALACIOS; GUTIÉRREZ-CÁRDENAS, 2020; HASSAN; HAMADA, 2017).

A pesquisa de Ferreira (2018) apresenta uma abordagem híbrida baseada em redes bayesianas e ontologias para modelagem do estudante em SAIE. O trabalho apresenta avanços para a área de Informática na Educação (IE) uma vez que consegue utilizar as tecnologias supracitadas, juntamente com nível de conhecimento e comportamento de estudantes para definir o desempenho. Sendo assim, o modelo é capaz de inferir a pro-

³ <https://backlinko.com/google-ranking-factors>

habilidade de conhecimento de um estudante em determinado conteúdo. Em resumo, a pesquisa apresenta um modelo dinâmico, probabilístico, independente de domínio, extensível e reutilizável.

Já o trabalho de Araújo (2017) apresenta uma arquitetura computacional capaz de estruturar OA, capturando metadados a partir de conteúdo de aulas e atividades colaborativas. Uma vez que se tem OA estruturados, a abordagem se propõe a oferecer conteúdo personalizado para estudantes. O trabalho, além da contribuição em estruturação de OA a partir de interações com conteúdo de uma aula, também disponibiliza um repositório de OA.

A pesquisa de Belizário Júnior e Dorça (2018) apresenta uma abordagem que combina algoritmo genético e tecnologias de Web Semântica para recomendação de OA a partir de páginas da Wikipedia. Tal pesquisa abre possibilidade de expansão para explorar outros repositórios de conteúdo que estão estruturados em páginas da Web. Além disso, a pesquisa não faz uma comparação com outros algoritmos para verificar se há melhoria no processo de recomendação.

Tanto o trabalho de Ferreira (2018), quanto o trabalho de Araújo (2017), possuem semelhanças por utilizarem para validação de suas abordagens o AVA Classroom eXperience (CX). O CX é um ambiente de aprendizagem ubíquo que, de um lado realiza a captura da aula, contando com a colaboração de uma lousa digital. Já do lado do estudante, apresenta um ambiente colaborativo, com módulos social, gamificação, visualização do desempenho e possibilidade de acesso do conteúdo personalizado de uma aula.

O processo de recomendação em ambientes educacionais na maioria das vezes se limita a traçar o perfil do estudante e verificar dentro do repositório desenvolvido para aquele ambiente específico, e alimentado por OA, quais conteúdos seriam melhores de acordo com os dados fornecidos pelos aprendizes. A pesquisa de Araújo (2017) apresenta a possibilidade de personalizar conteúdo do CX. Já o trabalho de Ferreira (2018) traz um modelo de estudante que, dentre outras coisas, apresenta possibilidades de captura do desempenho de estudantes a partir de interações do CX juntamente com dados fornecidos por docentes.

Diante da quantidade de recursos disponíveis na Web, exige-se das abordagens de recomendação de conteúdos uma preocupação que vai além da busca de repositórios de materiais educacionais específicos do AVA, ou até mesmo de repositórios de OA (MEDIO et al., 2019). Também é esperado que o conteúdo educacional tenha qualidade e leve em consideração fatores individuais de estudantes. Portanto, a expansão de acervos educacionais deve estar diretamente ligada ao processo de recuperação de conteúdo Web. Assim, uma abordagem que consegue fazer uso das abordagens apresentadas previamente e recomendar materiais educacionais que vão além dos repositórios associados ao AVA pode trazer contribuição para a IE. Para isso, além da recuperação, exige-se módulos colaborativos que permitem estudantes avaliarem o conteúdo, gerando um *feedback* que

pode ser monitorado de forma automática.

1.2 Objetivos e Questões de Pesquisa

Nota-se que o problema de recomendação personalizada para a educação ainda possui lacunas de investigação que envolvem todo o processo, isto é, desde a seleção de materiais até a entrega e verificação da aprendizagem a partir de preferências e conhecimentos do estudante. Nesse aspecto, este trabalho visa responder as seguintes Questão de Pesquisa (QP):

- QP1: É possível recuperar e estruturar materiais da Web na forma de OA para recomendá-los como recursos educacionais extras em um AVA a partir de dados fornecidos por professores e estudantes?
- QP2: A recomendação automática de materiais, a partir do nível de conhecimento do estudante e estilos de aprendizagem, pode trazer benefícios no processo de aprendizagem de acordo com a percepção de estudantes?
- QP3: É possível manter uma relevância na recomendação de OA quando estes são gerados a partir de conteúdo da Web?

Para responder as questões de pesquisa, o trabalho tem como objetivo geral a criação de uma abordagem dinâmica para recomendação personalizada de materiais da Web na forma de OA. Assim, dois grandes pontos podem ser levantados a partir do objetivo, sendo eles: recuperação e seleção de conteúdo. Esses pontos estão intimamente ligados com os desafios desta pesquisa.

Conforme citado na Seção 1.1, pesquisas apontam uma necessidade do uso de conteúdos que vão além de repositórios educacionais como fonte de aprendizagem por parte dos estudantes. Porém, utilizar somente as buscas padrões faz com que o retorno venha carregado de outros conteúdos não educacionais e que podem, além de causar uma dispersão durante o estudo, ser irrelevantes para o processo de aprendizagem. Sendo assim, um grande desafio desta pesquisa é fazer uma filtragem de conteúdos retornados por essas máquinas de busca, com a preocupação em selecionar materiais educacionais mais próximos da necessidade do estudante em fontes que não estão diretamente ligadas com ensino.

Além da recuperação de conteúdos da Web, outro desafio presente na pesquisa é a seleção para a recomendação personalizada. Uma vez que se tenha concretizado a etapa de busca de conteúdos tanto no repositório de OA vinculado ao AVA (caso tenha) quanto em outros repositórios estruturados ou não, o processo de recomendação deve levar em consideração as preferências do estudante e o nível de conhecimento. Nesse sentido, o problema cresce de forma exponencial, uma vez que estudantes são distintos e o acervo

de conteúdo Web é imensurável. Sendo assim, técnicas de IA devem ser desenvolvidas, analisadas e aplicadas na intenção de colaborar para a solução desse desafio.

Uma vez que já se sabe o objetivo geral e os desafios que o permeiam, alguns objetivos específicos devem ser levantados, sendo eles:

- ❑ Definir um módulo de gerenciamento de OA, capaz de gerar metadados de OA a partir de recursos Web e informações de tutores;
- ❑ Definir um módulo de recomendação personalizada que seja capaz de utilizar nível de conhecimento e preferências dos estudantes, coletados a partir de testes e uso de ambientes educacionais;
- ❑ Definir um módulo de avaliação do processo de recomendação de conteúdo, visando a constante melhoria de entrega de conteúdo.

Considerando-se este contexto, é proposta uma abordagem modelada com base na teoria do Problema de Cobertura por Conjuntos (PCC), ou *Set Covering Problem (SCP)* (CORMEN et al., 2009), e implementada utilizando-se meta-heurísticas de busca, mais especificamente algoritmos bioinspirados. Para esta proposta, diferentes algoritmos foram testados e tiveram seus desempenhos comparados. Além disso, este modelo também foi então aliado à FBC, apoiada por tecnologias da Web Semântica, visando-se a recuperação, a partir da Web, e seleção eficiente de conteúdos educacionais de forma dinâmica. Dessa forma, a abordagem traz avanços ao estado da arte em diversos aspectos, se apresentando mais completa quando comparada a trabalhos correlatados em relação aos requisitos e funcionalidades presentes, como apresenta-se mais adiante, permitindo-se superar de forma bastante assertiva os desafios associados à recuperação e seleção de conteúdos mais significativos ao estudante.

1.3 Organização do Texto

Este documento está dividido da seguinte forma: o Capítulo 2 traz a fundamentação teórica da pesquisa, discutindo principalmente o que foi utilizado neste trabalho. O Capítulo 3 apresenta os trabalhos correlatos, isto é, o que já foi aplicado com relação às técnicas discutidas no Capítulo 2. O Capítulo 4 apresenta a abordagem proposta neste trabalho, levantando as tecnologias que foram empregadas para atingir os objetivos. O Capítulo 5 traz os experimentos realizados para responder as questões de pesquisa. Por fim, o Capítulo 6 apresenta as considerações finais deste trabalho.

Fundamentação Teórica

Este capítulo apresenta a fundamentação teórica para a realização deste trabalho. A Seção 2.1 faz uma explanação acerca de metadados de OA, onde são apresentados os padrões existentes para representação desses, trazendo um foco para o IEEE-LOM¹ junto com a extensão *Customized Learning Experience Online (CLEO)*, e uma discussão acerca de anotação automática desses metadados. A Seção 2.2 apresenta a ontologia e seu papel na Web Semântica como um ferramenta poderosa para modelagem e consulta e inferências lógicas. A Seção 2.3 faz uma explanação sobre adaptatividade na educação e apresenta algumas possibilidades para realização desse processo em sistemas educacionais. A Seção 2.4 apresenta as principais técnicas utilizadas nos ambientes de recomendação. Por fim, a Seção 2.5 apresenta alguns algoritmos bioinspirados para problemas de busca e otimização e relaciona com o processo de recomendação em ambientes educacionais. Dessa forma, é possível analisar a fundamentação do problema tratado nesta pesquisa.

2.1 Metadados de Objetos de Aprendizagem

Metadados são definidos como um conjunto de dados que fornecem informações resumidas acerca de alguma entidade, ou seja, são dados que caracterizam outros dados. No âmbito educacional, uma entidade, conhecida como OA, é qualquer recurso digital, ou não digital, que pode ser utilizado no contexto de aprendizagem (LTSC, 2020). Um OA pode ser, por exemplo, um livro, um filme ou uma lista de exercícios. Na intenção de facilitar a forma de descrever esses metadados, alguns padrões foram criados e pesquisadores têm esforçado em automatizar processos para preenchimento destes metadados.

Os metadados de OA, cujo termo em inglês é *Learning Object Metadata (LOM)*, são formas de representação dos dados de um OA. A Institute of Electrical and Electronic Engineers (IEEE), ainda em 2002, em parceria com a *Dublin Core Metadata Initiative (DCMI)*, criou o padrão IEEE-LOM, que vem sendo adotado mundialmente para a representação de metadados de OA (MCCLELLAND, 2003). A versão proposta pela

¹ https://standards.ieee.org/standard/1484_12_1-2002.html

IEEE permite o registro de dados como, por exemplo, nome, formato e direitos autoriais de um OA. Mesmo aparentemente parecer um padrão bem completo, algumas extensões surgiram posteriormente, como é o caso da CLEO (TALIESIN, 2003). A extensão CLEO acrescenta vocabulários adicionais para melhorar o nível de agregação na categoria geral. Para a categoria educacional, são adicionados vocabulários alternativos para representar os recursos de aprendizagem e novos elementos. Também é acrescentado o propósito para a categoria de classificação.

Ainda sobre o IEEE-LOM, esse organiza os dados de um OA em nove categorias: geral, ciclo de vida, meta-metadados, técnica, educacional, classificação, relação, anotação e direitos. Sua representação é comumente feita no formato *eXtensible Markup Language (XML)* e cada uma dessas categorias possui subcategorias, sendo organizadas hierarquicamente. A categoria educacional é a que possui mais subcategorias e guarda dados relevantes que podem ser associados a perfis de estudantes, auxiliando no processo de recomendação personalizada.

Na categoria educacional é possível armazenar dados do tipo de recurso de aprendizagem, tipo de interatividade, nível de interatividade, densidade semântica, dificuldade, idioma, dentre outros. Ao registrar um OA em um repositório, é necessário que se preencha tais metadados. O trabalho manual para preenchimento dos metadados acaba demandando bastante tempo (GARCÍA-FLORIANO et al., 2017).

Além do IEEE-LOM, existem outros padrões para metadados de OA. Nesse contexto, também se destaca o padrão da DCMI (que foi parceira no desenvolvimento do IEEE-LOM). Também utilizado para descrever OA, a DCMI possui uma vasta experiência com criação de metadados. A DCMI e a IEEE possuem um compromisso de interoperabilidade dos padrões² (INITIATIVE et al., 2012). IEEE-LOM e DCMI também colaboram para a Web Semântica no sentido de manter dados conectados através dos metadados estabelecidos pelos padrões.

Existem diferentes maneiras de armazenar OA e/ou metadados em um repositório. Baseados em suas estruturas, os repositórios de OA podem ser classificados em quatro tipos (HARMAN; KOOHANG, 2007):

- ❑ OA e metadados centralizados: esse tipo de repositório mantém OA e seus metadados em um servidor centralizado;
- ❑ OA centralizados e metadados distribuídos: nesse caso, os OA são armazenados num servidor central, mas os seus metadados estão fora deste servidor;
- ❑ OA distribuído e metadados centralizados: esse tipo mantém metadados em um servidor central e fornece links para OA externos;

² <https://www.dublincore.org/collaborations/ieee/mou/>

- OA e metadados distribuídos: essa é uma arquitetura totalmente distribuída onde é capaz de conectar múltiplos servidores de indexação com múltiplos bancos de dados.

A extração automática de metadados a partir de conteúdos educacionais é um esforço que vem sendo adotado por parte de pesquisadores, no intuito de alimentar os repositórios de OA (ROY; SARKAR; GHOSE, 2008). A partir dos metadados anotados de um determinado OA, esse se torna mais acessível para uso, reúso e referência durante o processo de aprendizagem. Assim, é possível utilizá-lo mais facilmente para uma recomendação personalizada, por exemplo, e permite até mesmo uma facilidade para o sequenciamento de currículo (GASPARETTI et al., 2018).

É sabido que os repositórios são limitados com relação ao número de OA e que recuperar conteúdo da Web deve ser uma realidade para dar mais suporte no que diz respeito aos recursos de aprendizagem (MEDIO et al., 2019). A recuperação de recursos não estruturados e, posterior transformação em OA anotados, aumenta as chances de cobrir determinados conteúdos durante o processo de aprendizagem. Dessa forma, além de esforçar em um preenchimento automático dos metadados educacionais, também é importante um trabalho de recuperação de conteúdos e possível criação automática de metadados de acordo com algum padrão (por exemplo, o IEEE-LOM).

Atualmente existem muitos conteúdos na Web que não estão estruturados, como vídeos, textos, áudios, entre outros. Alguns desses conteúdos são possíveis de serem recuperados com metadados via *Application Programming Interface (API)*. Youtube³ e Wikipedia⁴ são exemplos de sistemas Web que possuem bastante conteúdo e que fornecem API para a extração de metadados. Infelizmente, a extração automática de metadados não é suficiente para transformar o conteúdo em um OA. De acordo com Neven e Duval (2002), para ter OA capazes de atender a sua finalidade, é necessário algumas características, como granulosidade e composição. Um processo automático para transformar o conteúdo da Web em OA requer uma análise sobre a qualidade do recurso.

2.2 Web Semântica e Ontologias

Na intenção de reestruturar e expandir a Web tradicional, vários trabalhos têm apresentado o uso da Web Semântica. A Web Semântica é definida por Berners-Lee, Hendler e Lassila (2001) como a Web de dados descritos e interligados para estabelecer um contexto ou semântica que adere a uma linguagem e regras gramaticais bem definidas. Com esse modelo de Web, os dados passam a ser interligados e as máquinas passam a compreendê-los. Dessa forma, um termo isolado que só teria significado para um humano que compreende o idioma, passa a possuir ligação com outros termos que ajudam a compreender aquele significado e permite que as máquinas realizem o processamento.

³ <https://www.youtube.com>

⁴ <https://en.wikipedia.org>

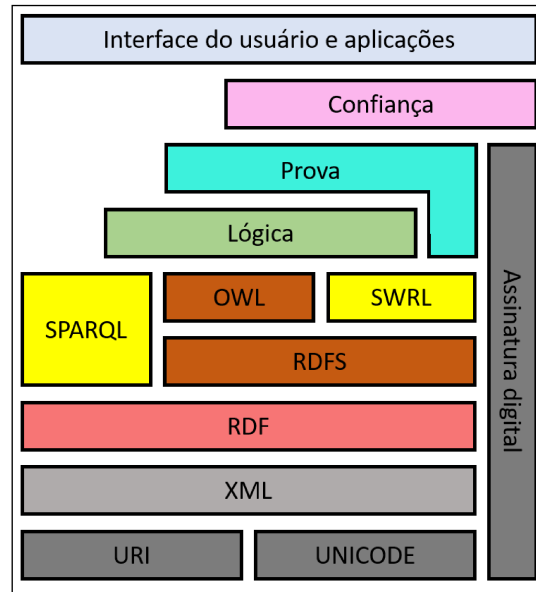


Figura 1 – Camadas da Web Semântica, adaptada de Berners-Lee et al. (2006).

A Figura 1 apresenta uma visão geral das camadas da Web Semântica, adaptada de Berners-Lee et al. (2006). Esse modelo foi evoluído de arquiteturas anteriores, tendo o início em 2001. Na figura, é possível ver o nível hierárquico das camadas e como vem sendo apresentada a arquitetura da Web Semântica. Ainda observando a figura, tem-se a *Ontology Web Language (OWL)*, que é uma linguagem utilizada para definir ontologias na Web.

Em computação, uma ontologia pode ser definida como uma especificação formal e explícita de um conceito em relação a um domínio específico (MING; JIE, 2002). A ontologia é um recurso presente na Web Semântica, permitindo a publicação de dados e recuperação com mais eficiência graças ao poder de estruturar conteúdos nesse tipo de recurso. Dessa forma, ontologias definem formalmente domínios, suas relações e as regras de inferência (BERNERS-LEE; HENDLER; LASSILA, 2001).

Uma estrutura de ontologia é composta por indivíduos, classes (que podem ser pessoas, por exemplo), atributos e os relacionamentos. Através dessa composição, é possível criar uma ontologia para fazer representações de modelo e, por sua vez, realizar inferências através de regras. Com relação às ontologias existentes, segundo Yue et al. (2015), estas são classificadas em três tipos, sendo eles:

- ❑ Ontologia superior ou geral: são modelos de objetos comuns que geralmente são aplicados a uma gama de ontologias de domínio;
- ❑ Ontologia de domínio: são as mais comuns e responsáveis por modelar um domínio específico;
- ❑ Ontologia híbrida: são modelos que combinam ontologias de domínio e superior.

Sendo amplamente empregada no desenvolvimento de artefatos que envolvem Web Semântica, a OWL foi desenvolvida para representar instâncias, grupos de instâncias e suas relações (HITZLER et al., 2009). Conforme observado em McGuinness, Harmelen et al. (2004), essa linguagem é dividida em três grupos:

- ❑ OWL Lite: utiliza somente algumas características da OWL;
- ❑ OWL DL: uma expansão da *OWL Lite*, trazendo mais propriedades da linguagem OWL;
- ❑ OWL Full: apresenta o mesmo vocabulário da OWL DL, sendo também uma expansão da OWL Lite.

Apesar de usarem o mesmo vocabulário, OWL DL está sujeita a algumas restrições.

Além das definições anteriores, é importante ressaltar que a OWL é uma extensão da *Resources Description Framework (RDF)* que permite fazer afirmações sobre recursos. Essas afirmações são compostas de uma tripla, sendo: <sujeito><predicado><objeto> (DECKER et al., 2000). A OWL também estende a *Resource Description Framework Schema (RDFS)*, que é uma extensão do RDF e já é capaz de definir, dentre outras coisas, a hierarquia de classes e os domínios. Sendo assim, a OWL surge para permitir uma semântica com mais restrições e inferências. A OWL DL, por exemplo, possui um vocabulário amplo que permite deduções lógicas sobre ontologias (MCGUINNESS; HARMELEN et al., 2004).

Apesar de, por exemplo, a OWL DL apresentar suporte a raciocínio de forma bem eficiente, ainda assim, ela não suporta regras. Nesse aspecto, surge a *Semantic Web Rule Language (SWRL)*, que é uma linguagem de regras da Web Semântica e que permite a criação de regras para ontologias modeladas em OWL, utilizando cláusulas de Horn (HORROCKS et al., 2004). Assim, é possível realizar inferências lógicas em uma OWL, ampliando a capacidade das ontologias na Web Semântica.

Os dados descritos em OWL (estendido de RDF e RDFS) são armazenados em bancos de dados específicos para essa representação. No geral, são bancos de dados que permitem representações em triplas. Uma vez que os dados estejam armazenados, seguindo as especificações anteriores, uma possibilidade de consulta é através do Simple Protocol and RDF Query Language (SPARQL) (SCHMIDT; MEIER; LAUSEN, 2010).

SPARQL é uma linguagem de consulta da Web Semântica, semelhante ao SQL, que permite buscas complexas em triplas armazenadas nos bancos de dados. Uma das vantagens do uso do SPARQL está com relação a sua expressividade e escalabilidade (FERRÉ, 2014). A maioria das grandes bases de dados projetadas para o modelo de *Linked Data* (ou dados ligados) permitem consultas livres através de SPARQL *EndPoints*. Estes lo-

cais na Web funcionam para acesso às bases de dados ligadas. Um exemplo de base que disponibiliza *EndPoint* é a DBPedia⁵.

A DBPedia é um projeto que visa extrair páginas da Wikipedia e disponibilizá-las de forma estruturada. Tal projeto conta com recursos de Web Semântica para fazer ligação de diferentes conteúdos. Dessa forma, é possível realizar buscas de forma semântica e explorar ainda mais os conteúdos. Com o apoio da DBPedia, é possível verificar, dentre outras coisas, conteúdos relacionados por conta da conectividade dos dados⁶.

```

Query Text
SELECT *
WHERE {
  ?sujeito ?predicado ?objeto .
}
LIMIT 20

```

Figura 2 – Consulta SPARQL

Fazer consulta na DBPedia ou em qualquer outra base de dados no modelo de *Linked Data* utilizando SPARQL, apesar de se assemelhar com SQL, possui bastante particularidade para tornar viável para o modelo de tripla. A Figura 2 apresenta uma consulta simples e genérica, utilizando o *EndPoint* da DBPedia para buscar 20 triplas quaisquer. Nota-se que a limitação a 20 triplas no exemplo ocorre por conta da cláusula *LIMIT*.

A DBPedia é um projeto de associar dados da Wikipedia e ela por si só já é uma base de dados gigante. A sua construção foi realizada levando em consideração os vocabulários já existentes na Web Semântica. Isso significa que a sua modelagem está associada com a *Friend Of A Friend (FOAF)* e outras mais. Fazendo uma busca na DBPedia em português, através do *EndPoint* disponibilizado, com o código a seguir, é possível ter o que significa mitose de forma reduzida.

```
PREFIX dbpedia-owl:<http://dbpedia.org/ontology/>
```

```
PREFIX dbr: <http://pt.dbpedia.org/resource/>
```

```
SELECT * WHERE {
```

```
    dbr:Mitose dbpedia-owl:abstract ?resumo
```

```
}
```

O resultado da consulta SPARQL seria conforme Tabela 1. A construção de uma ontologia não é um trabalho trivial. A atividade mais comum e também recomendada, em prol de encontrar mais sucesso na área de Web Semântica, é o reuso das mesmas

⁵ <http://pt.dbpedia.org/sparql>

⁶ <https://wiki.dbpedia.org/about>

Tabela 1 – Resultado da consulta SPARQL.

resumo
“Mitose (do grego mitos, fio, filamento) é o processo pelo qual as células eucarióticas dividem seus cromossomos entre duas células menores do corpo. Este processo dura, em geral, 52 a 80 minutos e é dividido em cinco fases: Prófase, prometáfase, metáfase, anáfase e telófase. É uma das fases do processo de divisão celular ou fase mitótica do ciclo celular.”@pt

(SIMPERL, 2009). Desse modo, a OWL possui padrões que devem ser seguidos para facilitar o reúso e interoperabilidade dos modelos.

O uso de ontologias para representar modelos tem sido bastante explorado na área educacional. Kalogeraki et al. (2016) descreve a dificuldade dos repositórios de OA em realizar uma comunicação entre eles (por conta de problemas de interoperabilidade) e como técnicas de Web Semântica, através da ontologia, são promissoras para o reúso e compartilhamento de OA. Nesse sentido, é possível avaliar a relação semântica entre OA e utilizar os resultados para a criação de um sistema de gerenciamento de OA para educação a distância.

2.3 Processo de Adaptatividade na Educação

O esforço em uma educação personalizada diz respeito à adaptatividade. Nesta área existem muitas pesquisas que utilizam dados de estudantes para realizar a adaptatividade (DWIVEDI; KANT; BHARADWAJ, 2018). Quando se trata de adaptatividade no contexto da aprendizagem, existem três pontos a serem discutidos, segundo Group et al. (2010), são eles:

- ❑ **Individualização:** São classificados neste item ambientes que esperam o mesmo objetivo de aprendizagem para todos os estudantes, mas os estudantes podem utilizar ritmos individuais durante o processo de aprendizagem. Isto é, nestes ambientes, estudantes podem, por exemplo, repetir alguns conteúdos e pular outros conteúdos.
- ❑ **Diferenciação:** Neste caso, os objetivos de aprendizagem são os mesmos, porém os métodos ou a abordagem das instruções variam de acordo com a preferência de cada estudante.
- ❑ **Personalização:** Este item refere-se a ambientes que a instrução é ajustada às necessidades de aprendizagem. Um ambiente totalmente personalizado consegue variar tanto os objetivos e conteúdos de aprendizagem, bem como o ritmo pode variar. A personalização engloba a diferenciação e individualização.

Além da decisão do tipo de adaptatividade que será levada em consideração, também é necessário analisar quais informações são relevantes para gerar um ambiente adaptativo.

Existem diferentes estratégias utilizadas por pesquisadores para a melhor adaptação da aprendizagem, dentre elas as Inteligências Múltiplas (IM) (GARDNER, 1983). Segundo Gardner (1983), o ser humano possui várias inteligências, sendo que, para determinadas áreas de atuação, algumas delas podem destacar enquanto outras não. De acordo com esta teoria, oito inteligências foram identificadas e são denominadas: linguística, musical, lógico-matemática, visual-espacial, corporal-cinestésica, interpessoal, intrapessoal e naturalista. Cogita-se ainda a possibilidade de uma nona inteligência (existencial).

Outra estratégia utilizada na adaptatividade em ambientes virtuais são os EA. Segundo pesquisas de Feldman, Monteserin e Amandi (2015), Valaski, Malucelli e Reinehr (2011), existem várias recomendações de EA, porém, os dois estilos mais utilizados são os propostos por (FELDER; SILVERMAN et al., 1988) e (KOLB; KOLB, 2005). As IM, se comparadas aos EA, referem-se ao que o indivíduo pode realizar, às habilidades, enquanto os EA referem-se às preferências no uso das habilidades (KELLY; TANGNEY, 2006).

Felder, Silverman et al. (1988) apresenta um modelo de EA dividido em quatro dimensões. Além disso, cada dimensão apresenta dois estilos. A seguir uma descrição de cada uma das dimensões:

- ❑ **Processamento:** dimensão responsável pelos EA ativo e reflexivo. Enquanto que os estudantes do grupo ativo gostam de aprender através de atividades práticas e discussões colaborativas, os estudantes reflexivos são mais introspectivos e preferem atividades de forma mais passiva;
- ❑ **Percepção:** dimensão responsável pelos EA sensitivo e intuitivo. Os estudantes sensitivos costumam ser mais práticos e gostam de aprender sobre dados e fatos. Os estudantes intuitivos gostam de coisas inovadoras e abstrações;
- ❑ **Entrada:** dimensão responsável pelos EA visual e verbal. Está relacionada com a maneira que os estudantes tendem a memorizar melhor uma informação. Os estudantes visuais preferem receber informações através de imagens, filmes e gráficos. Os estudantes verbais preferem textos descritivos ou falas;
- ❑ **Organização:** dimensão responsável pelos EA sequencial e global. Estudantes com perfil sequencial, preferem conteúdos estruturados e que tenham uma linearidade. Já os estudantes globais tendem a aprender observando uma visão geral do assunto e também selecionando alguns trechos.

Também foi desenvolvido um questionário para coleta manual dos EA, chamado *Index of Learning Styles (ILS)* (FELDER; SOLOMAN, 2015). Quando aplicado aos estudantes, é possível saber em qual dos grupos de cada dimensão um estudante tende a estar através das respostas que ele dá ao questionário. São 44 questões divididas em quatro partes. Estratégias para coletar de forma automática os EA têm sido desenvolvidas.

Alguns trabalhos vêm questionando a efetividade da aplicação de EA no processo educacional (AN; CARR, 2017; KIRSCHNER, 2017). Conforme observado por Dias et al. (2017), as críticas dizem respeito à classificação dos aprendizes somente tendo parâmetro os EA e também sem considerar que os EA podem ser alterados no decorrer do processo.

2.4 Ambientes de Recomendação Educacionais e Técnicas Adotadas

Ambientes de recomendação que oferecem recursos de maneira personalizada aos usuários têm sido explorados nas diversas aplicações computacionais (LOPS; GEMMIS; SEMERARO, 2011). Esse tipo de serviço já está associado no cotidiano dos usuários, através, principalmente, do comércio eletrônico (PAPPAS et al., 2017). Na área da educação, os esforços em pesquisas que envolvem recomendação personalizada em ambientes de aprendizagem também vêm ocorrendo (MANOUSELIS et al., 2011). Ao aprofundar na área de SR educacionais é possível observar que há diferentes maneiras de coleta e exploração de dados para realizar uma recomendação (WAN; NIU, 2018).

No âmbito de SR é possível encontrar três principais maneiras de filtragens de recursos de aprendizagem, sendo elas: Filtragem Colaborativa (FC); FBC e Filtragem Híbrida (FH) (WAN; NIU, 2018). Algumas pesquisas apresentam outros tipos de filtragem, sendo elas: filtragem demográfica, filtragem baseada em conhecimento, filtragem baseada em comunidade e filtragem baseada em críticas (GORDILLO; BARRA; QUEMADA, 2017; GIUSTOZZI et al., 2016). Além disso, o trabalho de Rodríguez et al. (2017) apresenta a filtragem baseada em argumentação, que é uma combinação de filtragem baseada em conteúdo, colaborativa e baseada em conhecimento, podendo ser vista até como uma nova técnica ou uma técnica híbrida.

Um exemplo do uso da FC se dá através da geração de uma matriz de avaliações de usuários para um conjunto de produtos (sendo que os usuários e produtos representam as linhas e colunas) e posterior recomendação a partir desse conjunto de dados (ALMAHAIRI et al., 2015). O problema desse modelo para um SR é a necessidade da classificação de usuários com preferências similares para conseguir fazer uma recomendação para o sujeito interessado (LOPS; GEMMIS; SEMERARO, 2011). Existem melhorias para esse tipo de abordagem, conforme pode ser observado em (ALMAHAIRI et al., 2015).

Os SR que possuem FBC buscam combinar o perfil do usuário com atributos do conteúdo para recomendar novos itens para os interessados. A vantagem de usar esse tipo de aplicação é que, para um determinado usuário, a recomendação vai ocorrer a partir das características dele e dos recursos disponíveis. Ou seja, nesse tipo de abordagem não há uma dependência do conjunto de usuários para realizar a recomendação (LOPS; GEMMIS; SEMERARO, 2011). Abordagens que utilizam FBC possuem limitações no

número e tipo de características que serão utilizadas como associação para a recomendação de objetos.

FBC são comumente encontradas em ambientes de recomendação de OA. O trabalho de Wan e Niu (2018), por exemplo, apresenta um SR de OA baseado em auto-organização. O SR proposto utiliza FBC para recomendação personalizada e faz uma crítica à necessidade de levar em consideração as mudanças dos estudantes no processo de aprendizagem. Tal fator é comumente ignorado quando se trata de FBC, pois, uma vez capturada as características dos estudantes que serão levadas em consideração para o processo de recomendação, estas se tornam estáticas e não são atualizadas no decorrer do processo.

2.5 Algoritmos para Recomendação Personalizada

A Seção 2.2 trouxe um pouco da tecnologia de Web Semântica através de ontologias. A Web Semântica é uma das técnicas de IA que colaboram, entre outras coisas, para sistemas de aprendizagem. Nesta seção serão discutidos alguns algoritmos de IA que podem auxiliar na resolução de problemas de busca e otimização. Tal problema está intrinsecamente ligado a sistemas de recomendação de OA, uma vez que esses sistemas devem tomar decisões sobre a seleção de OA dentro de um repositório.

Constantemente, observa-se o uso de algoritmos inspirados na natureza para problemas de otimização. O uso dessa estratégia justifica-se pelo fato de atualmente existir uma grande quantidade de dados disponíveis, o que demandaria muito tempo e esforço computacional para analisar todas as combinações possíveis, tornando o processo inviável. Dentre os algoritmos bioinspirados, duas técnicas se destacam para resolução de problemas de busca e otimização, sendo elas: inteligência de enxames e algoritmos evolutivos (ARIYARATNE; FERNANDO, 2014).

Os algoritmos de inteligência de enxames são clássicos na resolução de problemas que envolvem otimização. Os algoritmos de inteligência de enxames são inspirados em animais da natureza como abelhas, formigas e pássaros (KARABOGA; AKAY, 2009). Dentro dos algoritmos de inteligência de enxames, um exemplo é o *Particle Swarm Optimization (PSO)*, traduzido como otimização por enxame de partículas (KENNEDY; EBERHART, 1995). O PSO é um algoritmo inspirado no comportamento social de espécies, como por exemplo o voo de pássaros e o movimento de cardumes de peixes.

Outros algoritmos também caracterizados como inteligência de enxames são: *firefly* (inspirado no comportamento de vaga-lumes) (ARIYARATNE; FERNANDO, 2014) e o colônia de formigas (RASTEGARMOGHADAM; ZIARATI, 2017). Ambos seguem a proposta inicial de implementação que são meta-heurísticas para otimização de problemas. Nesse aspecto, problemas que envolvem recomendação em ambientes educacionais estão aptos a utilizar qualquer uma das estratégias de inteligência de enxame, como é o exemplo de Bhaskaran e Santhi (2017), que utiliza o algoritmo *firefly*.

Os algoritmos evolutivos também são algoritmos inspirados em fenômeno da natureza e procuram solucionar problemas de otimização através da seleção, cruzamento e recombinação dos elementos que envolvem a solução (VIKHAR, 2016). Os algoritmos evolutivos são uma subárea da computação evolutiva e são inspirados na capacidade das espécies de evoluir. Dentro dos algoritmos evolutivos é possível encontrar o Algoritmo Genético (AG) como exemplo (WHITLEY, 1994).

O AG clássico trata cada elemento de entrada como um indivíduo portador de código genético. Sendo assim, ele cria a população inicial do algoritmo, a partir daí, é feita a avaliação de aptidão de cada indivíduo. A avaliação de aptidão consiste num cálculo que está diretamente ligado com o problema a ser solucionado. Após essa etapa, realiza a seleção dos candidatos que vão participar do processo de reprodução. Realiza o cruzamento dos candidatos selecionados e em seguida realiza (ou não) a mutação de alguns indivíduos. Por fim, atualiza os valores (através da função de aptidão) de cada indivíduo e verifica se a condição de parada foi atingida.

No aspecto educacional, por apresentar uma potencialidade em problemas de busca e otimização, o uso das técnicas supracitadas é frequentemente encontrado para prover uma recomendação personalizada aos estudantes (BHASKARAN; SANTHI, 2017; KURILOVAS; ZILINSKIENE; DAGIENE, 2014; DWIVEDI; KANT; BHARADWAJ, 2018). Nesse sentido, é importante estudar o problema e verificar qual a melhor estratégia a ser aplicada. No próximo capítulo, são apresentados alguns trabalhos relacionados que auxiliaram na escolha da estratégia.

Trabalhos Correlatos

O Capítulo 2 apresentou a fundamentação teórica que norteia esta pesquisa. Nele, foram colocados aspectos fundamentais para o desenvolvimento do trabalho. A seguir, serão abordados trabalhos correlatos a esta pesquisa. São apresentados trabalhos sobre recuperação de conteúdo da Web e anotação automática de OA. Também são apresentados usos de algoritmos bioinspirados em sistemas de recomendação, buscando evidenciar a combinação de diferentes técnicas nesses sistemas. Por último são encontrados trabalhos sobre o uso de FBC para recomendação de materiais educacionais. Por lidar diretamente com o processo de recomendação, viu-se a necessidade de uma Revisão Sistemática da Literatura (RSL) (Apêndice A) para levantamento dos trabalhos com FBC. A seguir, os trabalhos correlatos à abordagem proposta neste trabalho são apresentados, juntamente com um estudo comparativo entre eles, possibilitando ter clareza em quais aspectos a abordagem deste trabalho traz elementos inovadores considerando o estado da arte.

O trabalho de Pal et al. (2019) apresenta um modelo de preenchimento automático de alguns metadados para recursos educacionais no formato de vídeo. No trabalho, é apresentada uma ontologia no domínio de Programação Orientada a Objetos com linguagem Java. O modelo gera automaticamente alguns metadados como densidade semântica e dificuldade. A extração de texto e técnicas de Processamento de Linguagem Natural (PLN) são aplicadas para o preenchimento automático dos metadados. Além disso, abre possibilidade para generalização do domínio. Apesar do trabalho de Pal et al. (2019) focar em extração de dados e geração automática de metadados, é possível verificar que ele apresenta um potencial acerca de recuperação de conteúdos da Web. Os experimentos utilizados estão inclusos vídeos do Youtube. No caso dos vídeos, os metadados são extraídos de forma manual e não há exploração de outros formatos educacionais.

García-Florianio et al. (2017) também apresenta uma proposta de preenchimento automático de metadados. O trabalho enfatiza a importância de técnicas que extraia os metadados de forma automática na intenção de enriquecer ambientes de aprendizagem. No contexto da proposta, também é utilizada uma técnica de extração de texto para classificar recursos da Web e interagir com redes sociais em ambientes de aprendizagem

a distância. Diferente do trabalho de Pal et al. (2019), o trabalho de García-Floriano et al. (2017) apresenta um classificador de metadados treinado com OA já classificados previamente. Nesse caso, técnicas de aprendizagem supervisionada foram utilizadas e se mostraram eficientes nestas investigações. Além disso, o trabalho também apresenta esta solução para um domínio específico e levanta a hipótese de generalização.

A pesquisa de Bocanegra et al. (2017) utiliza de vídeos do Youtube e fontes de conteúdos educacionais de saúde para apresentar um SR, baseado em tecnologias da Web Semântica, que é capaz de recomendar conteúdos extras a partir de um vídeo do Youtube. Para realizar a recomendação, a abordagem utiliza de metadados do vídeo (principalmente o título) e, a partir da extração de substantivos, faz uma busca de materiais que possam trazer informações extras acerca daquele conteúdo. O trabalho enfatiza a relevância de vídeos no contexto educacional, mas aponta uma preocupação da qualidade dos vídeos do Youtube.

O trabalho de Beldjoudi, Seridi e Karabadji (2018) faz uso de preferências do usuário extraídas do sistema para realizar recomendação. A pesquisa utiliza *Linked Open Data* (LOD) ou dados abertos ligados como recurso educacional para recomendação. Mais especificamente, o modelo utilizado como fonte de dados foram recursos disponíveis na DBPedia junto a uma base de dados que utiliza a ideia de folksonomia. O trabalho também aplica a colônia de formigas no processo.

O trabalho desenvolvido por El-Bishouty et al. (2014) utiliza algoritmo genético para resolver o problema de otimização, esforçando em maximizar o nível de suporte ao curso. Nesse caso, com o auxílio do algoritmo genético, os pesquisadores desenvolveram uma solução que fosse capaz de analisar a estrutura de um curso e verificar quais OA poderiam ser alocados. Além disso, a solução aponta em que local esses recursos didáticos deveriam ser inseridos para assim o curso permitir um maior suporte aos diferentes EA. O trabalho de El-Bishouty et al. (2014) utiliza os EA para a recomendação dos OA. Na pesquisa, o modelo de Felder, Silverman et al. (1988) é aplicado para a personalização dos cursos *online*.

Na pesquisa de Kurilovas, Zilinskiene e Dagiene (2014), a personalização com relação ao estudante continua sendo EA. É utilizado um algoritmo de otimização de colônia de formigas para definir caminhos de aprendizagem dos estudantes. O trabalho considera o caminho de aprendizagem como um objeto dinâmico, sendo que três situações distintas podem ocorrer: novos OA podem ser inseridos; OA existentes podem ser excluídos; OA podem ser alterados ou divididos. Nos casos citados e tendo um conhecimento prévio das ações já realizadas pelo estudante, entende-se que o caminho de aprendizagem, para ser personalizado com as preferências do estudante, deve ser dinâmico e a próxima ação deste aprendiz deve levar em consideração o que já foi visto e o que o ambiente ainda pode oferecer. Nesse caso, a pesquisa apresentada utiliza o algoritmo de colônia de formigas para recomendar caminhos de aprendizagem de forma dinâmica, considerando os EA

tratando o estudante como formigas e os OA como feromônios. Os testes são realizados para a situação que novos OA são inseridos no processo durante a aprendizagem.

A abordagem proposta por İnce, Yiğit e Işık (2017) é motivada pela grande quantidade de OA em repositórios e a dificuldade na seleção desses OA. De acordo com os autores, a seleção de OA se torna um problema de decisão multicritério, uma vez que é levado em consideração metadados para um resultado mais personalizado. Assim, a pesquisa apresenta uma solução de recomendação de OA a partir de repositórios, utilizando um processo híbrido que envolve processo hierárquico analítico e algoritmo genético. Através da abordagem híbrida, a estratégia consegue recomendar OA usando critérios estabelecidos durante uma busca em um repositório de OA.

Utilizando o algoritmo *Firefly*, o trabalho de Bhaskaran e Santhi (2017) apresenta uma estratégia de recomendação personalizada baseada em nuvem. Nesse caso, é utilizado o algoritmo de inteligência de enxames, com o auxílio do k-means, para classificar os estudantes de acordo com os EA e preferências e, a partir dessa classificação, apresentar o conteúdo que mais condiz com as características agrupadas previamente. Diferente das situações anteriores, o algoritmo inspirado na natureza, nessa situação, é utilizado no processo de recomendação, só que classificando estudantes para receber materiais de aprendizagem em sistemas tutores. A fim de realizar um experimento, pesquisadores utilizaram um sistema nomeado Protus, que acompanha estudantes em disciplinas de programação, armazenando os dados em nuvem.

O trabalho de Rastegarmoghadam e Ziarati (2017) é outro exemplo que utiliza otimização de colônia de formigas para criar caminhos de aprendizagem personalizados. A abordagem se baseia em EA, nesse caso o VARK (menos predominante o uso se comparado ao Felder and Silverman Learning Styles Model (FSLSM)), combinado com estilos de resolução de problemas MBTI para modelar o estudante e recomendar conteúdo a partir dessa modelagem. A partir dos conhecimentos acerca do estudante, em um dado sistema adaptativo, o algoritmo fica responsável por recomendar o próximo objeto de aprendizagem que este estudante deve acessar.

Também utilizando a ideia de caminho de aprendizagem, a abordagem apresentada por Dwivedi, Kant e Bharadwaj (2018) utiliza algoritmo genético para recomendar uma sequência de materiais didáticos para aprendizes. Nesse trabalho, eles partem da ideia que o número de materiais também pode ser variado de acordo com as individualidades do estudante. Portanto, o algoritmo genético auxilia no sequenciamento e quantidade de materiais a serem recomendados para um estudante.

Já direcionando a revisão da literatura para trabalhos que utilizam FBC em SR, técnicas computacionais que visam encontrar similaridade de objetos são mais observadas. Por se tratar de uma filtragem, onde é recomendado um conteúdo semelhante ao perfil do usuário e/ou outro conteúdo, essas técnicas são mais comuns (GORDILLO; LÓPEZ-FERNÁNDEZ; VERBERT, 2020; GORDILLO; BARRA; QUEMADA, 2017; MORILLO-

PALACIOS; GUTIÉRREZ-CÁRDENAS, 2020; JORDÁN et al., 2020; SLIMANI et al., 2020). As técnicas de similaridade nessas abordagens, em sua maioria, consistem em comparar metadados de OA em busca do mais similar possível ao esperado pelo usuário.

Ainda com relação a técnicas computacionais e FBC, aplicações com Web Semântica costumam ser combinadas no processo de recomendação (RODRÍGUEZ et al., 2017; MORILLO-PALACIOS; GUTIÉRREZ-CÁRDENAS, 2020; AISSAOUI; OUGHDIR, 2020). No caso do trabalho de Rodríguez et al. (2017) as regras de inferência OWL foram utilizadas para realização da filtragem. Já a pesquisa de Morillo-Palacios e Gutiérrez-Cárdenas (2020) explorou as consultas semânticas do tipo SPARQL em seu trabalho. Por fim, a pesquisa de AISSAOUI e OUGHDIR (2020) utilizou de ontologias para modelagem do domínio. Outras técnicas de IA observadas em trabalhos com FBC foram multiagentes e uso de aprendizado de máquina (RIVERO-ALBARRÁN et al., 2018; NAFEA; SIEWE; HE, 2019; HAMEED; EL-AMEER, 2019). O trabalho de Hameed e El-Ameer (2019), por exemplo, utilizou de KNN e redes bayesianas para classificação dos conteúdos e posterior recomendação de forma mais personalizada. Apesar de menos frequente, foi possível observar que a área de aprendizado de máquina pode ser explorada nesse tipo de domínio.

A pesquisa de Wan e Niu (2018) traz uma visão importante do que é esperado de um SR que utiliza FBC para recomendação de conteúdos educacionais. Na arquitetura apresentada, o trabalho aponta a importância da estruturação de alguns metadados do OA e também da modelagem do estudante. Isto é, espera-se os metadados dos OA e um modelo de estudante. A partir disso, é recomendado ao estudante os conteúdos que mais se assemelham com o modelo dele.

Nota-se uma predominância dos EA também nos SR que utilizam FBC. Eles são utilizados tanto para traçar perfil de preferências de estudantes, quanto para modelar OA, isto é, indicar para qual perfil aquele OA deve ser recomendado. O FSLSM tem sido o mais predominante dentre os trabalhos que utilizam EA e FBC (HASSAN; HAMADA, 2017; NAFEA; SIEWE; HE, 2019; JORDÁN et al., 2020; AISSAOUI; OUGHDIR, 2020). Há também pesquisas que utilizam os EA do tipo VARK como um dos atributos para modelagem do aprendiz (RODRÍGUEZ et al., 2017; DOJA et al., 2020). O trabalho de Song, Zhuo e Li (2016) também propõe o uso de EA como dados a serem levantados do estudante, porém não especifica qual modelo.

Além dos EA, através da revisão da literatura, encontra-se alguns trabalhos que têm utilizado de experiências anteriores, com relação à interação com o material educacional, como dados para a criação do modelo do estudante (GORDILLO; BARRA; QUEMADA, 2017; JORDÁN et al., 2020; BORBA; GASPARINI; LICHTNOW, 2017). O nível de conhecimento/formação, idioma de preferência e nível de dificuldade foram encontrados como dados relevantes do aprendiz para o processo de recomendação (GORDILLO; BARRA; QUEMADA, 2017; HAMEED; EL-AMEER, 2019; AISSAOUI; OUGHDIR, 2020).

Com relação aos metadados explorados de OA, título, palavras-chave e idioma são frequentemente citados nos trabalhos e aparentemente fundamentais para a filtragem de OA e posterior recomendação de um conteúdo educacional. No trabalho de Rodríguez et al. (2017) foram utilizados o tipo de recurso educacional, nível de interatividade, tipo de interatividade, contexto, descrição, idioma e formato (metadados estruturados de acordo com o IEEE-LOM). Já no trabalho de Gordillo, López-Fernández e Verbert (2020) e Gordillo, Barra e Quemada (2017) utilizaram título, idioma e palavras-chave dos OA como metadados para auxiliar na seleção dos melhores OA de acordo com as preferências do estudantes.

Na pesquisa de Rodríguez et al. (2017), autores utilizam a FBC combinada com outras técnicas para criação de uma abordagem capaz de recomendar e gerar argumentos para justificar a recomendação. Já o trabalho de Gordillo, López-Fernández e Verbert (2020) parte do pressuposto da importância da FBC, como já confirmada em outras pesquisas, e apresenta a contribuição do uso de avaliações pedagógicas para somar durante o processo de recomendação. Os autores apontam que o acréscimo do uso de avaliações pedagógicas para cada Recursos Educacionais Abertos (REA) torna a abordagem híbrida.

Nos trabalhos de Gordillo, Barra e Quemada (2017) e Hassan e Hamada (2017), é utilizada FBC para a recomendação de OA semelhantes com as preferências dos usuários. Além disso, na proposta apresentada por Hassan e Hamada (2017), a partir da FBC, dados acerca do contexto do usuário devem ser aplicados para melhor filtragem dos OA. Já na pesquisa de Nafea, Siewe e He (2019) a partir de um conjunto de OA avaliados pelo estudante, o algoritmo de recomendação, a partir de técnicas de clusterização, recomenda os OA mais relacionados. Caso o estudante não tenha um conjunto de OA avaliados, a recomendação é feita a partir dos seus EA. Na pesquisa de Hassan e Hamada (2017), a técnica de FBC foi combinada com a FC.

A partir dos trabalhos correlatos foi possível fazer um levantamento do estado da arte de pesquisas na área de computação aplicada a educação que envolvem o processo de recuperação de materiais na Web, anotação automática de metadados de OA e uso de tecnologia de Web Semântica e algoritmos bioinspirados para o processo de recomendação personalizada. A síntese dos trabalhos mais relevantes para esta pesquisa é encontrado na Tabela 2.

A Tabela 2 está dividida em sete colunas. A primeira coluna é a referência do trabalho, já as demais colunas são as características que foram encontradas nesses trabalhos. O símbolo (●) significa que determinada característica foi encontrada no trabalho. O símbolo (○) significa ausência da característica no trabalho. Em pesquisa prévia já constatou ausência de trabalhos que, ao mesmo tempo, se preocupam com recuperação de conteúdo da Web e associação com repositório de OA, anotação automática e recomendação personalizada em forma de OA. Deste modo, foram feitas buscas mais focadas nesses pontos para darem suporte a esta pesquisa.

Tabela 2 – Síntese dos trabalhos correlatos

Trabalho	A	B	C	D	E	F
El-Bishouty et al. (2014)	○	○	●	●	○	●
Kurilovas, Zilinskiene e Dagiene (2014)	○	○	○	●	○	●
Song, Zhuo e Li (2016)	○	○	○	●	○	○
García-Florianio et al. (2017)	○	●	●	○	○	○
İnce, Yiğit e Işık (2017)	○	○	●	●	○	●
Bhaskaran e Santhi (2017)	○	○	○	●	○	●
Rastegarmoghadam e Ziarati (2017)	○	○	●	●	○	●
Gordillo, Barra e Quemada (2017)	○	○	●	●	○	○
Rodríguez et al. (2017)	○	○	●	●	●	○
Hassan e Hamada (2017)	○	○	○	●	○	○
Borba, Gasparini e Lichtnow (2017)	○	○	○	●	○	○
Bocanegra et al. (2017)	●	○	○	●	●	○
Dwivedi, Kant e Bharadwaj (2018)	○	○	○	●	○	●
Beldjoudi, Seridi e Karabadji (2018)	●	○	○	●	●	●
Wan e Niu (2018)	○	○	●	●	○	○
Rivero-Albarrán et al. (2018)	○	○	○	●	○	○
Pal et al. (2019)	●	●	○	○	●	○
Nafea, Siewe e He (2019)	○	○	●	●	○	○
Hameed e El-Ameer (2019)	○	○	●	●	○	○
AISSAOUI e OUGHDIR (2020)	○	○	○	●	●	○
Doja et al. (2020)	○	○	○	●	○	○
Morillo-Palacios e Gutiérrez-Cárdenas (2020)	○	○	●	●	●	○
Gordillo, López-Fernández e Verbert (2020)	○	○	●	●	○	○
Jordán et al. (2020)	○	○	●	●	○	○
Slimani et al. (2020)	○	○	○	●	○	○
Abordagem Desenvolvida	●	●	●	●	●	●

A - Recuperação de conteúdos da Web

B - Geração automática de metadados de OA

C - Busca automática em repositórios de OA

D - Recomendação personalizada

E - Uso de Tecnologias da Web Semântica

F - Uso de algoritmo bio-inspirado para recomendação

Nota-se que, apesar da grande exploração de técnicas computacionais de otimização para o processo de recomendação, a maior parte dos trabalhos se limita a recomendar OA por já estarem estruturados através de seus metadados e terem a finalidade educacional. Nesse aspecto, é possível concluir que ainda há uma grande quantidade de materiais da Web que podem ser recomendados como recurso educacional. Dessa forma, a abordagem desenvolvida nesta pesquisa apresenta um diferencial por estruturar conteúdo da Web e recomendar em forma de OA.

Outra observação interessante é que, dos trabalhos que envolvem recomendação personalizada, a maioria utiliza EA no processo. Recentemente surgiram fortes críticas com relação aos EA, conforme apresentado por Kirschner (2017). O que se pode observar é

que os trabalhos mais recentes têm esforçado em combinar EA com outras preferências do usuário para realizar a recomendação. Esta evolução nos trabalhos pode ser consequência das críticas recentes. Além disso, nos sistemas de recomendação educacionais são verificados esforços no uso de ontologias e técnicas de Web Semântica para modelagem de domínio e, por consequência, o esforço em personalizar o processo de recomendação. Nota-se que estes sistemas comumente apresentam combinação de Web Semântica com outras técnicas de IA (OBEID et al., 2018; BELIZÁRIO JÚNIOR; DORÇA, 2018; TAMBE; KADAM, 2016). Lógica *Fuzzy*, algoritmos genéticos e aprendizado de máquina são algumas estratégias combinadas com Web Semântica nestes sistemas de recomendação.

Além disso, é possível observar a frequência de uso dos algoritmos bioinspirados para a recomendação personalizada e também as diferentes aplicações destes durante o processo de recomendação. Tais resultados são importantes para verificar o que já foi explorado e gerar novos caminhos a partir do que foi levantado. Ao término da Tabela 2 aparece a abordagem proposta nesta pesquisa, mostrando que o objetivo é cobrir os seis itens levantados na tabela.

A proposta de Belizário Júnior e Dorça (2018), que é continuada nesta pesquisa, não aparece relacionada e cobriria boa parte dos itens levantados. Porém, é importante ressaltar que este trabalho avança na expansão da abordagem e também na validação do modelo proposto no trabalho anterior. Itens como expansão de materiais da Web a serem explorados, associação de repositórios de OA e materiais da Web, possibilidade de associação com desempenho do estudante, uso de EA probabilístico são alguns dos fatores que não foram possíveis de observar no trabalho anterior. Desta forma, este trabalho traz significativos avanços em relação ao estado da arte, contribuindo para um reuso de conteúdo instrucional mais efetivo, e uma entrega de conteúdo personalizado mais eficiente e eficaz, possibilitando contribuições importantes no processo de aprendizagem.

Abordagem Desenvolvida

Este capítulo apresenta uma abordagem desenvolvida com uso de tecnologias de Web Semântica e algoritmo bioinspirado e explora a recomendação personalizada de OA, através do uso de FBC. A abordagem desenvolvida visa dar suporte para estudantes em AVA. Diferente de trabalhos prévios, levantados no Capítulo 3, esta pesquisa busca materiais da Web, que estão disponíveis em locais que não possuem finalidade exclusiva para o ensino e, após estruturá-los, anotando os metadados de OA, realiza a recomendação. A abordagem desenvolvida também permite exploração de repositórios do AVA associado.

As seções a seguir detalham cada uma das etapas da abordagem. A primeira seção apresenta uma visão geral, passando por todos os módulos e fazendo uma explicação breve. Já a segunda seção detalha a interface da abordagem, que é responsável por coletar dados de estudantes e professores. A terceira seção apresenta como é feita a estruturação de OA e a quarta seção apresenta como é criado os dados de entrada que auxiliará diretamente na seleção dos OA para a recomendação. A quinta seção detalha todas as possibilidades de recomendação a partir da abordagem. A sexta seção apresenta o modelo de estudante adotado nesta abordagem. Por fim, uma síntese do capítulo é apresentada.

4.1 Visão geral

A abordagem conta com informações de estudantes e professores e está dividida em sete etapas, além da ontologia que pode armazenar metadados de estudantes e de OA. Uma ontologia é um modelo de dados que, dentre outras finalidades, colabora com a área de Web Semântica, permitindo representações de domínio e inferências lógicas. Neste trabalho, a ontologia apresentada por Belizário Júnior (2018) foi modificada na intenção de armazenar e representar metadados e realizar inferências.

Para representar um OA, a ontologia desenvolvida buscou seguir os padrões do IEEE-LOM. Com esse padrão, é possível armazenar informações gerais, dados educacionais e até direitos de propriedade sobre um OA. A Seção 4.5 apresenta uma ilustração da ontologia utilizada nesta pesquisa.

Além disso, na intenção de ampliar as possibilidades de representação de um OA, também foram criadas entidades para representar a extensão CLEO com relação aos tipos de recursos educacionais. A partir do levantamento feito por Araújo (2017), foi possível explorar neste trabalho a extensão CLEO, aumentar a quantidade de tipos de recursos de aprendizagem que podem ser relacionados a OA e estender um pouco mais a ontologia utilizada nesta pesquisa para a modelagem do problema.

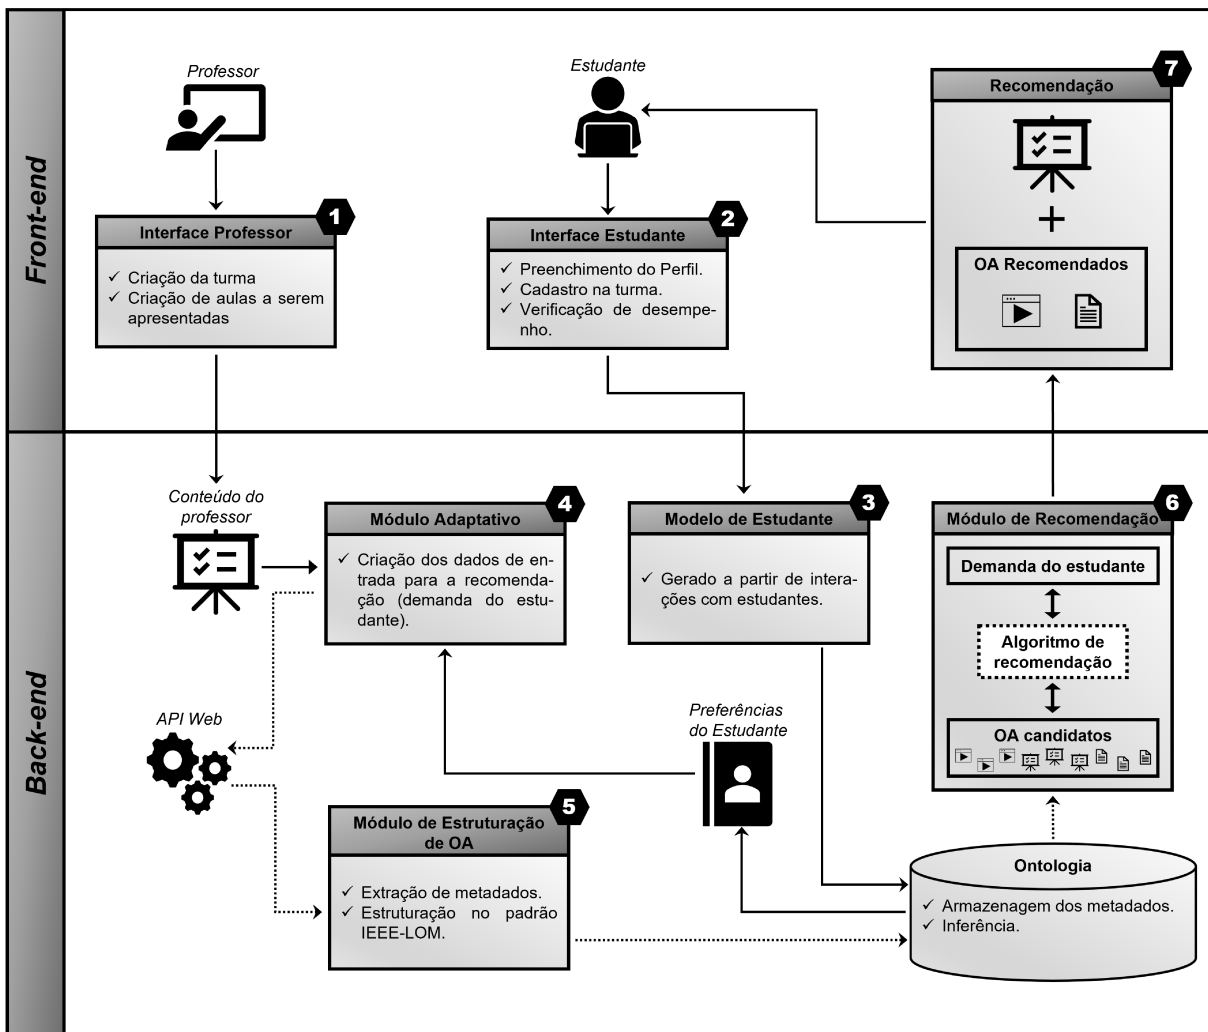


Figura 3 – Visão Geral da Abordagem

A Figura 3 apresenta uma visão geral da abordagem. Considerando que é o primeiro acesso do estudante na ferramenta, ele será estimulado a preencher o questionário ILS para uma definição inicial dos EA de acordo com o *FSLSM*. O preenchimento é facultativo e pode ser preenchido a qualquer momento, inclusive de forma fracionada, de acordo com o AVA utilizado. Independente do preenchimento do questionário ILS, o estudante deverá cadastrar em uma disciplina que deseja acompanhar pelo AVA (marcador 2 da Figura 3). Dentro da disciplina o estudante terá acesso ao esquema disponibilizado por professores. A partir de interações no AVA, como resposta a questionários e realização de atividades, professores poderão analisar o nível de conhecimento de estudantes.

Na marcação 1 da Figura 3, nota-se a interação de professores através do fornecimento de informações básicas do conteúdo e disponibilização de recursos educacionais próprios. Os dados fornecidos por professores são utilizados principalmente para o módulo de estruturação de OA (marcador 5). Já os dados fornecidos pelos estudantes são utilizados para a criação do modelo de estudante (marcador 3), etapa anterior ao módulo adaptativo que criará os dados de entrada para recomendação (marcador 4).

Ao responder questões para verificar o conhecimento adquirido em um determinado tópico, o estudante pode acessar materiais em que possui baixo desempenho através do componente desenvolvido para isso. A partir do EA e do conteúdo que o estudante necessita de materiais, forma-se a demanda do estudante (marcador 4). Uma vez que se tem a demanda do estudante, ocorre o processo de recomendação, através de FBC, realizando uma seleção a partir dos OA candidatos (marcador 6). Nesse caso, podem ser recomendados OA de acordo com o nível de conhecimento desse estudante e os EA (marcador 7). O método de recomendação pode utilizar somente os metadados armazenados na ontologia ou recuperar materiais da Web que são recomendados em forma de OA.

Uma vez que o estudante acesse os OA recomendados a partir de um conteúdo, esse terá a opção de avaliar o quão relevante aquele conteúdo foi para a aprendizagem acerca do tópico de interesse. Dessa forma, é possível alimentar uma classe na ontologia com metadados de OA externos, sendo que esses devem possuir uma avaliação através da colaboração dos aprendizes. As próximas seções apresentam mais detalhes sobre as etapas da abordagem. Um modelo resumido da abordagem foi apresentado em (PEREIRA JUNIOR; DORÇA; ARAUJO, 2019) e traz uma visão geral da proposta desta pesquisa, porém sem muitos detalhes.

É importante ressaltar que o presente trabalho envidou seus maiores esforços no desenvolvimento dos módulos 6 e 7 e na sua integração com os demais módulos, que apesar de terem sido desenvolvidos durante trabalhos progressos, sofreram melhorias e adaptações em algum grau para que o objetivo proposto neste trabalho fosse alcançado de forma plena.

4.2 Interface

Uma das bases da pesquisa em IE é a troca de dados entre estudantes e professores com o ambiente de aprendizagem. Nesse sentido, a abordagem apresenta a necessidade de interface (marcadores 1 e 2 da Figura 3) que deve ser entendida como uma camada de comunicação para receber os dados de entrada e retornar informações para o estudante.

Sobre a interface para interação com estudantes (marcador 2), além de dados pessoais, como idade e formação, para o processo de recomendação personalizada, é esperado que fatores ligados ao perfil e/ou conhecimentos prévios sejam levados em consideração. Portanto, para o melhor funcionamento dessa abordagem, é necessário que a aplicação seja

alimentada com informações sobre o nível de conhecimento do estudante. Tais informações podem ser carregadas manualmente ou automaticamente, através de questionários acerca do conteúdo vinculado no processo.

Com relação ao perfil do estudante, este trabalho utiliza os Estilos de Aprendizagem de Felder e Silverman ou *FSLSM*. Esse é um modelo utilizado em uma gama de trabalhos, conforme pôde ser observado no Capítulo 3 e no Apêndice A. Um dos motivos da popularidade do FSLSM é o fato de cobrir mais aspectos psicológicos que outros modelos (DEBORAH; BASKARAN; KANNAN, 2014). No trabalho desenvolvido aqui, os dados com relação aos estilos de aprendizagem dos estudantes são coletados através de questionário e devem compor o modelo do estudante que está descrito na Seção 4.6.

A Figura 4 apresenta uma parte do questionário ILS. Para esta aplicação, a estratégia desenvolvida por Araújo et al. (2020) é utilizada no sistema CX. Cada vez que o estudante acessa o AVA, ele pode responder 4 questões do questionário. Tal estratégia tem a intenção de não sobrecarregar o estudante com 44 questões para serem respondidas de imediato. Visando apresentar a independência de domínio da abordagem desenvolvida, um módulo foi desenvolvido para o AVA Moodle para a acoplagem do sistema de recomendação. Nesse caso, o ILS foi colocado para ser respondido na íntegra, porém o estudante pode optar por responder a qualquer momento.

[X]

Perguntas Diárias Comentários Quizzes

Índice de Estilos de Aprendizagem (ILS) INFO

Responda as seguintes perguntas integrantes do *Index of Learning Styles (ILS)*, proposto por Richard M. Felder e Barbara A. Soloman.

Nas disciplinas que cursei, eu

Em geral fiz amizade com muitos dos colegas

Raramente fiz amizade com muitos dos colegas

Em literatura de não-ficção, eu prefiro

Algo que me ensine fatos novos ou me indique como fazer alguma coisa

Algo que me apresente novas ideias para pensar

Eu gosto de professores que

Colocam bastante diagramas no quadro

Gastam bastante tempo explicando

Quando estou analisando uma história ou novela eu

Penso nos incidentes e tento colocá-los juntos para identificar os temas

Tenho consciência dos temas apenas quando termino a leitura e então tenho que voltar atrás para encontrar os incidentes que os confirmem

Enviar

Figura 4 – Parte do questionário ILS incluído no AVA CX.

A Figura 5 apresenta um trecho do questionário inserido no Moodle como parte do módulo integrado para recomendar materiais. As informações obtidas através do questionário do FSLSM são importantes, mas não exclusivas, para o processo de recomendação. Essas informações têm sido utilizadas como um dos parâmetros para recomendar um melhor OA para um determinado aprendiz. Dentre as várias colaborações do FSLSM para a seleção do OA, o tipo de recurso educacional tem sido utilizado tanto na recomendação

de OA do repositório vinculado ao AVA quanto de conteúdos da Web. Na Seção 4.5 serão abordados mais detalhes sobre a recomendação.

MDLJoão

João Pedro Barros Ferreira Student

Dashboard / Courses / NC1 / Topic 1 / Acessar recursos

Questionário

É a sua primeira vez nessa atividade, então para que a recomendação dos conteúdos seja mais **alinhada com os seus conhecimentos** sobre os assuntos da aula, responda esse questionário. É bem rápido 😊!

1. Eu compreendo melhor alguma coisa depois de
 - Refletir sobre ela
 - Experimentá-la
2. Eu me considero
 - Inovador(a)
 - Realista
3. Quando eu penso sobre o que fiz ontem, é mais provável que venha à mente
 - Palavras
 - Uma figura
4. Eu tendo a
 - Compreender a estrutura geral de um assunto, mas os detalhes podem ficar imprecisos
 - Compreender os detalhes de um assunto, mas a estrutura geral pode ficar imprecisa
5. Quando estou aprendendo algum assunto novo, me ajuda
 - Refletir sobre ele
 - Falar sobre ele
6. Se eu fosse um professor, eu preferiria ensinar uma disciplina
 - Que lida com ideias e teorias
 - Que lida com fatos e situações reais

Figura 5 – Parte do questionário ILS incluído no AVA Moodle.

Sobre o nível de conhecimento do estudante, esta pesquisa utiliza o processo elaborado por Ferreira (2018) em que é apresentado uma abordagem utilizando redes bayesianas que são atualizadas de acordo com o desempenho do estudante em um determinado conteúdo. Isto é, a cada conteúdo são apresentadas questões acerca do que foi visto. De acordo com o resultado, é possível classificar o estudante e verificar se existem pendências e em qual conteúdo. A Figura 6 apresenta uma visualização do desempenho de um estudante com relação à turma, gerado a partir de inserções de dados do professor e inferências da rede.

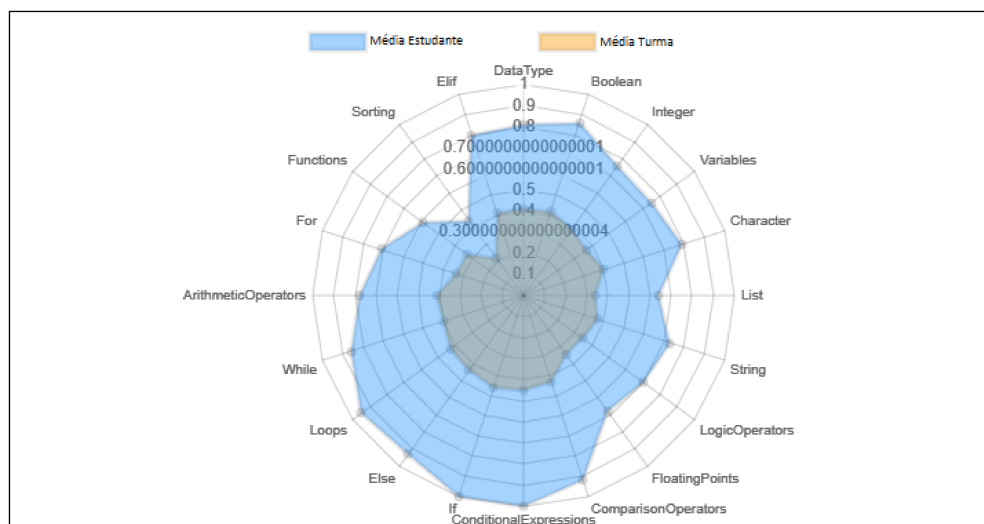


Figura 6 – Visualização do nível de desempenho do estudante.

Na marcação 1 da Figura 3, observa-se que há a coleta de informações de professores. Nesse caso, além da configuração básica da disciplina a ser ministrada, é necessário que tutores informem dados do conteúdo, como nome e palavras-chave. Caso o professor opte por carregar materiais educacionais, é importante que informe outros metadados esperados para um OA, conforme é observado na Figura 7.

O formulário de cadastro de um recurso didático no CX contém os seguintes campos e opções:

- Título*:** Campo de texto obrigatório.
- Palavras-chave*:** Campo de texto obrigatório.
- Arquivo de Slides:** Botão "Escolher arquivo" e texto "Nenhum arquivo selecionado". Abaixo, indica os formatos suportados: (.pdf, .ppt, .zip).
- Resumo:** Área de texto grande para inserir o resumo do recurso.
- Idioma:** Menu suspenso com a opção "Português" selecionada.
- Nível de dificuldade:** Campo de texto com o valor "N/D" selecionado.
- Importância:** Três opções de radio buttons: "Baixa", "Média" e "Alta".
- Tipo de interatividade:** Três opções de radio buttons: "Ativo", "Expositivo" e "Misto" (acompanhado de um ícone de ajuda).
- Nível de interatividade:** Seis opções de radio buttons: "Baixíssimo", "Baixo", "Médio", "Alto", "Altíssimo" (acompanhado de um ícone de ajuda).
- Densidade semântica:** Seis opções de radio buttons: "Baixíssima", "Baixa", "Média", "Alta", "Altíssima" (acompanhado de um ícone de ajuda).
- Tópicos:** Campo de texto com o placeholder "Selecione os tópicos da aula".
- Recurso(s) de aprendizagem:** Campo de texto com o placeholder "Selecione os recursos de aprendizagem..." e um ícone de ajuda.

Figura 7 – Tela de cadastro de um recurso didático no CX.

Caso o professor queira importar um recurso educacional espera-se que seja informado quais tópicos o recurso importado engloba. Os tópicos devem ser selecionados e são assuntos da disciplina que estão presentes nas redes bayesianas. Tal informação é relevante para que seja possível a recomendação levando em consideração o nível de conhecimento do estudante. Na Seção 4.6 há um detalhamento do nível de conhecimento do estudante.

Com todas essas informações coletadas, já se torna possível fazer uma recomendação personalizada. Também é importante reforçar que dados de estudantes podem ser constantemente atualizados. Isto vale tanto para a questão do nível de conhecimento quanto para os EA.

4.3 Módulo de Estruturação de OA

O módulo de estruturação de OA visa extrair informações de professores, estudantes e conteúdos da Web e armazenar os metadados na ontologia, buscando seguir os padrões do IEEE-LOM, como pode ser observado na Figura 3 (Marcador 2). Visando desenvolver uma abordagem de OA distribuídos e metadados centralizados, a definição dessa etapa é de grande importância e não trivial, sendo que a automatização visa enriquecer o processo com mais recursos, auxiliando posteriormente na recomendação personalizada.

Com relação à interação com professores, conforme já explicitada na seção anterior, esses devem fornecer informações acerca do conteúdo que está sendo abordado e podem cadastrar recursos didáticos que ficarão armazenados no repositório escolhido para o uso da aplicação. Os metadados acerca do conteúdo serão armazenados em uma classe da ontologia durante o processo de recomendação. Já os metadados do OA podem ser armazenados em outra classe da ontologia ou no repositório destinado ao AVA. Os AVA CX e Moodle, por exemplo, possuem gerenciamento próprio dos arquivos que são enviados por professores.

A Figura 7 é a representação de uma tela do CX. Essa tela deve auxiliar na exemplificação da etapa supracitada. Supondo que o professor esteja cadastrando um novo recurso didático. Esse deve iniciar fornecendo informações básicas do conteúdo (sendo que durante o processo de recomendação esses dados irão para a classe da ontologia que é responsável por administrar o conteúdo a ser recomendado). Em seguida, o professor informará os dados acerca do OA que está sendo armazenado. Esses metadados também podem ir para a ontologia e, caso opte por armazenar os metadados na ontologia, um atributo irá armazenar o endereço de acesso ao OA.

Outro momento com relação à estruturação dos metadados de OA para armazenamento na ontologia é o processo de recuperação de materiais da Web. Nesse caso, API auxiliam na busca de conteúdos em páginas não estruturadas, visando aumentar o leque de recursos educacionais.

Tabela 3 – Estruturação do Youtube e Wikipedia no padrão IEEE-LOM.

Metadados de OA	Wikipedia	Youtube
Título	Título da página	Titulo do vídeo
Descrição	Resumo da página	Descrição do vídeo
Palavras-chave	Conceitos utilizados na busca	Conceitos utilizados na busca
Idioma	Idioma da Página	Idioma do vídeo
Tipo de interatividade	Expositivo	Expositivo
Nível de interatividade	Baixo	Baixo
Recursos de aprendizagem	Introdução; definição; visão geral; resumo; <i>figura</i> ; <i>referência</i>	Apresentação; demonstração; analogia; <i>extração pela descrição</i>
Formato	Texto	Vídeo

A abordagem utiliza API disponibilizadas pela Wikipedia e pelo Youtube. A API do Youtube retorna um *JavaScript Object Notation (JSON)*, enquanto a API da Wikipedia retorna uma lista. Ambas trazem metadados dos conteúdos dos repositórios. A estruturação desses metadados para enquadrar no padrão IEEE-LOM ocorre de forma distinta para cada um deles. A Tabela 3 apresenta quais dados são extraídos da Wikipedia e do Youtube e também qual a referência destes dados com o conteúdo original. Nota-se que, com relação ao Youtube, os recursos de aprendizagem são mais dinâmicos.

A partir da legenda de cada vídeo, com o auxílio da interface NLTK, é possível fazer as etapas de *tokenize*, remoção de palavras vazias (*stop words*) e *stemming* e, após isso, fazer a busca por palavras que auxiliam no preenchimento de possíveis recursos de aprendizagem presentes no vídeo. Também, com essa análise, abre-se uma possibilidade de buscar densidade semântica e dificuldade através da frequência de palavras e outros metadados fornecidos pelas API.

A pesquisa realizada por Ferreira et al. (2020) buscou correlações entre dificuldade, densidade semântica, tempo de duração de vídeo, número de curtidas, número de comentários, dentre outros para tentar aumentar a quantidade de anotações automáticas a partir de metadados fornecidos pelas API oficial do Youtube e outras desenvolvidas com a finalidade de trabalhar com esses vídeos. Os resultados apresentaram uma correlação positiva e moderada entre a frequência de substantivos e a densidade semântica. Também foi possível verificar que há uma correlação neutra de curtidas, descurtidas, visualizações e comentários com dificuldade e densidade semântica. Através destes resultados, não foi possível estabelecer parâmetros para anotação automática dos metadados que dizem respeito a dificuldade e densidade semântica.

Com relação às palavras-chave, essas são preenchidas e atualizadas de acordo com cada busca. Por exemplo, se ao buscar pelos termos mitose, meiose e divisão celular, um mesmo vídeo ou página Wiki é retornada, o campo de palavra-chave vai ser preenchido com os três termos. Se um determinado recurso educacional aparece somente em uma das buscas, ele então terá como palavra-chave somente aquela busca. A Seção 4.5 trará detalhes da busca e filtros realizados para obter mais qualidade do recurso educacional.

4.4 Módulo Adaptativo

O marcador 4 da Figura 3 apresenta o módulo adaptativo. A partir desse módulo é criado os dados de entrada para a recomendação, também conhecido como *demandado do estudante*. Porém, para a criação dos dados de entrada, algumas etapas precisam ser desenvolvidas nesta seção para ficar claro o processo de geração dos dados.

Para atingir uma recomendação personalizada, é necessário o uso de informações fornecidas pelos aprendizes. Observa-se no Marcador 1 da Figura 3 que dois principais aspectos do estudante têm sido levados em consideração: nível de conhecimento e EA. Além disso,

informações dadas pelos professores são necessárias para saber sobre o conteúdo.

As informações de estudantes e professores devem ser passadas ao módulo adaptativo. Para isso, a aplicação usa o formato JSON como troca de arquivos entre o AVA que está fazendo a comunicação com professores e estudantes e a parte da abordagem responsável pelo processo de recomendação. Após reunir os dados de entrada, coletados através das interfaces (Marcador 1 e 2 da Figura 3), esses são estruturados no formato JSON e enviados ao módulo adaptativo. Ainda com relação à comunicação entre o processo de recomendação e o AVA, ao término do processamento, dados estruturados no formato JSON são retornados e estudantes podem acessar os materiais recomendados.

Com relação aos EA fornecidos pelos estudantes, esses têm influenciado principalmente na escolha do tipo de recurso de aprendizagem. Conforme reforçado no trabalho de Araújo (2017), a partir do EA de um estudante, é possível sugerir qual o tipo de recurso de aprendizagem mais apropriado. Por exemplo, OA que são do tipo figura ou gráfico, são recomendados para estudantes visuais. Por outro lado, tabela ou texto narrativo já são melhores recebidos por estudantes verbais.

As Tabelas 4 e 5 apresentam que grande parte dos recursos de aprendizagem apontados pelo IEEE-LOM e os que são estendidos pelo vocabulário CLEO podem ser associados ao FSLSM e recomendados para os estudantes. É interessante notar que alguns recursos não tiveram nenhuma associação, não permitindo criar regras para tal recurso em relação aos EA. O *recurso adicional* do vocabulário CLEO, nesta aplicação, está relacionado a qualquer perfil do estudante, pois o foco do trabalho é recomendar materiais adicionais aos estudantes, independente do perfil.

Tabela 4 – Recurso do IEEE-LOM associado ao FSLSM. Adaptado de Araújo (2017)

Padrão	Tipo de recurso de aprendizagem	Entrada	Orga- nização	Percep- ção	Processa- mento
LOM	Auto-Avaliação	verbal	-	sensitivo	ativo
	Declaração de problema	verbal	-	-	ativo
	Diagrama	visual	-	intuitivo	reflexivo
	Exame	verbal	-	-	ativo
	Exercício	verbal	-	-	ativo
	Experimento	visual	-	sensitivo	ativo
	Figura	visual	-	sensitivo	reflexivo
	Gráfico	visual	-	sensitivo	reflexivo
	índice	verbal	-	sensitivo	reflexivo
	Palestra	verbal	-	-	reflexivo
	Questionário	verbal	-	-	ativo
	Simulação	-	-	sensitivo	ativo
	Slide	-	-	-	reflexivo
	Tabela	verbal	-	sensitivo	reflexivo
	Texto narrativo	verbal	-	-	reflexivo

Tabela 5 – Recurso da extensão CLEO associado ao FSLSM. Adaptado de Araújo (2017)

Padrão	Tipo de recurso de aprendizagem	Entrada	Organização	Percepção	Processamento
CLEO	Analogia	-	-	sensitivo	reflexivo
	Apresentação	-	-	-	reflexivo
	Atrator	visual	-	-	-
	Avaliação	verbal	-	-	ativo
	Cenário	-	-	sensitivo	reflexivo
	Comunidade	verbal	-	-	ativo
	Contra exemplo	-	-	sensitivo	reflexivo
	Definição	verbal	-	intuitivo	reflexivo
	Demonstração	verbal	-	intuitivo	reflexivo
	Direção	-	Sequencial	-	-
	Esboço	-	global	-	-
	Exemplo	-	-	sensitivo	reflexivo
	Feedback	-	-	-	-
	Glossário	verbal	-	intuitivo	reflexivo
	Ilustração	visual	-	-	-
	Importância	-	-	-	-
	Introdução	verbal	-	-	-
	Item de avaliação	-	-	-	ativo
	Nota	verbal	-	-	reflexivo
	Objetivo	verbal	-	-	-
	Orientação	-	-	intuitivo	reflexivo
	Prática	-	-	sensitivo	ativo
	Pré-requisito	-	-	-	-
	Recordação	-	-	-	-
	Recurso adicional	-	-	-	-
	Referência	-	-	-	-
	Reforço	-	-	-	-
	Resumo	-	global	-	reflexivo
	Visão Geral	-	global	-	-

Além da colaboração dos EA para a escolha do tipo de recurso de aprendizagem mais adequado para um determinado estudante, também é possível utilizar informações do FSLSM para classificar automaticamente o tipo e o nível de interatividade mais propício para um determinado estudante. As Tabelas 6 e 7 trazem essas associações.

Tabela 6 – Tipo de Interatividade do padrão IEEE-LOM associado ao FSLSM. Adaptado de Araújo (2017)

Padrão	Tipo de Interatividade	Processamento
IEEE-LOM	Ativo	Ativo
	Expositivo	Reflexivo
	Misto	Ativo
		Reflexivo

Tabela 7 – Nível de Interatividade do padrão IEEE-LOM associado ao FSLSM. Adaptado de Araújo (2017)

Padrão	Nível de Interatividade	Processamento
IEEE-LOM	Muito Baixo	Reflexivo
	Baixo	Reflexivo
	Médio	Reflexivo
		Ativo
	Alto	Ativo
	Muito Alto	Ativo

O exemplo apresentado na Tabela 8 é a representação de uma entrada para o processo de recomendação e possui metadados que estão presentes nas diretrizes do IEEE-LOM. Nesse caso, os dados correspondem a um estudante que está cursando alguma disciplina da área de Ciências Biológicas. Os campos de título e palavras-chave são preenchidos com informações fornecidas pelo tutor. Estes dados estão diretamente ligados ao conhecimento que o estudante deve adquirir.

Tabela 8 – Exemplo de entrada de dados para o processo de recomendação.

Demanda do estudante		
Título	Reprodução Celular	
Palavras-chave	Mitose Meiose	Divisão celular
Tipo de Recurso Educacional	Lecture Summary Narrative Text Illustration Diagram Example Simulation Additional Resource Slide Note Analogy Graph Table Glossary	Self Assessment Presentation Practice Demonstration Nonexample Figure Definition Scenario Index Guideline Experiment Attractor Guidance
Tipo de Interatividade	Expositive	Mixed
Nível de interatividade	Very Low Medium	Low

No exemplo da Tabela 8, o modelo apontou que o estudante apresentava necessidade de aprendizagem em Reprodução Celular. Acerca do conteúdo Reprodução Celular, o professor relacionou mitose, meiose e divisão celular como assuntos. Com Relação aos EA de Felder e Silverman, o exemplo apresenta um estudante que possui as classificações

conforme a Tabela 9. Nesse caso, é possível ver que através dessas classificações, os dados de entrada sugerem que o OA a ser recomendado deve ter um dos 28 tipos de recurso educacional. Além disso, deve ter o tipo de interatividade como expositivo ou misto e o nível de interatividade como muito baixo, baixo ou médio.

Tabela 9 – Exemplo de classificação probabilística do EA de estudante.

Entrada		Organização		Processamento		Percepção	
Visual	Verbal	Global	Sequencial	Ativo	Reflexivo	Sensitivo	Intuitivo
0.9095	0.0905	0.1815	0.8185	0.0995	0.9005	1.0000	0.0000

Esta abordagem considera um modelo probabilístico de EA do estudante baseado na teoria de Felder e Silverman (ARAÚJO et al., 2020; FELDER; SILVERMAN et al., 1988). A Tabela 9 apresenta um exemplo considerando este modelo, que não classifica o estudante de maneira categórica e rígida, mas armazena uma probabilidade de preferência por um ou outro estilo dentro de cada dimensão como forma de apoiar a recomendação personalizada de conteúdo.

Visto que o trabalho desenvolvido objetiva uma recomendação personalizada, regras SWRL são utilizadas para dar suporte na geração dos dados de entrada nos campos que envolvem os EA. Com auxílio da ferramenta protégé¹, a ontologia proposta por Belizário Júnior e Dorça (2018) foi modificada para adequação a este trabalho. Nesse caso, a ontologia é classificada como uma ontologia de domínio, pois visa modelar um domínio específico. Com relação a *OWL*, o trabalho proposto utiliza a *OWL DL*. A Figura 8 apresenta uma visão geral das principais classes da ontologia, podendo perceber a representação do padrão IEEE-LOM.

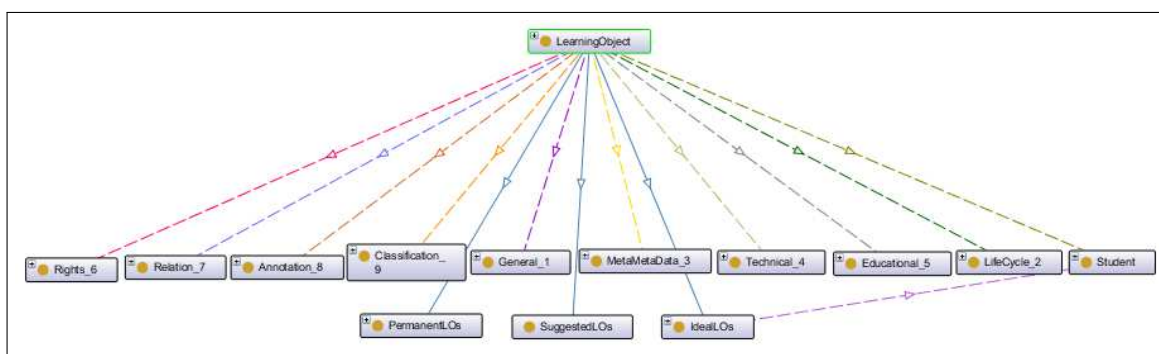


Figura 8 – Visão Geral da Ontologia

As principais modificações do modelo proposto por Belizário Júnior e Dorça (2018) para o trabalho atual foram criações de novas classes para atender a inferências que não eram tratadas anteriormente, como é o caso do nível de interatividade e tipo de interatividade, e instâncias para cobrir todos os tipos de recursos educacionais que são apresentados no CLEO e IEEE-LOM. Vale ressaltar que no trabalho de Belizário Júnior

¹ <https://protege.stanford.edu/>

e Dorça (2018) havia citado alguns recursos educacionais do CLEO. As regras SWRL criadas para este trabalho estão no Apêndice B.

No Apêndice B, é observado que as regras de inferência estão sendo utilizadas para determinar os tipos e níveis de interatividade e também os tipos de recursos de aprendizagem ideais para a aprendizagem de um determinado estudante. As regras não são determinantes para a recomendação, porém satisfazem ao auxiliar no que se espera do OA. A partir dessas regras, é possível preencher as três linhas finais da Tabela 8 que serve como entrada de dados para o processo de recomendação personalizada.

4.5 Módulo de Recomendação

A recomendação desenvolvida para este trabalho, apresentada na Figura 3 pelo Marcadador 6, é capaz de utilizar OA do repositório associado à abordagem e amplia a busca por recursos da Web (tanto conteúdos não estruturados, quanto repositórios de OA). Nesse aspecto, esta pesquisa apresenta um modelo de recomendação que ocorre em duas etapas. Os recursos de Web Semântica são utilizados para a recomendação de OA a partir de metadados armazenados na ontologia e repositórios associados ao AVA. Já para a recuperação e recomendação de recursos Web ainda não estruturados em formato de OA, são utilizados também algoritmos bioinspirados.

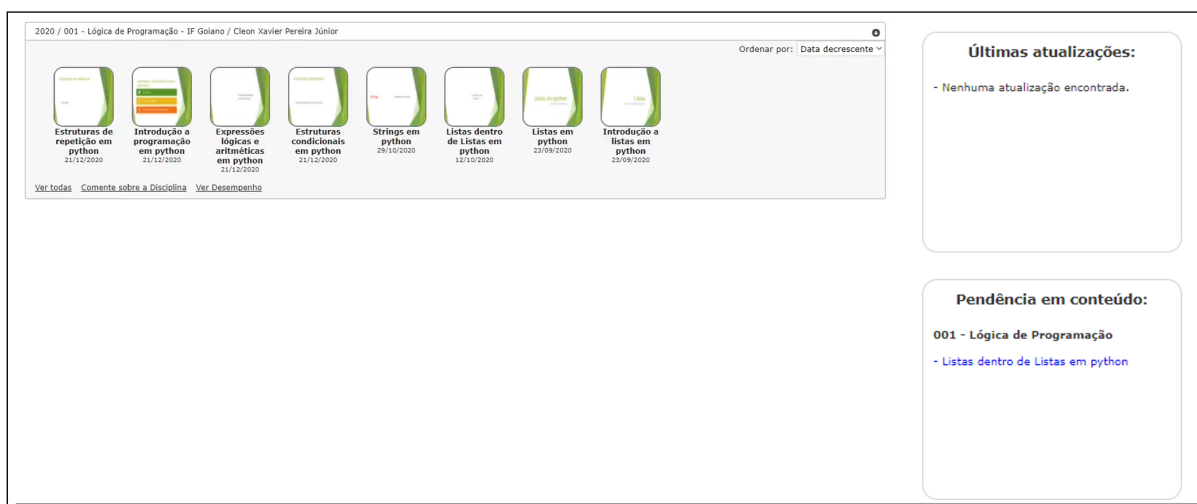


Figura 9 – Recomendação de conteúdo a partir do desempenho

O processo de recomendação nesta abordagem leva em consideração o nível de conhecimento do estudante e os EA. Com relação ao nível de conhecimento, a Seção 4.2 apresenta as possibilidades de captura e a Seção 4.6 detalha o modelo do estudante. Uma vez que se tem capturado o desempenho do estudante, materiais cedidos por tutores e vinculados a tópicos da disciplina são recomendados de acordo com as necessidades dos estudantes. Ao ser direcionado para a área destinada para acessar o material ofertado pelo tutor, estudantes podem acessar materiais que também são recomendados de acordo

com o tópico e levam em consideração os EA. A Figura 9 apresenta um exemplo de recomendação a partir do nível de conhecimento do estudante.

A partir do nível de conhecimento, a recomendação leva em consideração os EA para apresentar materiais extras para estudantes. Conforme já mencionado, o processo de recomendação é híbrido com relação às tecnologias, porém a filtragem é baseada em conteúdo. Foi desenvolvido um modelo que utiliza diferentes técnicas para recomendar conteúdos que já estão armazenados na ontologia e conteúdos recuperados da web.

Uma das possibilidades de armazenamento de metadados é a ontologia. Nesse caso, a abordagem desenvolvida é responsável por gerenciar todos os metadados fornecidos por tutores e estudantes. Na recomendação utilizando metadados armazenados na ontologia, os EA do estudante são levados em consideração. Isto é, para um determinado conteúdo, os recursos de aprendizagem recomendados vão de acordo com os EA do estudante. Com as modificações apresentadas na ontologia é possível inferir, de forma automática, o tipo de recurso educacional, tipo de interatividade e nível de interatividade que um OA deveria ter somente com os EA de um estudante. A Tabela 8, nas três últimas linhas, é o resultado da execução das inferências. Por esse motivo, os termos estão em inglês.

Apesar de todas essas informações, a recomendação personalizada que se limita aos recursos armazenados na ontologia leva em consideração somente o tipo de recurso educacional para filtrar os OA disponíveis. A decisão foi tomada levando em consideração que esses repositórios criados para gerenciamento de OA possui um número menor de materiais se comparado a toda a Web, conforme observado em Medio et al. (2019), e o excesso de filtros pode dificultar o retorno de OA.

Tendo a nova configuração da ontologia, o desafio no processo de recomendação dos recursos que possuem metadados armazenados somente na ontologia se dá em apresentar ao estudante os OA que cubram os conceitos de um determinado conteúdo. As palavras-chave de um determinado conteúdo são consideradas como conceitos importantes sobre esse conteúdo. O correto cadastro pelo professor é requisito para uma boa recomendação.

No exemplo apresentado na Tabela 8 é possível ver 3 palavras-chave para o conteúdo de reprodução celular, sendo elas: mitose, meiose e divisão celular. Nesse caso, após a seleção inicial dos OA através de regras de inferência, buscando somente os que estão de acordo com os EA do aprendiz, a segunda etapa é a filtragem de OA que sejam relevantes para o conteúdo. Para conseguir um melhor sucesso nessa filtragem, foi construída uma aplicação em Python que recebe os metadados de OA recomendados pela ontologia, de acordo com os EA, e filtra levando em consideração o conteúdo.

A filtragem levando em consideração as palavras-chaves ajuda na busca de materiais relevantes que já estão armazenados. Esses metadados de OA podem ter sido disponibilizados por tutores ou recuperado da Web e, após avaliação, se tornado permanente na ontologia. Visando ampliar essa busca por conteúdos dessa ontologia, também foi implementado um módulo capaz de ampliar as palavras-chaves com conteúdos relacionados.

Semelhante ao trabalho executado em Dias et al. (2017), esta proposta tem utilizado recursos da DBPedia para ampliar as possibilidades de busca por materiais relacionados a um determinado conteúdo. Considere uma Entrada de dados para o processo de recomendação I_j como uma tupla $I_j = \langle r_1, r_2, r_3, \dots, r_n \rangle$ em que r_j representa uma palavra-chave dos metadados utilizados para o processo de recomendação e devem ser associados com recursos da DBPedia (URIs).

Os recursos da DBPedia, conhecidos como URIs, servem para identificar pessoas, lugares, dentre outros. Neste trabalho, como também realizado em Dias et al. (2017) esse recurso é uma página da Wikipedia que pode descrever um assunto qualquer. Desse modo, Dias et al. (2017) formaliza esse recurso como uma tupla $r_j = \langle uri_j, L(r_j), C(r_j), P(r_j) \rangle$ e uri_j representa o identificador do recurso (conforme apresentado na DBPedia), $L(r_j)$ o conjunto de rótulos (nomes) deste recurso, $C(r_j)$ representa o conjunto de categorias e $P(r_j)$ representa as propriedades do recurso.

Com o apoio de uma API disponível para trabalhar com dados da Wikipedia, uma palavra-chave é então transformada no rótulo correto a um recurso correspondente da DBPedia. Por exemplo, ao fazer uma busca pelo termo *ciclos celulares*, é possível determinar que a página correspondente na Wikipedia é *Ciclo celular* (que também é o $L(r_j)$) e um recurso r_j seria $\langle \text{http://pt.dbpedia.org/resource/Ciclo_celular} \rangle$.

Apesar do crescimento da DBPedia em português, ainda existem poucos recursos conectados o que limitaria a busca por itens relacionados. Nesse aspecto, ainda conforme Dias et al. (2017), este trabalho realiza uma busca nas bases em inglês. Através da propriedade *owl : sameAs*, é possível encontrar o recurso em inglês. Considere então a função $f(r_j@EN)$ para retornar o recurso correspondente em inglês. Ao executar $f(r_j@EN)$ tem-se que o recurso (r'_j) correspondente para o exemplo anterior seria $\langle \text{http://dbpedia.org/resource/Cell_cycle} \rangle$.

A importância do uso da base em inglês neste momento, é conseguir um resultado mais amplo de termos associados a uma categoria (que na aplicação está associada a uma palavra-chave). No caso do exemplo $r'_j \langle \text{http://dbpedia.org/resource/Cell_cycle} \rangle$ o $C(r'_j)$ correspondente é $\langle \text{http://dbpedia.org/resource/Category:Cell_cycle} \rangle$. O desafio agora está em relação as buscas por categorias relacionadas ao $C(r'_j)$. Existem duas propriedades da DBPedia (*skos : broader* e *skos : broader_of*) que, análogo a uma árvore hierárquica, representam os pais (*skos : broader*) e filhos (*skos : broader_of*) de um determinado recurso. Através destas propriedades, é possível ter uma abrangência de uma determinada categoria.

Para $C(r'_j)$ tem-se que $C^+(r'_j)$ representam as categorias pais de $C(r'_j)$ e $C^-(r'_j)$ representam as categorias filhas. Neste trabalho, espera-se ter um resultado $\alpha(r'_j) = C^+(r'_j) \cup C^-(r'_j)$ e a partir desse resultado, aplicar a função $f(\alpha(r'_j)@Pt)$ para enfim conseguir os termos em português. O resultado da função $f(\alpha(r'_j)@Pt)$ para a categoria *Cell_cycle* seria: Citologia, Ciclo celular e Mitose.

Conforme apresentado nos parágrafos anteriores, a palavra-chave ciclo celular, através do uso de funções da DBPedia, permite fazer uma busca mais abrangente, acrescentando outros dois termos (citologia e mitose). Uma nova seleção deve ser realizada ao fim para eliminar os termos que já estão presentes nas palavras-chave. Por exemplo, se a busca tivesse sido realizada de acordo com o que foi apresentado na Tabela 8, a palavra mitose deveria ser eliminada, restando citologia.

A implementação do módulo de busca na ontologia, sem levar em consideração outros materiais, é útil para estudos que visam ter o controle total dos OA que podem ser recomendados a estudantes no processo de aprendizagem. Como a abordagem desenhada para esta pesquisa tem intenção de explorar a possibilidade de materiais da Web serem recomendados em forma de OA, esta etapa é essencial para a criação de uma arquitetura independente, porém é somente a base para de fato buscar uma investigação de recomendação a partir de materiais disponibilizados na Web.

Grande parte dos sistemas de recomendação de OA exploram repositórios que foram criados para a finalidade de aprendizagem e realizam a personalização de acordo com o conteúdo e/ou perfil do estudante. Por outro lado, há um crescimento de conteúdos na Web, que não estão estruturados em repositórios educacionais, mas que podem ter a mesma finalidade. Nesse sentido, a segunda etapa de recomendação desta pesquisa visa recuperar conteúdos da Web, gerar metadados de OA e, por fim, realizar uma recomendação personalizada com a oportunidade de expansão dos recursos educacionais.

Considerando a necessidade de uma busca Web a fim de expandir os recursos de aprendizagem, nessa etapa da recomendação, três principais API são utilizadas, sendo elas: *Youtube Data API*, *Wikipedia API* e *Youtube Transcript API* para auxiliar no processo de recuperação de conteúdos disponíveis. A partir dos dados de entrada previamente gerados pelas regras de inferência (conforme observado o exemplo da Tabela 8), são realizadas buscas na Web através das API. Este trabalho tem utilizado conteúdos oriundos da Wikipedia e Youtube.

Através da combinação dos termos encontrados nas palavras-chave e títulos disponíveis nos dados de entrada, as funções de busca das API são utilizadas. No caso do Youtube, ainda na função de busca são colocados parâmetros para retornar somente materiais da categoria educacional e com duração entre 04 e 20 minutos. O tempo de duração foi estabelecido levando em consideração dados levantados por Almeida e Carvalho (2018). Já na Wikipedia, não é aplicado esse filtro, porém é possível encontrar trabalhos que utilizam algoritmos para analisar o nível de relevância do conteúdo de uma página.

Os OA são recomendados a partir do perfil do estudante, e devem conseguir cobrir todos os conceitos de um determinado conteúdo. Para isso, deve-se computar o quão similar é o conteúdo candidato a ser recomendado dos dados de entrada. A ideia geral para a escolha dos melhores OA também é baseada no trabalho de Belizário Júnior (2018).

Para exemplificar o modelo, suponha que além dos três conceitos, representados por

palavras-chave no exemplo da Tabela 8 (Mitose, Meiose e Divisão celular), existam mais dois. Sendo assim, um estudante precisa aprender cinco conceitos representados pelo conjunto $X = \{K_1, K_2, K_3, K_4, K_5\}$. Para cobrir esses conceitos, são utilizados OA candidatos. Nesse caso, considere F uma coleção de subconjuntos de X , como $F = \{OA_1, OA_2, OA_3, OA_4, OA_5, OA_6\}$, em que $OA_1 = \{K_1, K_2\}$, $OA_2 = \{K_3\}$, $OA_3 = \{K_4, K_5\}$, $OA_4 = \{K_5\}$, $OA_5 = \{K_2, K_3, K_4, K_5\}$ e $OA_6 = \{K_2, K_3\}$. Cada OA tem um custo calculado por sua similaridade com as especificações do instrutor. Para este exemplo, considere o vetor $(3,7,1,1,4,2)$ que representa os custos dos OA na mesma ordem que em F . A Figura 10 representa este exemplo.

MATRIZ DE ENTRADA						
	OA₁	OA₂	OA₃	OA₄	OA₅	OA₆
K₁	1	0	0	0	0	0
K₂	1	0	0	0	1	1
K₃	0	1	0	0	1	1
K₄	0	0	1	0	1	0
K₅	0	0	1	1	1	0

VETOR DE CUSTO					
3	7	1	1	4	2

Figura 10 – Exemplo de uma Matriz Binária e seu Vetor de Custo.

O objetivo é encontrar um subconjunto de OA, a um custo mínimo, que cubra todos os conceitos. Assim, a solução proposta está usando a teoria do PCC, ou *SCP* (CORMEN et al., 2009). A partir de uma matriz binária a_{ij} com m linhas e n colunas, o SCP tenta cobrir todas as linhas usando um subconjunto das colunas a um custo mínimo. Dado $x_j = 1$, se a coluna j (com custo $c_j > 0$) estiver na solução e $x_j = 0$, caso contrário, então o SCP é definido como:

$$\text{Minimize } \sum_{j=1}^n c_j x_j \quad (1)$$

$$\text{Sujeito a } \sum_{j=1}^n a_{ij} x_j \geq 1, \quad i = 1, \dots, m \quad (2)$$

$$x_j \in \{0, 1\}, \quad j = 1, \dots, n \quad (3)$$

De acordo com o exemplo anterior, a solução $\{OA_1, OA_3, OA_6\}$ tem custo igual a 6. Portanto, o custo de cada OA recomendado é calculado em relação aos dados de entrada, de acordo com o grau de similaridade, e, quanto menor o custo, mais próximo é o OA recomendado do que está proposto para o sujeito.

Antes de dar prosseguimento ao processo de recomendação, é preciso entender como é calculado o custo de cada OA. A função c_j representa o custo do OA potencial a ser recomendado (isto é, que cobre ao menos uma das palavras-chave) e é representada como:

$$c_j = \sum_{i=1}^y |\alpha_{i(\text{entrada})} - \alpha_{i(j)}|, \quad (4)$$

onde α_i representa um parâmetro, isto é, um metadado do OA. Os y parâmetros utilizados para realizar o cálculo do custo de um OA são:

- Tipo de interatividade: Cada item do vocabulário do campo recebe um valor e no caso de um tipo misto $|\alpha_{i(\text{entrada})} - \alpha_{i(j)}| = 0$, já os demais como seguem:
 - ativo = 0;
 - expositivo = 1.
- Tipo de Recurso de aprendizagem: nesse caso, aplica-se o cálculo do cosseno de similaridade para verificar o quão similar os tipos de recurso de aprendizagem presentes no OA a ser recomendado é do OA ideal.
- Nível de interatividade: Neste caso, se o OA for do tipo médio, $|\alpha_{i(\text{entrada})} - \alpha_{i(j)}| = 0$, para os demais o vocabulário de cada item recebe os seguintes valores:
 - muito baixo ou baixo = 0;
 - alto ou muito alto = 1.
- Densidade semântica: Cada item do vocabulário do campo recebe um valor, sendo:
 - Muito baixo: 0;
 - Baixo: 0.25;
 - Médio: 0.5;
 - Alto: 0.75;
 - Muito Alto: 1.
- Dificuldade: Cada item do vocabulário do campo recebe um valor, sendo:
 - Muito fácil: 0;
 - Fácil: 0.25;
 - Médio: 0.5;
 - Difícil: 0.75;
 - Muito Difícil: 1.

Uma vez que o vocabulário misto do parâmetro *tipo de interatividade* e o vocabulário médio do parâmetro *nível de interatividade* sempre aparecerão nos dados de entrada, esses são utilizados apenas para efetuar o cálculo caso o OA apresente essas configurações. Suponhamos um OA com as seguintes configurações: tipo de recurso educacional = *lecture*, tipo de interatividade = *active* e nível de interatividade = *very low*. Esse OA terá custo igual a 1 por ser ativo e esperava um tipo de interatividade expositiva. No nível de interatividade $|\alpha_{i(\text{entrada})} - \alpha_{i(j)}| = 0$. Já o tipo de recurso de aprendizagem é realizado um cálculo de similaridade que resulta num valor entre 0 e 1. Os níveis de dificuldade e densidade semântica também podem ser calculados.

Após calcular o custo de cada OA, a próxima etapa consiste no uso de um algoritmo bioinspirado que consiga resolver o PCC. O motivo do uso de um algoritmo bioinspirado é por esse ser um problema complexo e de crescimento exponencial. No próximo capítulo serão discutidos os experimentos realizados para a seleção do melhor algoritmo de acordo com os cálculos aqui apresentados.

Por fim, depois de realizar o processo de FBC, o estudante deve receber o material fornecido pelo professor (normalmente os slides da aula) e materiais recomendados que devem ajudar na absorção do conhecimento e no reforço da aprendizagem (Marcador 7 da Figura 3). A Figura 11 apresenta um exemplo de visualização de slides de um conteúdo, junto com a possibilidade de acesso a materiais recomendados de forma personalizada. Nesse caso, foi configurado para a possibilidade aparecer somente no último slide, dando prioridade para o material cedido pelo tutor.

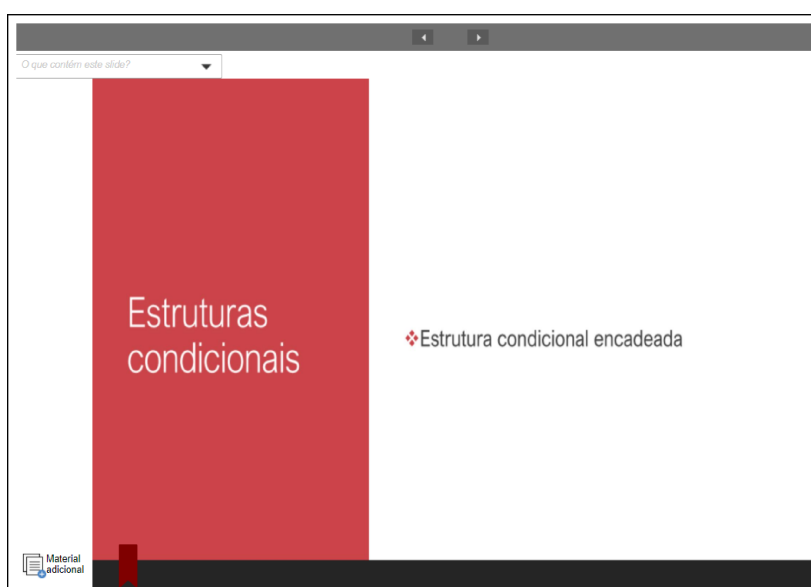


Figura 11 – Apresentação para estudantes.

A Figura 12 apresenta, através de exemplo, mais alguns detalhes de como os materiais são fornecidos. Os materiais são agrupados por tipo de recurso educacional e pode ser somente um ou vários, a depender do retorno dado pelo algoritmo de acordo com a

demanda do estudante. Conforme já mencionado, a abordagem realiza buscas no Youtube e na Wikipedia.

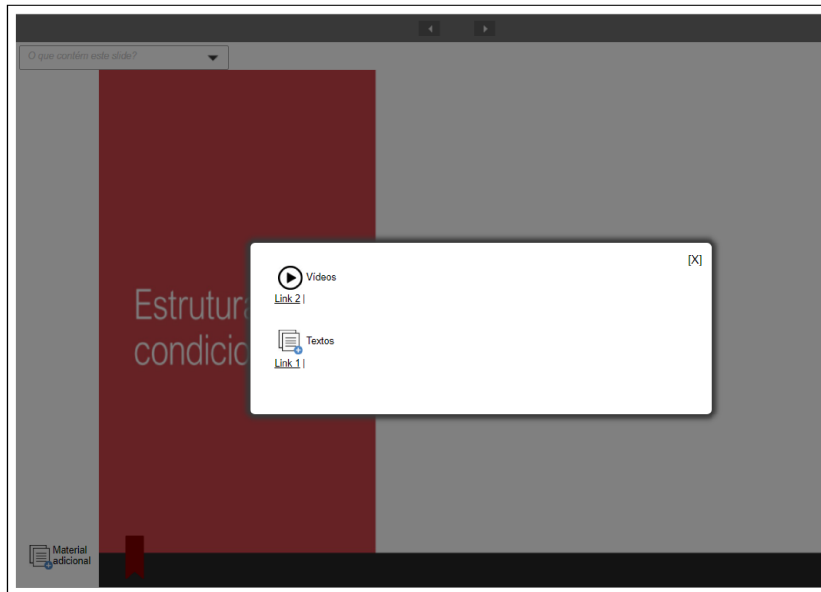


Figura 12 – Apresentação para estudantes no CX.

A Figura 13 apresenta uma visualização do retorno de materiais extras, a partir de um conteúdo específico, no AVA Moodle. O AVA Moodle apresenta a possibilidade de divisão de conteúdo por tópicos. Aproveitando desse esquema, foi desenvolvido um recurso que permite o professor acrescentar no tópico para que estudantes possam solicitar materiais. Caso o estudante não tenha respondido o questionário ILS, aparecerá uma tela pedindo para que o estudante preencha, podendo este recusar a solicitação.

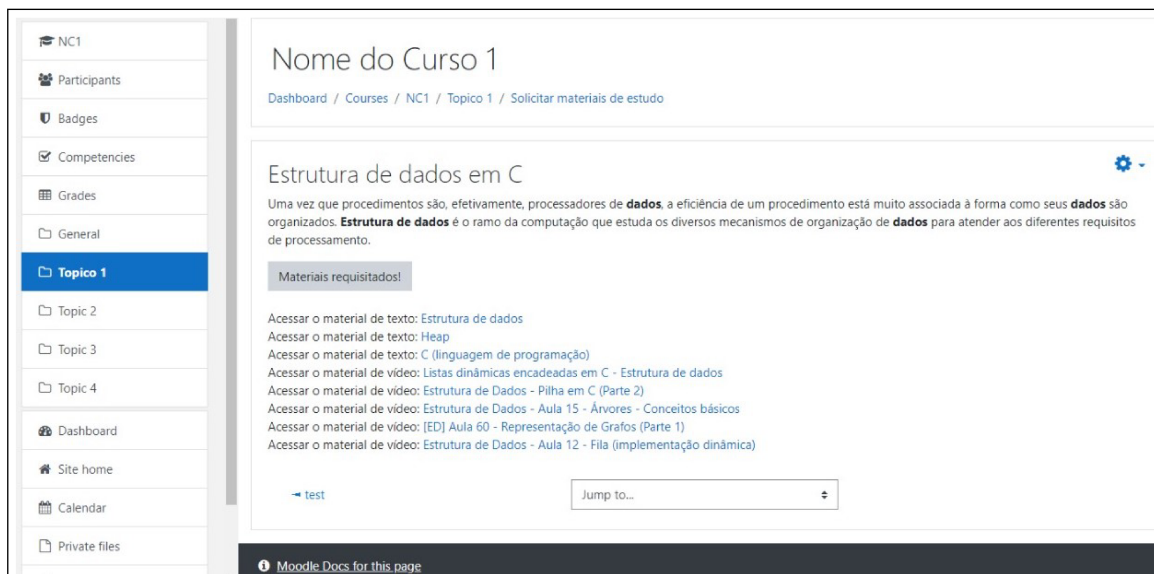


Figura 13 – Apresentação para estudantes no Moodle.

Como alternativa para contornar o *cold start*, caso o estudante não tenha fornecido dados pessoais que auxiliem na recomendação de conteúdos, o conteúdo a ser recomendado

levará em consideração que todos os valores do ILS terá 0.5. A Tabela 9 apresenta um exemplo de EA probabilístico com alguns dados já coletados, por isso os valores são diferentes de 0.5.

4.6 Modelo do Estudante

Um dos módulos presentes na arquitetura clássica de um sistema tutor inteligente é o Modelo do Estudante (ME). Na Figura 3, através do Marcador 3 é possível observá-lo. O ME pode ser entendido como um modelo de dados que representa um conjunto de informações sobre o estudante, tais como informações pessoais, nível de conhecimento, preferências, dentre outras informações e que se torna essencial para a adaptação individualizada (GILMAN et al., 2014; FERREIRA, 2018). Esse módulo é de extrema importância para a atualização do perfil do estudante que está interagindo com o AVA.

Ainda dentro da definição de ME, para o desenvolvimento da modelagem, abordagens distintas podem ser utilizadas, como é o caso de: sobreposição (*overlay*), esteriótipos (*stereotypes*), aprendizado de máquina, redes bayesianas e ontologias (FERREIRA, 2018). Na intenção de enriquecer essa abordagem acerca do ME, este trabalho apresenta um modelo que combina ontologias e redes bayesianas, parte desenvolvido e apresentado no trabalho de Ferreira (2018). A Figura 14 apresenta um exemplo de rede bayesiana representando as probabilidades de conhecimento.

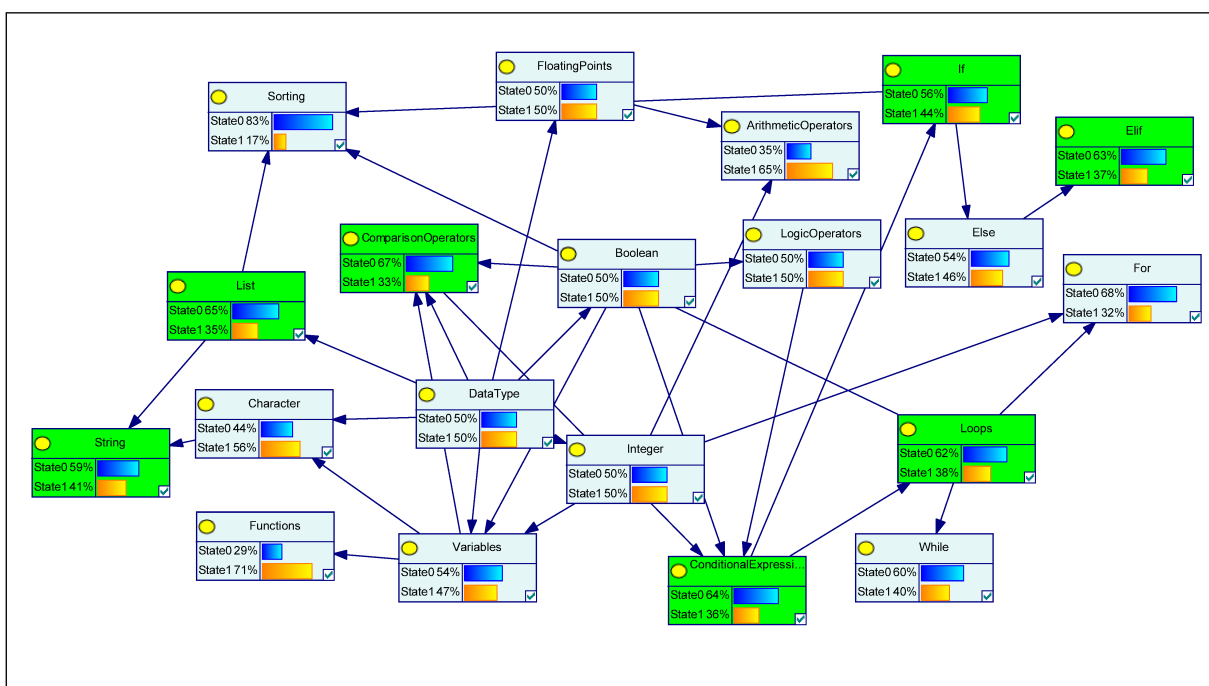


Figura 14 – Exemplo de Rede Bayesiana representando probabilidade de conhecimento em alguns conceitos.

Observando a Figura 14 nota-se que, para cada nó, existe o *State0* e *State1*. O *State1* representa a porcentagem da probabilidade de conhecimento naquele assunto e o *State0*

o contrário. Sendo assim, para o exemplo apresentado na figura, o estudante tem 17% de probabilidade de ter conhecimento em ordenação. Já para o conteúdo de funções, o estudante tem 71% de probabilidade. A principal vantagem em combinar o trabalho atual com um ME proposto anteriormente é que na abordagem apresentada por Ferreira (2018) o modelo é independente de domínio e, além de trazer informações acerca do nível de conhecimento, conforme já apresentado brevemente na Seção 4.2, também leva em consideração o comportamento do estudante.

Para o uso do ME de forma efetiva, é necessária a criação de redes bayesianas que representem o domínio da abordagem, como a apresentada na Figura 14. Dessa forma, através da rede bayesiana, é possível fazer inferências com relação ao nível de conhecimento do aprendiz. Essa rede possui nós que representam conceitos e, para cada conceito, existe a probabilidade dele acontecer. Os conceitos são organizados de forma hierárquica, conforme a arquitetura das redes Bayesianas.

O trabalho de Ferreira (2018) apresenta uma ontologia para a modelagem do estudante que possui informações pessoais (incluindo o FSLSM), comportamento, contexto e conhecimento. Apesar do modelo proposto por Ferreira (2018) incluir o FSLSM, neste trabalho estes EA são tratados na ontologia adaptada para esta abordagem, compondo assim o processo de inferência e recomendação personalizada para a abordagem proposta nesta pesquisa.

4.7 Síntese do Capítulo

O capítulo apresentou a abordagem proposta nesta pesquisa para auxiliar como suporte às questões levantadas neste trabalho. Até o momento, é mais comum o uso de SR em ambientes não educacionais. Mesmo não sendo comum o uso no cotidiano em ambientes educacionais, há uma gama de pesquisas que exploram os SR personalizada para entrega de materiais, caminhos de aprendizagem, dentre outros, conforme apresentado no Capítulo 3. Este trabalho se diferencia ao apresentar uma abordagem híbrida em tecnologia e que recupera materiais da Web, mesmo em ambientes não educacionais, para recomendar como OA.

O objetivo geral deste trabalho aponta para a necessidade de uma abordagem dinâmica para recuperação de conteúdo Web para sua posterior recomendação personalizada em forma de OA. com isso, este capítulo atende tanto o objetivo geral, quanto os objetivos específicos, que estão intrinsecamente ligados ao desenho dos módulos desta abordagem. Sendo assim, o próximo capítulo busca validar a proposta desenvolvida aqui para, em seguida, responder as questões de pesquisa levantadas neste trabalho.

Experimentos e Análise dos Resultados

Esta pesquisa foi submetida ao Comitê de Ética em Pesquisa (CEP) do Instituto Federal Goiano (local de coleta de dados), sob o Certificado de Apresentação de Apreciação Ética (CAAE) 34300620.0.0000.0036, e teve sua aprovação, conforme parecer 4.254.746. A primeira etapa consistiu na análise comparativa de algoritmos bioinspirados que pudessem dar suporte no processo de recomendação levando em consideração o PCC. Tal experimento está diretamente ligado ao marcador 6 da Figura 3. O segundo experimento consistiu na criação de uma interface independente que permitia a seleção de estudante e de conteúdo. Tal experimento serviu para validar o funcionamento do ciclo proposto na Figura 3. Uma vez validado o ciclo proposto, os experimentos seguintes consistiu na acoplagem da abordagem em AVA.

Após acoplar a abordagem no AVA, o próximo experimento se deu em validar a possibilidade de recomendação de materiais utilizando dados do AVA. Para isso, a partir de consultas no banco de dados do AVA, foram selecionados dados de estudantes e de conteúdos de aulas previamente cadastradas. Com esses dados foi realizado um experimento que permitiu visualizar a potencialidade da recomendação, a diversidade de materiais recomendados e o comportamento da abordagem para distintas entradas.

Uma vez validada a abordagem no AVA CX, foi criado um componente também para o AVA Moodle para verificar se o SR é fracamente acoplado a um determinado AVA, isto é, se é possível utilizar em diferentes AVA. O recurso criado para o Moodle teve um bom comportamento e trouxe resultado satisfatório com relação à acoplagem da abordagem. O componente foi melhor descrito no capítulo anterior.

O Experimento 4 iniciou com a criação de uma turma no AVA CX e testes com estudantes voluntários dessa turma. De forma espontânea, estudantes poderiam responder sobre o quão relacionado um determinado OA recomendado estava com o conteúdo que ele estava estudando e se aquele OA contribuiu para aprendizagem. Após um período de adaptação com a ferramenta, estudantes voluntários responderam questionários da percepção sobre a recomendação.

O último experimento visou comparar o módulo de recomendação em diferentes ce-

nários que envolveram os EA. Na intenção de validar a qualidade da abordagem, ao término do uso dos SR os estudantes voluntários foram convidados a responder acerca do sistema, através do questionário ResQue. Os resultados apresentados através do questionário ResQue permitiu ter uma visão geral do SR e, por tratar de um comparativo de três recomendações distintas, também permitiu realizar algumas análises estatísticas. As seções a seguir trazem um detalhamento de cada etapa dos experimentos executados nesta pesquisa.

5.1 Experimento 1: Algoritmo de recomendação

A primeira investigação que envolveu experimentos nesta pesquisa foi com relação a escolha do algoritmo de recomendação. A partir de buscas por trabalhos correlatos, notou-se que é comum a adoção de algoritmos bioinspirados para ambientes de recomendação personalizada, como observado no Capítulo 3. Além disso, a proposta apresentada por Belizário Júnior e Dorça (2018) e que foi usada como base para este trabalho, utiliza um AG para a solução. A solução apresenta vantagem do AG em relação a um método aleatório, mas não compara com outras abordagens.

Ao fazer uma revisão da literatura, verificou-se comparações de AG com outros algoritmos evolutivos e também algoritmos de inteligência de enxame. Por essa razão, em busca da estratégia que obtivesse o melhor resultado num tempo mais ágil, esta pesquisa optou por testar e comparar três estratégias distintas para o problema de recomendação, utilizando o PCC. São elas: AG de Whitley (1994), Algoritmo Presa Predador (APP) de Tilahun e Ong (2015) e uma adaptação do PSO, chamada *Jumping Particle Swarm Optimization (JPSO)*, de Balaji e Revathi (2016).

AG e APP são considerados algoritmos evolutivos. Apesar de serem de categorias diferentes, JPSO e AG são frequentemente comparados para diversos problemas. Além disso, na literatura, o APP foi comparado com PSO e AG (TILAHUN; ONG, 2015). Em relação ao JPSO, é uma adaptação utilizada em problemas como o PCC (BALAJI; REVATHI, 2016). Com base nas comparações da literatura, este trabalho foi motivado para comparar os três algoritmos na intenção de verificar qual apresenta melhor desempenho no problema de recomendação de OA utilizando a formalização do PCC. Como entrada para os algoritmos, tem-se uma matriz binária e um vetor de custo, exemplificado na Seção 4.5 pela Figura 10. Nas próximas subseções, serão apresentados o método e os resultados dessas implementações.

5.1.1 Método

Na intenção de analisar o comportamento dos três algoritmos supracitados (AG, APP e JPSO) para o problema de cobertura por conjuntos aplicado na busca e seleção de OA, este experimento foi dividido em duas etapas. A primeira parte visou replicar os dados obtidos

por Belizário Júnior e Dorça (2018) e comparar com mais dois algoritmos bioinspirados. A segunda etapa buscou comparar os três algoritmos levando em consideração o mesmo tamanho de população inicial para verificar o comportamento.

Com relação às bases de dados testadas, primeiramente trabalhou-se com a instância 4.10 disponível no *benchmark* OR-library¹. Essa instância é representada por uma matriz de 200x1000 e seu vetor de custo. É sabido pela literatura que essa instância tem uma solução ótima igual a 514 como resultado de sua função objetivo (*fitness*). Cada algoritmo foi submetido à base, sendo que o AG teve uma população inicial de 100 indivíduos, na intenção de alcançar os resultados apresentados por Belizário Júnior e Dorça (2018). Os algoritmos APP e JPSO tiveram uma população inicial de 10 indivíduos.

A segunda instância submetida ao teste possuía uma representação em matriz de tamanho 10x200. Isto é, existiam 200 OA para cobrir 10 conceitos. Esse teste apresenta uma situação mais próxima do que é esperado no ambiente real. A critério de informação, para esse segundo teste foram utilizados conceitos de reprodução celular de uma disciplina de biologia. Os conceitos foram: Reprodução, Mitose, Meiose, Célula, Tecido Adiposo, Tecido Conjuntivo, Epitélio, Protista, Animália e Plantae. Apesar de utilizar termos reais, os metadados dos OA dessa base foram preenchidos com valores totalmente aleatórios. O tamanho da população foi o mesmo do primeiro teste. Também foi colocado em consideração o tempo gasto pela abordagem passando por todos os processos, porém sem realizar as buscas nas bases externas.

Todos os testes apresentados na primeira etapa foram executados em uma máquina com processador Intel Core i5 e 4Gb de RAM. Foram verificados o tempo de execução, número de gerações/iterações e *fitness*, gerando dois gráficos para cada um dos testes. Além disso, cada teste foi repetido 10 vezes.

A segunda etapa consistiu em utilizar os algoritmos desenvolvidos pela primeira etapa e também as bases de dados utilizadas na etapa anterior. Diferente da primeira etapa, esta etapa considerou a população inicial de tamanho 10 para todos os algoritmos. Tal modificação foi realizada para observar os comportamentos dos algoritmos tendo população inicial iguais. Cada teste foi repetido 30 vezes. Todos os testes apresentados foram executados em uma máquina com processador Intel Core i7 (8ª geração) e 8Gb de RAM. Foram verificados o tempo de execução, número de gerações/iterações e *fitness*.

5.1.2 Resultados e análise

O primeiro teste executado foi da instância 4.10, cuja matriz de entrada possui tamanho 200x1000. A Figura 15 traz o resultado da execução. A apresentação no gráfico é referente à média das dez execuções. O gráfico que compara o tempo de execução com o *fitness* traz o Desvio Padrão (DP) das execuções. Além disso, a Tabela 10 apresenta o comparativo dos algoritmos a cada 50 gerações.

¹ <http://people.brunel.ac.uk/mastjjb/jeb/orlib/scpinfo.html>

Para os gráficos, assumiu-se que todas as iterações do algoritmo utilizaram o mesmo tempo de execução, fazendo um cálculo a partir do tempo total. Nos dois gráficos, é possível observar que o JPSO obteve um melhor desempenho. Também é possível ver que, apesar do AG demandar menos tempo para aproximar da solução ótima, esse necessitou de mais iterações, segundo os experimentos. Tanto o AG quanto o JPSO encontraram a solução ótima a partir de uma determinada iteração (sendo que o AG não foi possível visualizar no gráfico pois demandou mais gerações). O APP, nas 10 execuções, mesmo aumentando o número de iterações só conseguiu chegar próximo da solução ótima.

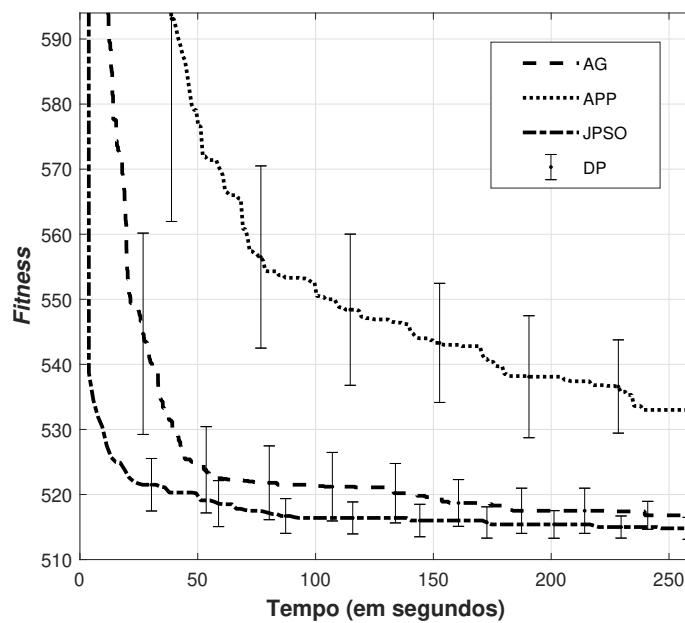
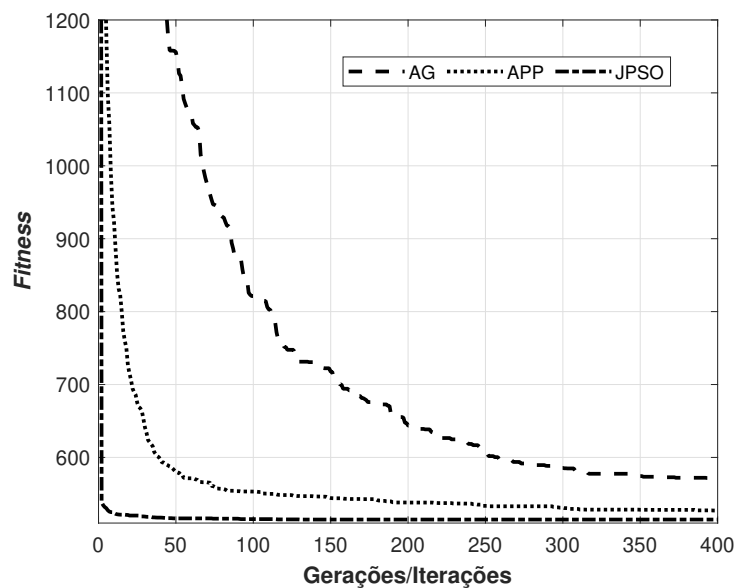
(a) Comparativo de Tempo *vs* Fitness(b) Comparativo de Iterações/Gerações *vs* Fitness

Figura 15 – Desempenho dos algoritmos para uma entrada de tamanho 200x1000

O teste cujos gráficos foram representados pela Figura 15 foi executado para visualizar o desempenho dos algoritmos em uma situação hipotética. Em geral, não espera-se que sejam utilizados 200 conceitos em um único conteúdo quando a abordagem for submetida a um ambiente real. Sendo assim, o segundo teste (instância 10x200) foi executado para verificar o comportamento dos algoritmos em uma instância menor e o resultado está apresentado na Figura 16.



(a) Comparativo de Tempo *vs* Fitness(b) Comparativo de Gerações/Iterações *vs* Fitness

Figura 16 – Desempenho dos algoritmos para uma entrada de tamanho 10x200

No cenário apontado pela Figura 16, o AG e APP obtiveram desempenho melhor que o JPSO com relação ao tempo de execução. Para essa amostra menor, todos os algoritmos conseguiram chegar na solução ótima, conforme é possível ver na Figura 16(b). Esse cenário, apesar de simulado, representa algo próximo do que deve ocorrer em ambientes

reais utilizando a abordagem desenvolvida nesta pesquisa. Dessa forma, todos os três algoritmos atenderiam satisfatoriamente a abordagem. A Tabela 10 apresenta os resultados médios, desvio padrão, maiores e menores valores obtidos a cada 50 iterações.


Tabela 10 – Comparativo da execução dos algoritmos bioinspirados para problema de recomendação.

Ger. iter.	Téc. n.	200x1000				10x200			
		Média	D.P.	Menor	Maior	Média	D.P.	Menor	Maior
50	AG	1155,80	50,70	1079	1274	3,27	0,22	2,74	3,59
	JPSO	516,40	2,33	514	520	2,55	0,06	2,46	2,61
	APP	579,90	27,68	529	618	2,49	0,04	2,46	2,57
100	AG	821,30	30,20	788	876	3,08	0,15	2,74	3,27
	JPSO	515,40	2,01	514	520	2,54	0,06	2,46	2,61
	APP	553,20	14,32	527	581	2,47	0,02	2,46	2,49
150	AG	717,50	22,90	679	756	2,95	0,10	2,74	3,09
	JPSO	514,80	1,60	514	518	2,52	0,06	2,46	2,58
	APP	544,30	9,94	526	557	2,46	0,00	2,46	2,46
200	AG	643,60	35,73	576	694	2,75	0,15	2,56	3,04
	JPSO	514,80	1,60	514	518	2,52	0,06	2,46	2,58
	APP	538,20	9,20	524	557	2,46	0,00	2,46	2,46
250	AG	606,40	20,44	576	653	2,60	0,07	2,52	2,73
	JPSO	514,80	0,00	514	514	2,52	0,05	2,46	2,58
	APP	533,60	6,80	523	541	2,46	0,00	2,46	2,46
300	AG	585,60	15,34	562	607	2,56	0,09	2,46	2,73
	JPSO	514,80	0,00	514	514	2,51	0,05	2,46	2,58
	APP	531,10	6,51	523	541	2,46	0,00	2,46	2,46
350	AG	574,40	15,05	556	604	2,52	0,07	2,46	2,65
	JPSO	514,80	0,00	514	514	2,51	0,05	2,46	2,58
	APP	528,20	6,05	522	541	2,46	0,00	2,46	2,46
400	AG	571,80	16,55	554	604	2,51	0,07	2,46	2,65
	JPSO	514,80	0,00	514	514	2,50	0,04	2,46	2,58
	APP	527,20	6,29	519	539	2,46	0,00	2,46	2,46


Conforme observado na Tabela 10, a partir de 250 iterações, na instância grande, o JPSO já consegue chegar na solução ótima e zera o desvio padrão. Observando a tabela, em número de gerações, o AG não apresenta resultados satisfatórios. O que o torna viável é que, mesmo necessitando de mais gerações, ele possui um custo em tempo bem mais satisfatório que os demais algoritmos, além de testes com mais gerações conseguir fazer com que ele apresente a solução ótima para a base trabalhada, conforme já mencionado aqui e também apresentado por Belizário Júnior e Dorça (2018).

A segunda parte do experimento consistiu em levar em consideração todos com população inicial de tamanho 10. O gráfico da Figura 17 apresenta a comparação em relação ao tempo. Comparado com o gráfico 15, observa-se que agora o AG está com o comportamento mais próximo do APP que do JPSO. Mesmo assim, o AG ainda apresenta resultado

melhor que o APP. Com relação ao número de iterações, o AG continua necessitando de mais gerações para convergir.



(a) Comparativo de Tempo *vs* Fitness



(b) Comparativo de Gerações/Iterações *vs* Fitness

Figura 17 – Desempenho para a instância 200x1000 com população de tamanho 10.

Na instância de tamanho 10x200, comparando os algoritmos com mesmo tamanho de população inicial, o AG continuou apresentando o mesmo comportamento em relação aos demais, isto é, necessitando de mais gerações para convergir para a solução. O gráfico da Figura 18 mostra o resultado até a geração 300. Com relação ao tempo, observando

somente a etapa do algoritmo, o JPSO teve um gasto médio de 19,12 segundos para executar 300 iterações, enquanto que o APP teve um gasto médio de 3,22 segundos. O AG, com 300 gerações e população inicial de tamanho 10 teve uma média de 0,33 segundos.

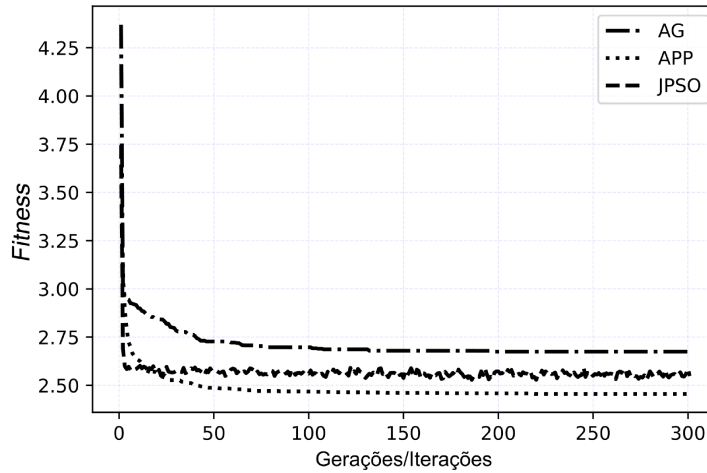


Figura 18 – Desempenho para a instância 10x200 com população de tamanho 10.

Uma vez que, com relação às bases trabalhadas, era conhecida a solução ótima e que, exceto o APP para a instância 200x1000, todos conseguiram em um determinado momento alcançar esta solução, ao analisar todas as situações, optou-se por utilizar o AG com população inicial de tamanho 100 para a abordagem. Vale salientar que esse tipo de experimento é válido em um ambiente educacional, pois o tempo de resposta e a solução aproximada encontrada podem interferir para diminuir a dispersão do estudante no decorrer da atividade.

No trabalho de Pereira Júnior et al. (2020) foi publicado parte dos resultados desenvolvidos neste experimento. No artigo há um foco para a instância 200x1000 e as 30 execuções. Além disso, o trabalho apresenta a visão geral da abordagem e um protótipo que está descrito no experimento a seguir.

5.2 Experimento 2: Avaliação da Abordagem

O SR desenvolvido nesta pesquisa utilizou a linguagem de programação Python para a implementação. Uma interface experimental foi criada, utilizando Angular.JS, a fim de fazer testes para verificar o funcionamento do ciclo desenhado na Figura 3. Com o auxílio do *framework* Django, foi possível conectar a interface experimental com a abordagem.

Dessa forma, utilizando alguns conceitos de reprodução celular, criados na Seção 5.1, foi possível verificar o funcionamento dos módulos da abordagem mesmo sem o uso de um AVA. Tal experimento também foi interessante para levantar quais dados mínimos são necessários para criar a *demanda do estudante* e o quanto a ferramenta proposta nesta pesquisa consegue ser independente do AVA a ser acoplada. Serviços *REST* com auxílio

do *framework* Django foram necessários para realizar chamadas na abordagem. A seguir, o método e os resultados obtidos.

5.2.1 Método

Este experimento foi construído para avaliar qualitativamente a abordagem, mesmo não estando conectada em um AVA. Desse modo, foram inseridos dados de estudantes, assim como conteúdos e conhecimentos a serem adquiridos. Todos os metadados foram armazenados na ontologia, juntamente com referências para alguns OA, podendo representar um repositório. Para o módulo de geração de OA a partir da Web, foram utilizados como experimentos tanto o Youtube quanto a Wikipedia. Além disso, para verificar a potencialidade de expansão da ferramenta, foram realizados testes para conexão com repositórios de OA. Nesse caso, o repositório escolhido foi o CX (ARAÚJO; DORÇA; CATTELAN, 2018).

No caso do Youtube, a busca consistiu em trabalhos que faziam parte da categoria de educação (sendo assim, já ocorre um filtro inicial de trabalhos irrelevantes) e a busca também consistiu na combinação da palavra-chave específica com o título do assunto, conforme Tabela 8, evitando que viessem trabalhos fora de contexto. Na Wikipedia foi utilizada a API da mesma para a busca de assuntos. A primeira etapa consistiu na busca de palavras-chave combinadas com o título, em seguida, a partir do resultado retornado, foram realizadas as buscas dos conteúdos das páginas.

A interface construída para este experimento permite selecionar o conteúdo que o estudante deve aprender (neste caso serve para alimentar o conhecimento que ele precisa adquirir), o estudante que receberá a recomendação personalizada e o tipo de recomendação, sendo este tipo:

- Busca em metadados armazenados na ontologia a partir dos EA do estudante;
- Busca em metadados armazenados na ontologia considerando somente o conhecimento a ser adquirido;
- Busca em metadados armazenados na ontologia e na Web, selecionando o(s) melhor(es) OA.

A subseção a seguir apresenta os resultados obtidos a partir dos testes realizados com a abordagem utilizando a interface experimental.

5.2.2 Resultados e análise

A Figura 19a representa uma situação de busca na ontologia a partir dos metadados previamente armazenados e recomendação personalizada. Nesta figura é possível ver quais OA foram recomendados a partir dos conceitos levantados, quais conceitos não foram

cobertos e OA que não apresentam os conceitos de interesse, mas são relacionados. Esse resultado encoraja no sentido de observar que mesmo que uma solução não consiga fazer buscas nos repositórios externos e/ou não consiga cobrir todos os conceitos, haverá um esforço em entregar o que foi possível encontrar.

Recomendação de conteúdo
Conteúdo a ser recomendado: Reprodução celular
Aluno: Estudante Exemplo 1
Buscar usando EA | Buscar sem EA | Busca Geral

Objetos de Aprendizagem

Título	Conceito	Acesso
Divisão Celular	mitose,prófase,meiose	Link 0002

Conceitos não cobertos

Conceito: divisão celular

Objetos de Aprendizagem Relacionados

Título	Conceito	Acesso
Mitose	metáfase,ciclo celular	Link 0003

Recomendação de conteúdo
Conteúdo a ser recomendado: Reprodução celular
Aluno: Estudante Exemplo 1
Buscar usando EA | Buscar sem EA | Busca Geral

Objetos de Aprendizagem

Título	Conceito	Acesso
Mitose vs. Meiose - Divisão Celular - Prof. Paulo Jubilut	mitose,meiose,divisão celular	https://youtube.com/watch?v=EkRs9kL5Kw4

Conceitos não cobertos

Conceito: Não há

Objetos de Aprendizagem Relacionados

Título	Conceito	Acesso
Não há		

(a) Recomendação com OA relacionados (b) Recomendação sem OA relacionados

Figura 19 – Recomendação utilizando o conhecimento a ser adquirido e os Estilos de Aprendizagem.

A Figura 19b apresenta uma busca que inclui a ontologia, o Youtube, a Wikipedia e o repositório CX. No cenário atual, foram selecionados no máximo 5 OA para cada conceito em cada base externa (podendo totalizar até 45 recursos digitais externos para o exemplo). Se, para um determinado conceito, algum recurso se repetia, este ficava cobrindo ambos os conceitos. Após a execução da inferência por parte da ontologia e da seleção através do AG, um vídeo do Youtube foi selecionado como o melhor OA para o exemplo. Observa-se que todos os conceitos foram cobertos somente com um OA.

A recomendação sem levar em consideração os EA também foi implementada, permitindo ser utilizada nos testes em um cenário real. Para os experimentos atuais não verificou a necessidade de visualização, pois não difere da figura 19a, uma vez que a base de testes é bem pequena.

Através da Figura 19 observou o potencial da ferramenta com recomendação tanto com os OA cujos metadados estão armazenados na ontologia, quanto com conteúdo da Web. Vale salientar que são extraídos metadados dos conteúdos da Web e metadados de OA são gerados e armazenados de forma automática para facilitar nas próximas recomendações. Também é importante destacar que a ferramenta em ambiente real conta com

um módulo colaborativo que visa diminuir a probabilidade de recomendação de materiais de baixa qualidade. A Seção 5.3 apresenta a ferramenta acoplada ao AVA e resultados de recomendação com dados de estudantes.

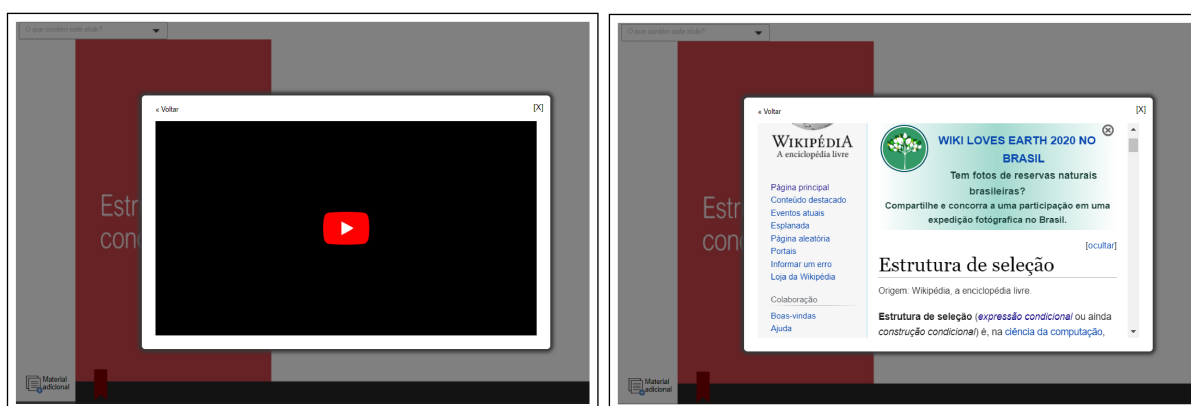
5.3 Experimento 3: Uso de AVA para recomendar materiais extras

A QP1 deste trabalho levanta a seguinte interrogação: *É possível recuperar e estruturar materiais da Web na forma de OA para recomendá-los como recursos educacionais extras em um AVA a partir de dados fornecidos por professores e estudantes?* A fim de responder esse questionamento, a abordagem foi acoplada no Moodle e no CX, conforme já mencionado no capítulo anterior. Para esta seção, o CX foi utilizado e foi realizado um experimento a partir de dados dos estudantes cadastrados na plataforma e que havia dados acerca dos EA. A seguir, o método adotado e os experimentos realizados.

5.3.1 Método

A primeira etapa do experimento consistiu em acoplar a funcionalidade de recomendação de OA no AVA CX. Para isso, foi criada uma classe Java na aplicação CX e utilizados comandos *REpresentational State Transfer (REST)*. Desta forma, não houve alteração nas funcionalidades já existentes no CX, somente o acréscimo de uma classe para conexão e realização de chamadas com a aplicação desenvolvida em Python.

Por se tratar de recomendação de materiais a partir de dados fornecidos pelo professor, o local escolhido para alocar a funcionalidade foi no último slide de uma aula. Sendo assim, uma vez implementada a funcionalidade, foi possível ver as possibilidades de renderização dos materiais adicionais. A Figura 20 apresenta dois exemplos de renderização com recursos educacionais distintos.



(a) Conteúdo complementar oriundo do Youtube. (b) Conteúdo complementar oriundo da Wikipedia.

Figura 20 – Exemplo de recomendação de materiais do Youtube e da Wikipedia.

A Figura 20a apresenta como ocorre a renderização de um vídeo para o estudante e a Figura 20b apresenta a renderização de uma página da Wikipedia. Além disso, como já mencionado, é possível que a recomendação traga OA do repositório do CX. É interessante que os SR consigam realizar uma diversificação nos resultados, tentando aproximar do interesse do usuário. Sendo assim, para responder de fato a QP, foram necessários mais alguns passos com relação ao método.

Uma vez que o SR foi inserido no AVA, o próximo passo consistiu em levantar temas de aulas e perfis de estudantes a fim de realizar o processo de recomendação para diferentes conceitos. Na intenção de delimitar os usuários cadastrados no CX, a Tabela 11 apresenta os critérios que foram utilizados de inclusão e exclusão de dados participantes neste experimento.

Tabela 11 – Critérios de inclusão e exclusão dos usuários.

Critério	Descrição
Inclusão	- Possuir perfil de estudante - Ter respondido totalmente ou parcialmente o questionário ILS - Não ser usuário de teste
Exclusão	- Apresentar os EA probabilísticos nos valores iniciais (0.5) - Ser duplicado - Não ter autorizado o uso dos dados

Ao aplicar os critérios de inclusão e exclusão apresentados na Tabela 11, foi possível obter o levantamento do perfil de 61 estudantes que possuíam classificação probabilística dos EA. A Figura 21 apresenta a distribuição dos estudantes (em porcentagem) de acordo com os EA. Na Subseção 5.3.2 há um maior detalhamento deste gráfico relacionando com os resultados obtidos neste experimento.

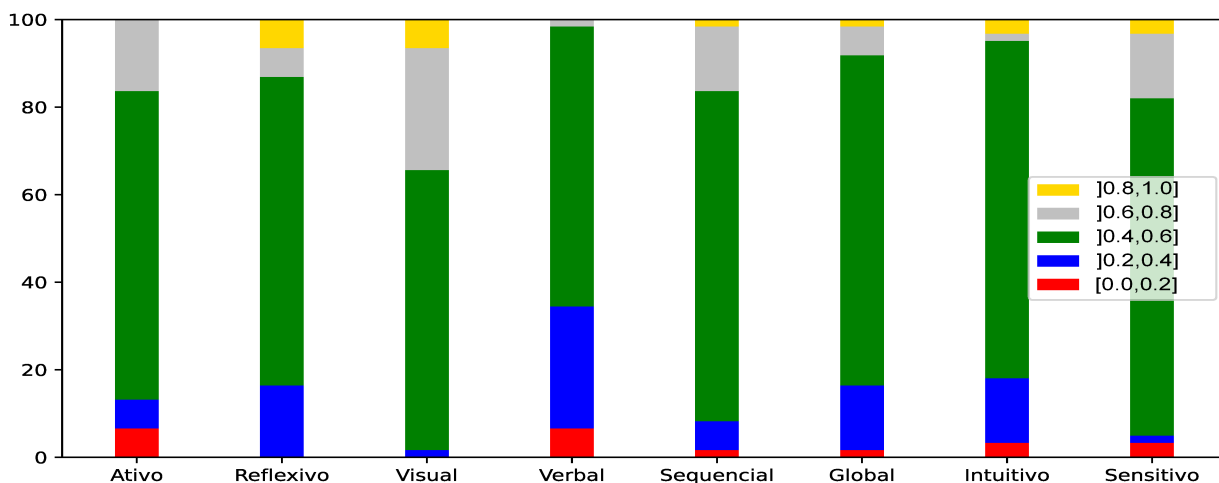


Figura 21 – Distribuição dos estudantes por EA na base analisada.

A partir da filtragem realizada de acordo com a Tabela 11 foi criada a base de dados de estudantes para a execução dos experimentos. A última etapa no desenvolvimento

deste método foi o levantamento de conteúdos utilizados como testes. Sendo assim, foram selecionadas cinco aulas com temáticas da área da computação. A Tabela 12 apresenta cinco temas de aulas e três palavras-chave para cada uma das aulas.

Tabela 12 – Conteúdo de aulas selecionados para o experimento.

	Título	Palavra-chave 1	Palavra-chave 2	Palavra-chave 3
Aula 1	Design de <i>Web-sites</i>	Web	Navegação	Arquitetura da Informação
Aula 2	Estrutura condicional em C	Simples	Composta	Encadeada
Aula 3	Vetores em linguagem C	Unidimensionais	Estático	Dinâmico
Aula 4	Estrutura de repetição em C	For	While	Teste no final
Aula 5	Modelo Entidade-Relacionamento	Diagramas	Cardinalidade	Atributos

A combinação do título da aula com as palavras-chave também serviram de entrada de dados para a recomendação de materiais extras sobre estes conteúdos. Observa-se na Tabela 12 que cada aula possui uma coluna que é designada ao título do conteúdo e três palavras-chave. A subseção a seguir apresenta detalhadamente os resultados obtidos a partir deste método.

5.3.2 Resultados e análise

A fim de verificar a capacidade da abordagem em recuperar materiais da Web, gerar automaticamente metadados de OA e fazer recomendação personalizada de recursos educacionais em um AVA a partir de dados fornecidos por professores e estudantes, os resultados a seguir trazem uma análise a partir do banco de dados com EA probabilísticos de estudantes coletados por meio da plataforma CX e conteúdos da área de computação.

Ao analisar a Figura 21, é possível verificar que a maioria dos estudantes estão classificados com valores entre 0.4 e 0.6 (perfis entre 40 e 60% para cada EA). Isso reforça a necessidade de uma recomendação utilizando classificação probabilística, onde a distância do OA com a demanda do estudante é calculada levando em consideração o valor probabilístico do EA do estudante, ao contrário de uma classificação binária/excludente, categórica e estática. Se o processo fosse realizado utilizando classificações binárias e estáticas para cada entrada, colocariam os EA dos estudantes em extremos e forçaria uma recomendação baseada nesses extremos. Por exemplo, um estudante com valor probabilístico de 50,01% para o estilo visual (dimensão Entrada) seria classificado exclusivamente como visual, ao passo que ele está mais centralizado e com preferências tão próximas do visual quanto do verbal.

Conforme apresentado na Seção 4.4 e reforçado na Subseção 5.3.1, além dos dados de estudantes, informações acerca do conteúdo a ser recomendado são necessárias. Nesse caso, foram selecionados cinco temas de aulas da área de computação para realização dos testes. Para cada conteúdo de aula, foram realizados testes com até três palavras-chave e, considerando como candidatos, os OA oriundos da Wikipedia, do Youtube e do repositório CX. A Figura 22 apresenta o número de recomendações distintas encontradas de acordo com a quantidade de palavras-chave informadas. OA oriundos do repositório CX apareceram como candidatos mas não foram selecionados por não apresentarem proximidade com a *demandado do estudante* (Marcador 5 da Figura 3).

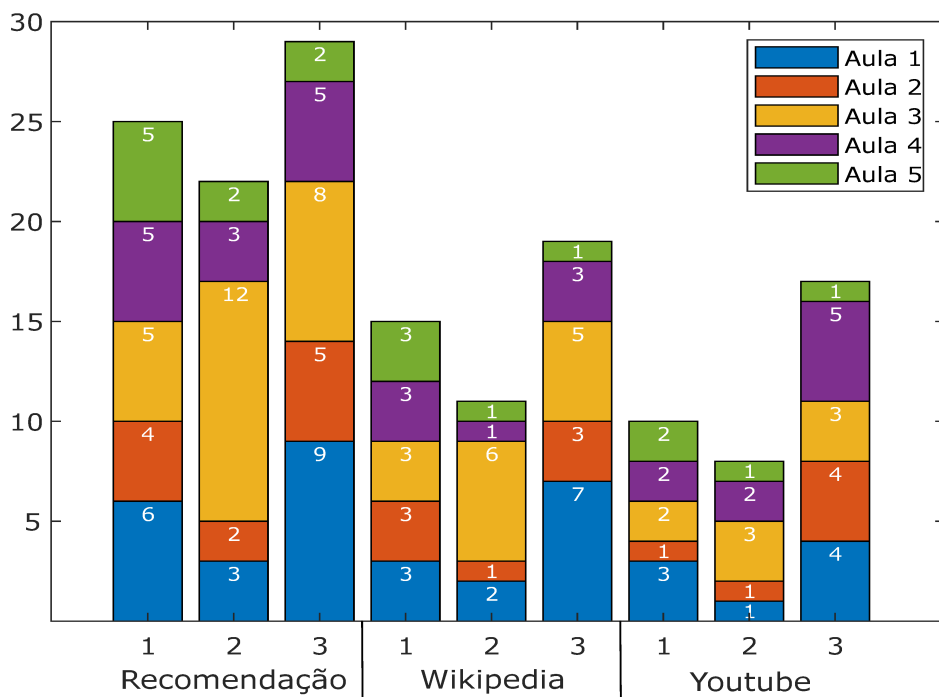


Figura 22 – Quantidade de recomendações distintas e OA, de acordo com o número de palavras-chave, por conteúdo de uma aula.

Para entender melhor o gráfico da Figura 22, será utilizado como exemplo a Aula 1 (cor azul). Na primeira parte do gráfico, a primeira barra informa que para a Aula 1 foram recomendados 6 OA distintos no total. Isto é, para os 61 perfis, cada perfil recebeu um OA como material extra, porém não foi o mesmo para os 61 pois se trata de uma recomendação personalizada e critérios individuais são levados em consideração. É importante enfatizar essa variação, pois, conforme levantado por Wan e Niu (2018) muitas vezes a recomendação baseada em FBC esquece de se preocupar com a diversidade de materiais.

Continuando uma análise dos resultados, a partir dos dados apresentados na Figura 22, nota-se que, para uma palavra-chave, em geral, a quantidade de recomendações distintas realizadas, levando em consideração os 61 perfis, foi maior que para duas. Isso ocorre, pois, quando se tem somente uma palavra-chave, um único OA consegue cobri-la

e vários OA candidatos possuem o mesmo custo. A partir de duas palavras-chave, a solução apresentada consegue realizar recomendações mais direcionadas para o conteúdo da aula. Com três palavras-chave, além de aumentar o número de recomendações distintas, observou-se que foi preciso no mínimo dois OA para cobri-las, em todas as cinco aulas.

Ainda observando o gráfico da Figura 22, nota-se que a Aula 2 apresenta um comportamento diferente, trazendo um número maior de recomendações com duas palavras-chave se comparada com uma única. Ao observar os OA retornados, foi possível verificar que a maioria eram da Wikipedia e que não estavam tão relacionados ao assunto, como é esperado pela abordagem. Apesar de, até esse momento, a busca da Wikipedia selecionar somente os três melhores resultados para cada palavra-chave, ainda foi considerado um número alto, correndo um risco de se recomendar algo que não fosse tão útil para acréscimo de conhecimento ao estudante. Notou-se que, para a Wikipedia, no momento de buscar OA candidatos pela API, o ideal é que fosse selecionado somente o melhor resultado por palavra-chave.

Esta etapa da pesquisa visou responder a QP1 através de testes com a recomendação personalizada utilizando FBC. Os resultados desta etapa do trabalho também podem ser encontrados em (PEREIRA JÚNIOR; ARAÚJO; DORÇA, 2020). De acordo com os critérios utilizados para a recomendação, resultados apontaram que os materiais da Wikipedia e do Youtube tiveram maior sucesso na recomendação e foi notado que, para este tipo de abordagem, é interessante que se tenha mais de uma palavra-chave relacionada ao conteúdo da aula. As seções a seguir apresentam experimentos e análises estatísticas com estudantes no intuito de se verificar o quanto esta abordagem contribui para melhorar a performance dos estudantes nos cursos.

5.4 Experimento 4: Análise da recomendação

A QP2 traz o seguinte questionamento: *A recomendação automática de materiais, a partir do nível de conhecimento do estudante e estilos de aprendizagem, pode trazer benefícios no processo de aprendizagem de acordo com a percepção de estudantes?* Visando responder este questionamento, o experimento a seguir conta com uma investigação, a partir de questionários (Apêndices C e D), da percepção de estudantes quanto à melhoria no processo de aprendizagem a partir da recomendação proposta nessa abordagem. A seguir os passos para execução dos experimentos, as limitações e os resultados obtidos.

5.4.1 Método

Caracterizada como uma pesquisa aplicada, esta etapa de validação do trabalho iniciou com a escolha do público-alvo. Aqui vale salientar que no dia 11 de março de 2020 a

Organização Mundial de Saúde declarou pandemia do novo Coronavírus². Diante da pandemia, as aulas no Brasil passaram da modalidade presencial para o ensino remoto emergencial. Nesse contexto, ocorreu uma alta evasão escolar por limitações ao uso da tecnologia, falta de recursos tecnológicos, dentre outros. Sendo assim, a turma escolhida para execução desta etapa foi uma turma de ensino médio técnico que tinha o maior número de matriculados no início do ano letivo, desconsiderando as evasões posteriores.

Uma vez definida a turma de aplicação, a etapa seguinte se deu no desenvolvimento de uma rede bayesiana que pudesse representar o conteúdo a ser ministrado na unidade curricular. A disciplina escolhida foi Lógica de Programação e nela são ensinados conceitos de programação procedural. A turma no ano de 2020 utilizou a linguagem de programação Python para aprender os comandos da programação procedural. A Figura 23 é uma representação da rede bayesiana utilizada para auxiliar na modelagem do desempenho de estudantes no decorrer da disciplina.

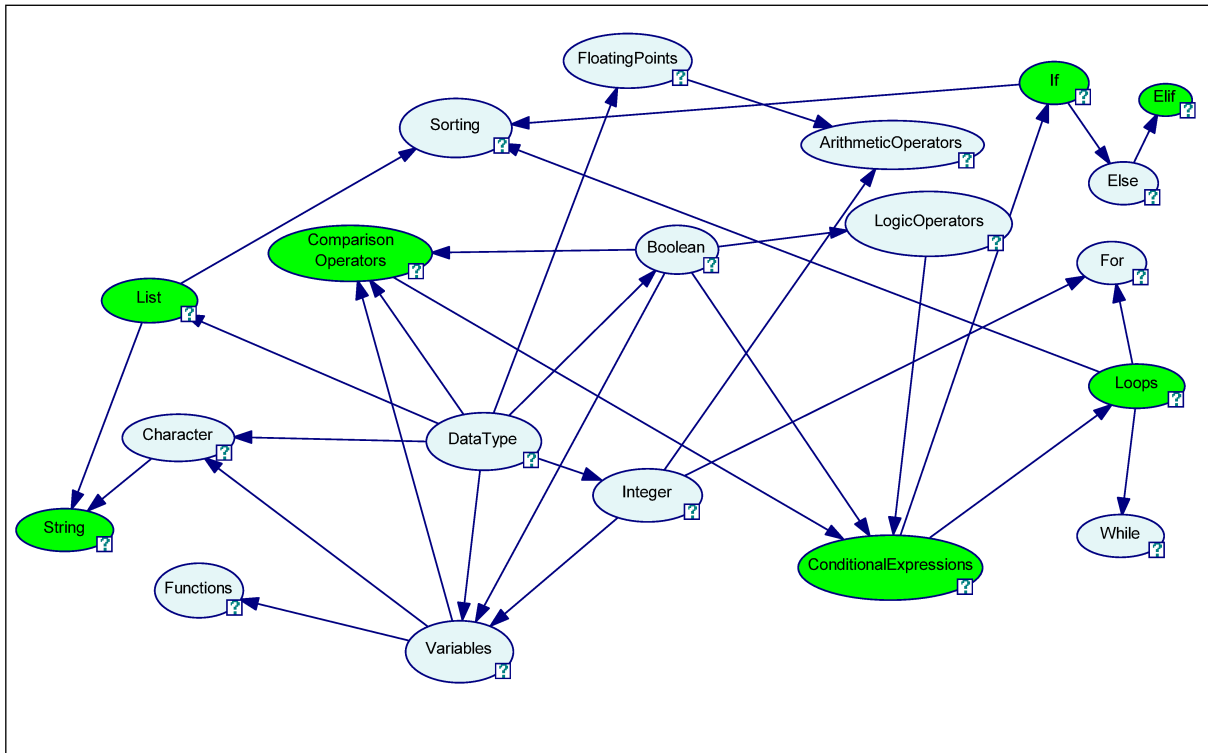


Figura 23 – Rede Bayesiana representando conceitos de programação procedural em Python.

Conforme mencionado no trabalho de Ferreira (2018), a rede bayesiana possui nós evidência e nós de saída. Os nós evidência, representado na Figura 23 pela cor verde, são utilizados para observar o desempenho do estudante em um determinado conceito. Para essa observação, podem ser utilizadas questões de múltipla escolha ou questões abertas. Neste experimento, estudantes foram submetidos a questões abertas que envolviam os conceitos em evidência. A Figura 24 apresenta as etapas de execução deste experimento.

² <https://www.unasus.gov.br/noticia/organizacao-mundial-de-saude-declara-pandemia-de-coronavirus>

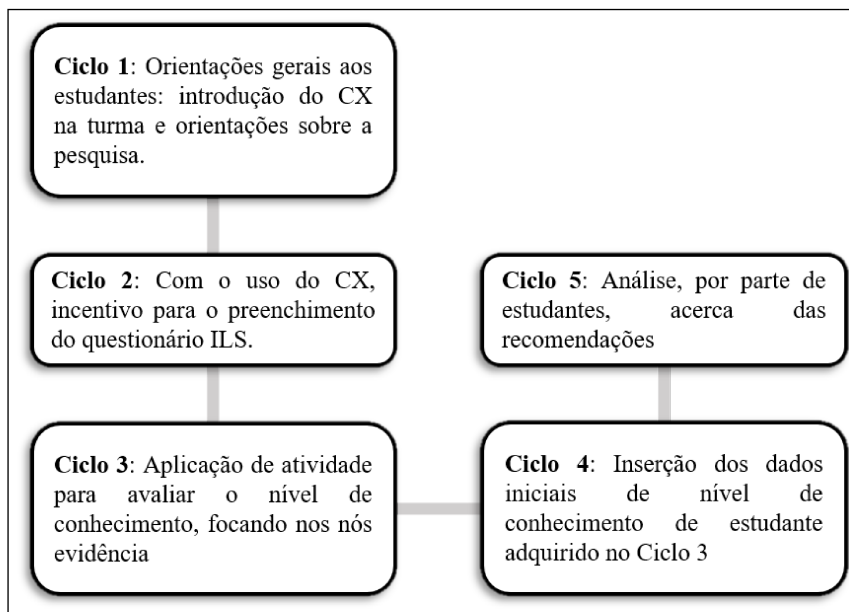


Figura 24 – Etapas de execução do experimento 4.

O AVA CX foi utilizado como estratégia pedagógica na disciplina de Lógica de Programação e estudantes, de forma voluntária, puderam responder o questionário ILS, interagir com a ferramenta e fornecer dados acerca dos EA e do nível de conhecimento. Cada ciclo apresentado na Figura 24 teve duração de 03 semanas e foi uma metodologia adotada pela instituição durante o ensino remoto emergencial no ano de 2020. Sendo assim, durante os últimos 04 meses do ano letivo os estudantes puderam utilizar o AVA para acessar materiais fornecidos pelo professor e pelo SR. A turma inicialmente contava com 40 estudantes matriculados, porém, devido a pandemia de COVID-19, teve uma alta desistência. Durante o Ciclo 1 do experimento tiveram 17 estudantes envolvidos. Ao final, 10 estudantes participaram até o Ciclo 5.

A partir dos resultados das questões que envolviam os conceitos dos nós evidência (Ciclo 3) e histórico dos estudantes na disciplina, o banco de dados da aplicação foi alimentado com a probabilidade inicial de conhecimento dos estudantes em conceitos dos nós evidência e a rede ficou responsável por fazer uma contínua atualização das probabilidades geral do nível de conhecimento desses estudantes a partir das informações dadas previamente pelo professor e das futuras informações fornecidas por estudantes.

Uma vez que os dados acerca dos EA foram preenchidos a partir de respostas ao questionário ILS e os dados acerca do nível de conhecimento foram inicialmente preenchidos a partir de respostas às atividades propostas pelo professor para este experimento e histórico já previamente adquirido através de outras atividades, o processo de recomendação personalizada já poderia acontecer conforme proposto nesta pesquisa. Vale salientar, que mesmo sem estes dados, para cada conteúdo no AVA CX já ocorria a recomendação de materiais, já que os EA, quando não possuem dados de estudantes, são repassados com valor 0.5, não interferindo no tipo de OA a ser retornado.

O questionário aplicado para medir a satisfação com o processo de recomendação (ciclo 5) foi dividido em duas partes. Na primeira parte (Apêndice C), o estudante deveria dizer o quanto concordava com o nível de conhecimento em cada tópico calculado pela rede. O estudante também deveria responder se concordava com a recomendação de conteúdo pendente. Conforme mostrado na Figura 9, a partir do nível de conhecimento do estudante, a abordagem apresenta uma lista de materiais fornecidos pelo professor acerca daquele conteúdo e dentro desses materiais o estudante também pode encontrar OA trazidos de repositórios. A Figura 9 aponta uma pendência de conteúdo de *lista dentro de lista em Python*. Por último, ainda no primeiro questionário, o estudante deveria responder se tinha a prática de buscar materiais extras a partir do conteúdo de uma aula. Esta última pergunta foi mais na intenção de conhecer o perfil dos voluntários da pesquisa. Todos os questionamentos seguiram a escala de Likert com cinco níveis.

A segunda parte (Apêndice D) trouxe perguntas direcionadas para a recomendação personalizada de OA a partir do material de uma aula. Esta etapa não limitou que o estudante respondesse somente uma vez. Caso quisesse, o estudante poderia abrir mais de um conteúdo e, para cada conteúdo, deveria responder o questionário. Para o experimento, foram criados dois tipos de recomendação: I - recomendação de no mínimo um OA de cada formato e sem levar em consideração os EA; II - recomendação de OA levando em consideração também os EA e trazendo um ou mais OA que cobrissem o conteúdo e que tivessem melhores ranqueados de acordo com o EA. Os dois botões apareciam no último slide de uma aula, conforme apresentado na Figura 25. Assim, foi coletado sobre qual recomendação o estudante teve preferência.

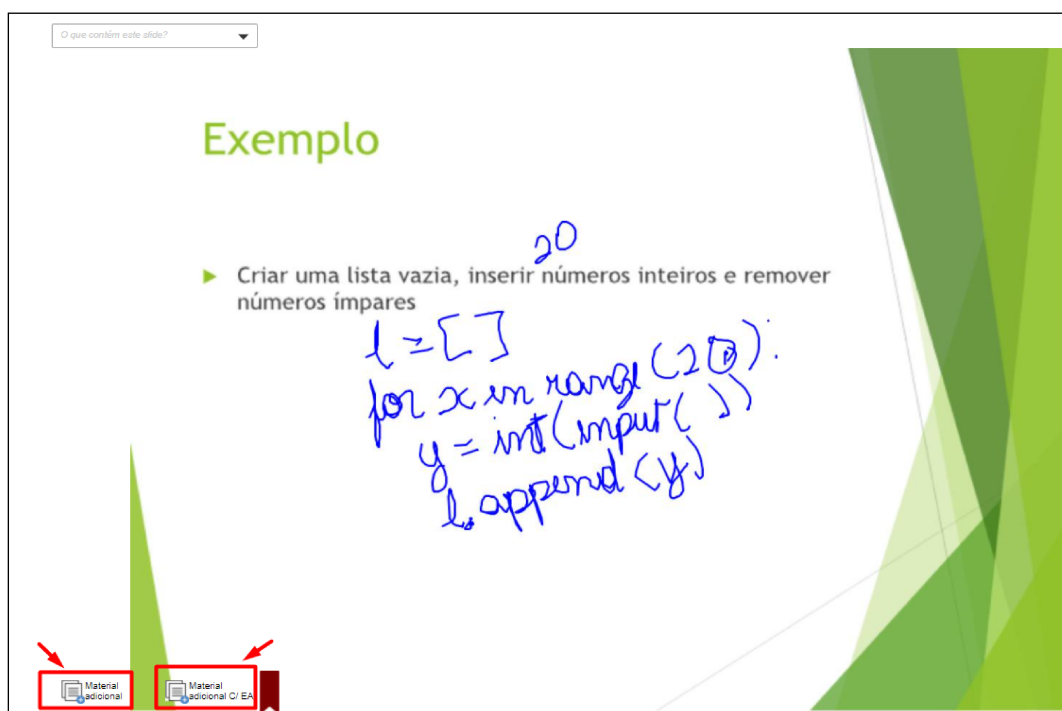


Figura 25 – Exemplo de um conteúdo com possibilidades distintas de recomendação.

Além de avaliar a preferência de recomendação, estudantes também foram convidados a responder acerca dos vídeos e textos recomendados. Tal razão para a avaliação é por serem materiais advindos de bases externas que não foram desenvolvidas necessariamente para a educação. Por fim, os estudantes poderiam responder sobre a quantidade de materiais recomendados, o tipo de material que teve maior preferência e o quanto estes estudantes acreditavam que aquele tipo de recomendação poderia colaborar para o aprendizado. Escala Likert e seleção sem escala foram utilizadas nesta etapa do experimento.

A aplicação do questionário ocorreu combinada com entrevistas. O professor da disciplina fez agendamentos de no máximo dois estudantes por vez e acordou um período de 90 minutos para a aplicação dos questionários e coleta de dados. com isso, além do resultado no questionário, foi possível coletar algumas impressões de estudantes no decorrer do experimento. A seguir, os resultados e análise desta parte do experimento.

5.4.2 Resultados e análise

Após passar pelos ciclos de 1 a 4 apresentados na Figura 24, a última etapa (Ciclo 5) corresponde a análise, por parte dos estudantes, das recomendações recebidas. O primeiro questionário aplicado possuía três afirmações para o estudante avaliar, sendo elas:

- ❑ Q. 1: O nível do meu conhecimento que o sistema está informando em cada um dos conceitos da disciplina está correto.
- ❑ Q. 2: Ao término de uma aula, eu costumo buscar materiais extras para aprofundar no conteúdo.
- ❑ Q. 3: As aulas que foram recomendadas para mim como reforço são aulas que possuem conteúdo que apresento dificuldades.




Figura 26 – Avaliação do estudante com relação ao nível de conhecimento.

As recomendações realizadas nesta etapa estão intimamente ligadas às respostas do Ciclo 3. O gráfico da Figura 26 traz o resultado desta primeira etapa. Com relação à *Q. 1*, nota-se que os estudantes, em sua maioria, concordam ou concordam totalmente com o nível do conhecimento que foi inferido pela rede. Também é importante observar que nenhum estudante avaliou negativamente esse ponto do questionário. Vale salientar que os estudantes tiveram acesso ao questionário no fim do ano, portanto eles já tinham uma visão geral do conteúdo e poderiam dizer com mais precisão sobre o nível de conhecimento. Somente um estudante que disse não concordar e nem discordar. Esse resultado foi bem motivador e trouxe mais confiança acerca dos pesos em cada nó da rede.

Com relação à *Q. 2*, nota-se que a base trabalhada está bem equilibrada com relação a estudantes que costumam buscar materiais extras para aprofundar e os que provavelmente não buscariam ou é algo indiferente no processo de aprendizagem. Tal resultado de certa forma é motivador para a pesquisa, pois estudantes que já não tinham costume de buscar materiais extras, podem agora tê-los através de um clique e isso pode ser um fator motivador para utilizá-lo no processo de aprendizagem. Já estudantes quem comumente buscam materiais extras, podem tê-los de forma personalizada e em um único local, diminuindo o espaço de busca e o tempo gasto para encontrar algo.

Com relação à *Q. 3*, a ferramenta foi configurada para recomendar conteúdo de tópicos que estudantes possuíam uma probabilidade de conhecimento menor que 60%. Portanto, somente 07 estudantes receberam a recomendação de conteúdo (aulas), dando uma diferença no tamanho da barra do gráfico. Dos estudantes que avaliaram, como também observado na *Q. 1*, nenhum discordou ou discordou totalmente da recomendação. Tal resultado já era esperado, uma vez que, em sua maioria, deram *feedback* positivo com relação ao nível de conhecimento inferido pela rede bayesiana. Tanto no início quanto no final, os estudantes foram informados que parte do processo para apresentação do nível de conhecimento foi feito de forma automática e que eles não deveriam se preocupar em discordar do resultado, pois isso não iria interferir na disciplina.

A segunda parte do questionário teve questões direcionadas ao conteúdo de uma aula e os materiais fornecidos, tanto o fornecido pelo professor, quanto os recomendados pelo SR. Conforme já explicado na seção anterior, cada estudante poderia selecionar um ou mais conteúdo para avaliar. A avaliação, porém, deveria ser feita por conteúdo. Isto é, o estudante deveria avaliar um conteúdo por vez e responder o questionário referente a este conteúdo e o material fornecido. Foram obtidos um total de 29 respostas, porém, ao analisar a base com as respostas, foram verificadas algumas duplicidades e descrições incorretas do conteúdo. Desta forma, restaram 23 respostas para analisar.

Visando avaliar as recomendações com EA (filtrando um ou mais materiais que cobrissem os tópicos do conteúdo) e sem EA (trazendo um ou mais materiais de cada formato disponível), foi solicitado ao estudante para responder qual foi a preferência dele. Após esse questionamento, foi perguntado se, dentre os materiais (slides daquela aula, vídeos

extras oriundos do Youtube e textos recuperados da Wikipedia), para aquele conteúdo, qual foi o preferido. As duas perguntas foram cruzadas e a Figura 27 traz um gráfico resultante das respostas coletadas. Nota-se que o material do tipo *Texto Wiki* aparece uma única vez e o estudante que marcou preferência pelo texto Wiki disse ser indiferente sobre os diferentes tipos de recomendação personalizada.

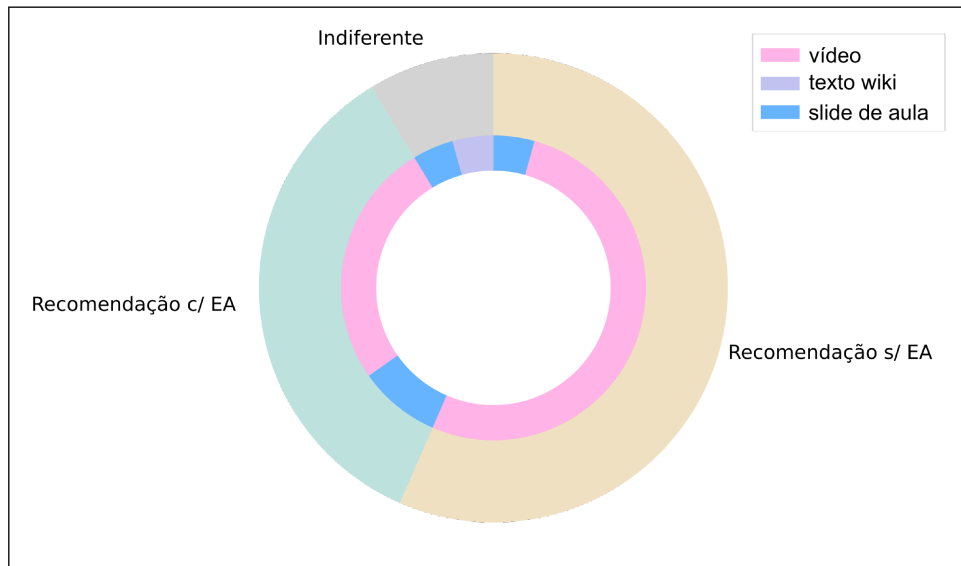


Figura 27 – Gráfico comparativo das preferências de recomendação e de materiais.

Ainda observando a Figura 27, há uma pequena diferença entre a recomendação utilizando também os EA e a recomendação sem utilizar os EA. Ao analisar, cruzando com o questionamento sobre a preferência de material, tende-se a concluir que neste experimento o uso dos EA não impactaram e sim o tipo de material. O que é notado que prevaleceu de fato foi a preferência por vídeos, indiferente do tipo de recomendação. O gráfico da Figura 28 ajuda a discutir essa questão do vídeo e do texto.




Figura 28 – Gráfico de avaliação geral sobre os materiais e o desempenho.

O gráfico da figura 28 traz a resposta de mais três levantamentos que visou classificar em escala Likert. Sendo eles:

- ❑ Vídeo: Em geral, os vídeos recomendados para esta aula estão relacionados com o conteúdo apresentado.
- ❑ Texto: Em geral, os textos recomendados para esta aula estão relacionados com o conteúdo apresentado.
- ❑ Desempenho: Se eu utilizar os materiais extras recomendados nesta aula como fonte complementar de estudos, acredito que vou ter melhor rendimento acerca do conteúdo.

Os vídeos tiveram quase 100% de avaliações positivas, tendo somente uma avaliação neutra. A avaliação com relação aos vídeos retornados é motivadora por saber que mesmo utilizando a máquina de busca do Youtube, a abordagem apresentada aqui traz alguns filtros extras, conforme apresentado no Capítulo 4, e ainda assim mantém uma relação com o conteúdo. Inclusive, é possível acreditar que a avaliação positiva com relação ao melhor rendimento utilizando materiais extras tem relação com a qualidade dos vídeos retornados.

Em relação aos textos, mesmo utilizando a máquina de busca fornecida pela Wikipedia para recuperar materiais da Wiki, os conteúdos retornados tiveram uma avaliação bem mais negativa que os vídeos no quesito do quanto relacionado os materiais se encontravam com os tópicos abordados naquele conteúdo. Em geral, os textos da Wikipedia possuem caráter de visão geral e definição acerca de um assunto e não explicação de um tópico específico. Por se tratar de introdução à programação utilizando Python, a maioria das vezes o retorno da Wikipedia era simplesmente uma página com a história da linguagem Python.

Os estudantes também foram questionados sobre a quantidade de materiais extras retornados em cada uma das recomendações e as respostas foram, em sua maioria, *quantidade boa* sobre a recomendação de material adicional sem EA e bem equilibrada entre *pouco*, *gostaria de mais* e *quantidade boa* em recomendação de material adicional com EA. Apesar de existir a opção de quantidade alta de materiais, nenhum estudante marcou esta opção.

Os resultados deste experimento motivou o uso de uma abordagem que leve o EA como um auxiliar para recomendação, conforme já vinha sendo feito, porém que o algoritmo de seleção seja utilizado para ranquear ao menos um material de cada formato, permitindo que as preferências do estudante sejam levadas em consideração mas que não corra o risco de eliminar algum formato de material no esforço de retornar o mínimo possível que cubra os tópicos de um conteúdo.

5.5 Experimento 5: Avaliação da recomendação

Já previamente discutida, a QP2 traz o seguinte questionamento: *A recomendação automática de materiais, a partir do nível de conhecimento do estudante e estilos de aprendizagem, pode trazer benefícios no processo de aprendizagem de acordo com a percepção de estudantes?*. Além disso, a QP3 traz um viés mais técnico quando levanta o seguinte questionamento: *É possível manter uma relevância na recomendação de OA quando estes são gerados a partir de conteúdo da Web?*. Os experimentos anteriores serviram para validar a ferramenta, verificar a capacidade de recomendação baseada no conhecimento do estudante e também baseada nos estilos de aprendizagem desse estudante. Visando complementar o experimento anterior e trazer uma contribuição para a QP3, esta última etapa ofertou três recomendações distintas para estudantes na intenção de verificar as preferências em um ambiente real.

5.5.1 Método

Ainda no contexto da pandemia da Covid-19, esta etapa da pesquisa foi desenhada para ser executada de forma remota. Caracterizada como pesquisa aplicada, a execução do experimento foi dividida em 04 partes. A primeira parte consistiu em criar turmas no ambiente CX e preparar o ambiente com aulas para que estudantes pudessem acessar e acompanhar os materiais fornecidos pelos professores. A segunda parte consistiu em incentivar estudantes a se cadastrarem no CX para ter acesso aos materiais. A terceira parte esteve relacionada a responder o questionário ILS. Por fim, os estudantes deveriam escolher um conteúdo (aula), analisar o material ofertado pelo professor, os materiais recomendados pelo SR e responder um último questionário.

Com relação à primeira e segunda parte, a Tabela 13 apresenta um resumo das características dos participantes. No total, foram selecionadas quatro turmas, sendo três de ensino superior e uma de ensino médio. Todas as disciplinas selecionadas foram disciplinas da área de computação. A escolha das turmas foi ocorrendo à medida que professores autorizavam o uso do material da disciplina para realizar a pesquisa.

Tabela 13 – Participantes da pesquisa por disciplina

Turma	Nível	Estudantes matriculados	Participantes da pesquisa
Turma A	Médio	26	9
Turma B	Superior	13	5
Turma C	Superior	24	5
Turma D	Superior	8	4

A Tabela 13 apresenta a relação de estudantes matriculados nas disciplinas e o número de participantes na pesquisa. Apesar de tentar motivar a participação de diversas maneiras, o número foi baixo. Fatores como o ensino remoto, distanciamento do pesquisador

com os envolvidos na pesquisa e o tempo elevado para execução do experimento podem ter contribuído para a baixa adesão na pesquisa. Todos os estudantes foram contatados por e-mail e WhatsApp acerca da pesquisa em andamento e da importância da participação.

Uma vez tendo voluntários para a pesquisa, a terceira parte deste experimento consistiu em solicitar que estudantes respondessem ao questionário ILS. Cada vez que o estudante acessava a plataforma CX, quatro novas questões do questionário aparecia para esse estudante e o processo era repetido até finalizar de responder todas as questões. Todos os estudantes que cadastraram na ferramenta CX e aceitaram o Termo de Consentimento Livre e Esclarecido (TCLE) responderam esta etapa da pesquisa.

The slide content includes:

- Logo of Instituto Federal de Goiás (Instituto Federal de Goiás - Campus Iporá).
- Title: **Filas Circulares**
- Section: **• Remoção:**
- Logic: **Se início == (tamanho - 1) início = -1; início = início + 1**
- Diagram 1: Circular queue with slots 0-9. 'inici' is at 7, 'fim' is at 4. Values in slots: 0:80, 1:0, 2:8, 3:5, 4:0, 5:20, 6:300, 7:0, 8:0, 9:8.
- Diagram 2: Circular queue after removal. 'inici' is at 0, 'fim' is at 4. Values in slots: 0:80, 1:0, 2:8, 3:5, 4:0, 5:20, 6:300, 7:0, 8:0, 9:8.
- Bottom navigation: Three recommendation cards for 'material 1', 'material 2', and 'material 3'. A star rating system with 5 stars and a score of 20.

Figura 29 – Exemplo de conteúdo com 03 recomendações distintas de materiais adicionais.

Na quarta etapa, os estudantes receberam três recomendações, cada uma com um conjunto de materiais para um determinado conteúdo. As recomendações foram: I - recomendação de materiais a partir de um conteúdo, sem levar em consideração EA, e trazendo no mínimo um material em formato vídeo e um material em formato texto; II - recomendação de materiais a partir de um conteúdo, levando em consideração EA e trazendo a menor quantidade de materiais para cobrir o conteúdo; e III - recomendação de materiais a partir de um conteúdo, levando em consideração EA, e garantindo o mínimo de um material em cada formato (mistura de ambas). A Figura 29, no canto inferior esquerdo, traz um exemplo de como foram colocadas as três recomendações.

Para cada OA trazido em forma de material adicional dentro de cada uma das recomendações, assim como no experimento anterior, o estudante deveria analisar, avaliar se

o conteúdo do material estava relacionado com o conteúdo estudado e se aquele material foi útil para a aprendizagem dele. A avaliação do item ajuda o recomendador a melhorar no retorno de materiais. A Figura 30 apresenta a tela de avaliação dos itens.

Com relação ao MATERIAL EXTRA que você acabou de acessar:
 1: discordo totalmente 2: discordo 3: não concordo e nem discordo 4: concordo 5: concordo totalmente

O material está relacionado ao conteúdo da aula
 1 2 3 4 5

Este material recomendado foi útil para o meu aprendizado
 1 2 3 4 5

Enviar

Figura 30 – Tela de avaliação dos itens.

Após analisar as três recomendações, estudantes foram convidados a responder um último questionário. Visando fazer um levantamento mais preciso do sistema de recomendação, os estudantes nesta etapa responderam o questionário ResQue. Esse questionário, proposto por Pu, Chen e Hu (2011), foi desenvolvido para avaliar sistemas de recomendação em fatores como qualidade dos itens recomendados, usabilidade do sistema, utilidade, qualidade da interação e interface, satisfação do usuário com o sistema, dentre outros, a partir da visão do usuário. O questionário completo tem 32 questões e o questionário reduzido possui 15 questões. Ambos foram validados e são equivalentes. Deste modo, optou-se pelo uso do questionário reduzido, eliminando a última questão que envolvia intenção de compra do produto, que não fazia sentido para o contexto deste trabalho. O Apêndice E traz o formato do questionário aplicado.

Antes de realizar a análise dos resultados, alguns critérios de exclusão foram estabelecidos para garantir a qualidade da pesquisa. Sendo assim, dos 23 voluntários para a pesquisa, somente os dados de 19 estudantes puderam ser utilizados. O motivo de eliminação principal foi o tempo utilizado para resposta do questionário ResQue (total de 03 eliminados). A Tabela 14 apresenta os critérios de inclusão e exclusão adotados.

Tabela 14 – Critérios de inclusão e exclusão dos usuários na pesquisa.

Critério	Descrição
Inclusão	- Possuir perfil de estudante - Ter respondido totalmente ou parcialmente o questionário ILS - Ter respondido totalmente o questionário ResQue
Exclusão	- Ter respondido o questionário ResQue em menos de cinco minutos - Ser duplicado - Não ter autorizado o uso dos dados

Com relação ao perfil do público participante, o gráfico da Figura 31 traz, em percentual, uma visão geral dos estudantes que participaram da pesquisa de acordo com os EA.

Nota-se que é um público misto e os extremos não são frequentes, enfatizando a importância de utilizar EA probabilísticos. Por exemplo, ao analisar o gráfico, observa-se que não há nenhum estudante que esteja classificado entre 80 e 100% em verbal e sequencial, mas não significa que esses estudantes não tenham esses EA.




Figura 31 – Perfil dos voluntários na pesquisa com relação aos EA

Tendo como objetivo verificar se havia alguma preferência de recomendação dentre as três sugeridas em uma aula específica, para cada item do questionário, o estudante deveria realizar a avaliação de cada uma das recomendações. Dessa forma, ao final, por se tratar de três amostras independentes, foi aplicado o teste de Kruskal-Wallis para avaliar estatisticamente o resultado. O Apêndice E apresenta a forma com que o questionário foi aplicado, de modo a facilitar ao estudante a comparação em cada um dos itens. Assim, o resultado obtido permitiu comparações e ajudou a responder a QP3. Com relação ao tempo gasto para responder o questionário ResQue, o valor mediano foi de 15 minutos e 18 segundos. A seguir, seguem os resultados deste experimento.

5.5.2 Resultados e análise

Visando analisar o impacto dos EA no processo de recomendação quando envolve a recuperação de materiais da Web e também a qualidade dessa recomendação, o questionário ResQue foi aplicado na última etapa desse experimento para sumarizar a experiência do usuário no processo de recomendação. A Tabela 15 apresenta o resultado da aplicação do questionário.

Tabela 15 – Resultado da aplicação do questionário ResQue

Análise	Recom. 1		Recom. 2		Recom. 3	
	Média	DP	Média	DP	Média	DP
1- Os materiais recomendados para mim corresponderam aos meus interesses.	4.26	0.87	4.05	0.91	4.26	0.73
2- O sistema de recomendação me ajudou a descobrir novos materiais.	4.00	1.33	3.26	1.37	3.58	1.17
3- Os materiais recomendados para mim foram diversificados.	4.16	1.07	3.26	1.41	3.53	1.26
4- O layout da interface do sistema de recomendação é atrativo.	4.05	1.13	3.95	1.13	3.84	1.17
5- O sistema de recomendação explica porque os materiais foram recomendados para mim.	2.63	1.38	2.68	1.45	2.63	1.38
6- As informações fornecidas para os materiais recomendados são suficientes para eu tomar uma decisão de abri-los.	3.58	1.17	3.47	1.31	3.58	1.26
7- Eu achei fácil informar ao sistema se eu não gosto/gosto do item recomendado.	4.74	0.56	4.63	0.76	4.74	0.56
8- Eu me tornei familiar com o sistema de recomendação muito facilmente.	4.42	0.51	4.47	0.51	4.47	0.51
9- Me sinto no controle para modificar minhas preferências.	3.42	0.90	3.47	0.96	3.53	1.02
10- Eu entendi porque estes conteúdos foram recomendados para mim.	4.11	1.05	3.95	1.31	4.00	1.00
11- O recomendador me deu boas sugestões.	4.16	0.69	3.79	1.08	3.84	0.96
12- Em geral, eu estou satisfeito com o sistema de recomendação.	4.32	0.89	3.84	1.12	3.89	1.10
13- O sistema de recomendação é confiável.	3.95	0.91	3.95	1.03	3.89	0.94
14- Eu usarei este recomendador outra vez.	4.32	0.95	3.95	1.08	4.00	1.12
Desempenho Geral	4.01		3.77		3.84	

Recom. 1 = Recomendação de materiais a partir de um conteúdo sem levar em consideração EA.

Recom. 2 = Recomendação de materiais a partir de um conteúdo levando em consideração EA.

Recom. 3 = Recomendação de materiais, levando em consideração EA, e trazendo no mínimo um material de cada formato.

No geral, observa-se que todas as recomendações tiveram desempenho final acima de 3.5, o que pode ser considerado um bom resultado. Para a recomendação 1, que aparentou ser relativamente melhor, o único critério de seleção era a cobertura de conteúdo levando em consideração a qualidade dos itens. Com relação à qualidade, além dos filtros já previamente realizados pelas máquinas de busca, as avaliações de estudantes para cada item também foi levado em consideração, procurando melhorar o recomendador em geral.

Além das perguntas padrões do ResQue, ao final também foi perguntado qual material teve maior predominância na recomendação de número 2. Observou-se que 12 dos 19 voluntários marcaram que o texto foi o mais predominante. Tal fator pode ter contribuído para o desempenho da recomendação 2 em relação às demais. Apesar da Wikipedia ser uma fonte de busca bastante utilizada na atualidade, nota-se que o conteúdo é geralmente para itens mais genéricos e, por vezes, o buscador traz bastante material fora de contexto. Ainda quando traz no contexto, são páginas mais informativas para quem está buscando uma leitura inicial acerca de um conteúdo.

A recomendação de número 3 visou trazer materiais levando em consideração os critérios das duas recomendações anteriores. Dessa forma, o resultado esperado seria um conjunto de itens selecionados considerando os EA e também o mínimo de um material de cada formato. Essa recomendação, em geral, também teve uma boa avaliação. Além do desempenho geral, é necessário analisar alguns pontos que foram mais críticos e tiveram notas baixas na avaliação. Assim, os gráficos das Figuras 32 e 33 ajudam a visualizar como foram as avaliações por item.

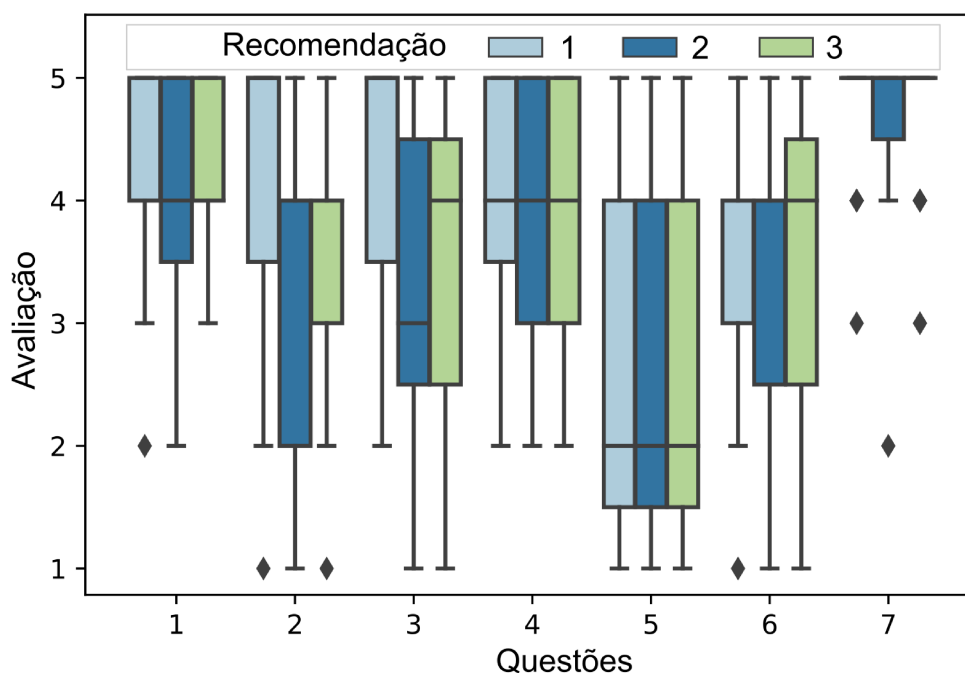


Figura 32 – Primeira parte de respostas ao questionário ResQue




Figura 33 – Segunda parte de respostas ao questionário ResQue

O item de número 4 do questionário foi o que teve pior avaliação. De fato, ao desenhar o experimento, optou-se por não explicitar quais fatores estavam sendo levados em consideração por cada um dos recomendadores para não ter nenhuma tendência na hora da avaliação. Dessa forma, esse item teve uma avaliação negativa. Assim como o item 9, uma vez que não se sabe quais critérios, além do conteúdo, que levaram aquela recomendação, esperava-se que o item tivesse uma avaliação mais negativa. O item 9 só não teve uma avaliação pior por um dos fatores ser o conteúdo e, para trocar os materiais, bastava navegar até outro conteúdo.

Os itens 1, 12 e 14 são fundamentais para responder a QP3. A partir do levantamento realizado e dos resultados obtidos, há um otimismo sobre o uso de materiais da Web e SR personalizada para suporte em ambientes educacionais a partir do conteúdo que está sendo ministrado. O CX trabalha na perspectiva de aulas e o recomendador inserido neste ambiente teve uma boa avaliação.

Na intenção de avaliar estatisticamente os dados que foram coletados, foi utilizado o teste de Kruskal-Wallis. Esse é um teste não paramétrico que serve para avaliar três ou mais grupos independentes e indicado para amostras menores que 30 (VARGHA; DELANEY, 1998). Para este caso, por se tratar de dados que foram coletados por meio de uma variável qualitativa ordinal, não há a necessidade de verificar a normalidade da distribuição dos dados.

Para cada item do questionário foi executado o teste de Kruskal-Wallis verificando se havia diferença estatisticamente significativa entre as recomendações. Conforme observado nos gráficos das Figuras 32 e 33, os elementos de um grupo ficaram visualmente

parecidos. Dessa forma, ao executar o teste de Kruskal-Wallis, foi constatado não existiu diferença estatisticamente significativa (isto é, todos obtiveram $p > 0.05$) entre os três tipos de recomendação entre as respostas de nenhuma das perguntas.

Ainda com relação à QP2, não é possível afirmar, neste caso, se a recomendação utilizando EA satisfazem os estudantes no cenário de recomendação de materiais da Web em forma de OA. É importante ressaltar que, mesmo não sendo possível identificar qual das três opções de recomendação foi a melhor, os resultados indicaram uma avaliação positiva das recomendações. Isso quer dizer que, no geral, a recomendação de materiais relacionados com o conteúdo estudado foi percebido como útil pelos estudantes.

Considerações Finais

Este trabalho apresentou uma abordagem modelada com base na teoria do PCC, e implementada utilizando-se meta-heurísticas de busca, mais especificamente algoritmos bioinspirados, em que diferentes algoritmos foram testados e tiveram seus desempenhos comparados. Ainda, técnicas de FBC apoiada por tecnologias da Web Semântica foram empregadas visando-se a recuperação, a partir da Web, e seleção eficiente de conteúdos educacionais de forma dinâmica.

Desta forma, a abordagem traz avanços ao estado da arte em diversos aspectos, se apresentando mais completa quando comparada a trabalhos correlatados em relação aos requisitos e funcionalidades presentes, conforme discutido no Capítulo 3, permitindo-se superar de forma bastante assertiva os desafios associados à recuperação e seleção de conteúdos mais significativos ao estudante.

Ainda, a abordagem proposta permitiu a realização de experimentos, inclusive com estudantes reais, que resultaram em análises que possibilitaram responder às perguntas de pesquisa inicialmente propostas, mostrando que a abordagem é promissora e supera os desafios inicialmente apontados.

6.1 Principais Contribuições

Conforme apresentado na Seção 1.1, este trabalho teve como base outras três pesquisas científicas que apresentaram avanços ao estado da arte. A pesquisa de Ferreira (2018) apresentou uma abordagem híbrida baseada em redes bayesianas e ontologias para modelagem do estudante. Já a pesquisa de Araújo (2017) trouxe uma arquitetura computacional capaz de estruturar OA, capturando metadados a partir de conteúdo de aulas e atividades colaborativas, e personalizar de acordo com os EA dos estudantes. Por último, a pesquisa de Belizário Júnior (2018) apresentou uma abordagem que combina algoritmo genético e tecnologias de Web Semântica para recomendação de OA a partir de páginas da Wikipedia.

Os três trabalhos supracitados foram pesquisas que ocorreram de forma independente. A partir dessas três pesquisas, este trabalho visou investigar a recomendação personalizada de materiais, levando em consideração um conteúdo específico. O modelo de estudante desenvolvido por Ferreira (2018) foi aplicado para recomendação personalizada com relação ao desempenho do estudante. Porém, por utilizar EA probabilístico e tecnologias de Web Semântica, esta pesquisa desenvolveu um método próprio para personalização relacionada aos EA.

Ainda no contexto de EA, a pesquisa de Araújo (2017) contribuiu ao trazer o mapeamento entre metadados de OA e EA. Sendo assim, para criar a *demand do estudante*, isto é, os dados de entrada para o processo de recomendação, tal mapeamento foi utilizado. Diferente da pesquisa de Araújo (2017), o conteúdo a ser estruturado e recomendado nesta pesquisa foi principalmente recuperado de repositórios da Web. Além disso, o processo de estruturação da *demand do estudante* contou com regras SWRL, sendo estas regras mais uma contribuição desta pesquisa.

Tecnologias de Web Semântica e algoritmo bioinspirado para recomendação de OA foram abordados no trabalho de Belizário Júnior (2018), além da formalização do PCC para recomendação de OA. Porém, avançando com relação ao trabalho de Belizário Júnior (2018), a pesquisa desenvolvida aqui inova ao apresentar: i) a formalização da recomendação com relação à FBC; ii) uma ampliação dos metadados anotados de forma automática para a criação da *demand do estudante*; iii) a possibilidade de recomendação levando em consideração também o desempenho do estudante; iv) a criação de uma abordagem independente que pode ser acoplada a diferentes AVA; v) recomendação de materiais de repositório de OA e da Web; vi) testes com estudantes reais para validação da abordagem desenvolvida.

Como contribuição técnica, o trabalho apresenta uma abordagem capaz de recomendar materiais da Web (Youtube e Wikipedia) e também de repositórios do AVA que está acoplada utilizando tecnologias de Web Semântica e algoritmo bioinspirado. Durante o desenvolvimento, houve um cuidado na criação de uma abordagem que fosse independente de ambiente virtual, sendo que a mesma pode ser facilmente inserida a qualquer AVA que dispõe de dados de estudantes e de conteúdo.

A abordagem desenvolvida foi implementada no ambiente virtual CX, no Moodle e também foi criada uma interface simples para realizar testes. Tais implementações demonstraram o quanto a abordagem é dinâmica com relação ao ambiente que será utilizada. O artefato é uma contribuição técnica da pesquisa e, por ter criado na intenção de ser fracamente acoplado, espera-se que continue sendo explorado em pesquisas futuras que envolvam recomendação de materiais, em forma de OA, a partir de um conteúdo e características individuais dos estudantes.

Com relação às contribuições científicas, esta pesquisa analisou diferentes algoritmos para observar qual tinha uma melhor conversão para uma solução aproximada. Foram

levados em consideração o tempo e quantidade de execuções. A partir desse resultado, outras pesquisas podem trabalhar já com esses dados quando se tratar de problema de recomendação de materiais considerando cobertura por conjuntos. Além disso, o trabalho motiva a aplicação do PCC para problemas de recomendação, uma vez que a literatura não apresenta muito o uso desta técnica.

Outra contribuição deste trabalho é com relação a parte de computação aplicada. A pesquisa desde seu princípio, teve como foco contribuir para a área de Informática na Educação. Visando colaborar com a área, o recomendador desenvolvido foi aplicado em algumas turmas de ensino médio e superior. As turmas foram observadas durante o 2º semestre de 2020 e 1º semestre de 2021. Questionários foram aplicados nestas turmas e permitiu concluir que a ferramenta satisfaz na recomendação levando em consideração o desempenho do estudante, o conteúdo a ser estudado e preferências (neste caso os EA). Desta forma, os resultados incentivam a explorar mais os materiais da Web como recurso adicional ao estudante no processo de preparação de materiais em ambientes virtuais.

6.2 Limitações e Trabalhos Futuros

A pesquisa apresenta algumas limitações que estão relacionadas ao processo de execução e também que foram enfrentadas durante os experimentos. Um problema ao utilizar materiais da Web e principalmente API para recuperar conteúdo de alguns repositórios, é que estas API costumam ter atualizações frequentes, fazendo com que a ferramenta se torne obsoleta ou que haja manutenção frequente. Além disso, o Youtube limita o número de buscas por dia através de API. Sendo assim, a adoção em grande escala exige a criação de um parâmetro para configurar diferentes chaves. Além disso, não foram realizados testes de escalabilidade para saber qual a capacidade da abordagem.

Outra limitação do trabalho diz respeito ao cadastro do conteúdo para que seja possível realizar o processo de recomendação. É importante que docentes que estejam interessados em utilizar a ferramenta, passe por um treinamento prévio para fazer o cadastro corretamente do conteúdo e palavras-chave. Os resultados desta pesquisa apresentaram números esperados de palavras-chave. Sendo assim, o número de palavras-chave e os termos utilizados se preenchidos de forma incorreta provavelmente recomendarão materiais que não estão sendo esperados pelo usuário.

Ainda no contexto de limitação, com relação à execução dos testes, todos tiveram que ocorrer de forma remota por conta do contexto da pandemia de Covid-19. Notou-se uma motivação baixa em utilizar a ferramenta. Vários fatores motivacionais foram utilizados, mesmo assim o número de participantes foi considerado baixo com relação ao esperado. Os resultados, diante do contexto explicitado, permite que sejam discutidos alguns trabalhos futuros.

Alguns trabalhos futuros podem ser desenvolvidos a partir desta pesquisa. Primei-

ramente, é interessante uma investigação com uma amostragem maior de estudantes, levando em consideração os diferentes níveis de formação, para comparar e verificar aspectos do processo de recomendação nos diferentes níveis de formação. Tais análises ajudarão a refinar os pontos que podem ser melhorados do SR. Outro trabalho que pode ser explorado ainda analisando aspectos da recomendação é o nível de satisfação com materiais no formato de texto advindos da Wikipedia e materiais no formato de vídeo advindos do Youtube.

Com relação ao teste que leva em consideração o AVA CX, é interessante apresentar os materiais recomendados pela abordagem em diferentes pontos dos slides de aula e realizar testes de verificação do comportamento de estudantes a partir do local de apresentação dos materiais recomendados. Assim, será possível concluir o melhor local para apresentar materiais adicionais daquele conteúdo.

Relacionado ao desempenho do estudante, como trabalhos futuros, devem ser desenvolvidos testes que possam verificar o uso e o não uso da ferramenta e buscar correlação com o desempenho do estudante em um determinado conteúdo. Uma vez que a abordagem está desenvolvida e descrita neste trabalho, trazer correlações com o desempenho abrem mais leques de investigação.

Também, ao término deste trabalho, notou-se a importância de desenvolver ferramentas que possam gerar mais *feedbacks* para docentes e tutores com relação ao comportamento de estudantes em AVA. Até então, essa abordagem teve foco total no estudante e não foi levado em consideração aspectos que possam colaborar com docentes, tais como, dados estatísticos do tempo gasto pelos estudantes dentro do AVA em um determinado conteúdo e outros.

6.3 Contribuições em Produção Bibliográfica

Este trabalho teve início em agosto de 2016, com definição do tema em janeiro de 2019. De agosto de 2016 até a data de defesa foram produzidos os seguintes trabalhos ligados ao tema:

- **PEREIRA JUNIOR, C. X.; DORÇA, F. A.; ARAUJO, R. D.** Towards an adaptive approach that combines semantic web technologies and metaheuristics to create and recommend learning objects. In: IEEE.2019 IEEE 19th International Conference on Advanced Learning Technologies (ICALT). 2019. v. 2161, p. 395–397. (PEREIRA JUNIOR; DORÇA; ARAUJO, 2019)
- **PEREIRA JÚNIOR, C. X.; BELIZÁRIO JÚNIOR, C. F.; ARAÚJO, R. D.; DORÇA, F. A.** Personalized recommendation of learning objects through bio-inspired algorithms and semantic web technologies: an experimental analysis. In: Anais do

XXXI Simpósio Brasileiro de Informática na Educação. Porto Alegre, RS, Brasil: SBC, 2020. p. 1333–1342. (PEREIRA JÚNIOR et al., 2020)

- **PEREIRA JÚNIOR, C. X.**; ARAÚJO, R. D.; DORÇA, F. A. Recomendação personalizada de conteúdo instrucional complementar usando repositório de objetos de aprendizagem e recursos da web. In: SBC. Anais do XXXI Simpósio Brasileiro de Informática na Educação. 2020. p. 1293–1302. (PEREIRA JÚNIOR; ARAÚJO; DORÇA, 2020)
- FERREIRA, J. P. B.; MASCHIO, P. T.; SANTANA, T. S.; COSTA, N. T.; **PEREIRA JÚNIOR, C. X.** Análise de vídeos como recurso educacional em plataforma não formal de aprendizagem. In: SBC. Anais do XXXI Simpósio Brasileiro de Informática na Educação. 2020. p. 1733–1742. (FERREIRA et al., 2020)

Além dos trabalhos supracitados, durante o doutorado outras produções científicas foram realizadas e que contribuíram indiretamente para a pesquisa:

- **PEREIRA JÚNIOR, C. X.**; FRANCISCO, R. E.; SILVA, L. F.; VEIGA, E. F.; FERNANDES, M. A.; DORÇA, F. A. Uso de ontologias para agentes conversacionais no contexto de ensino-aprendizagem: Uma revisão sistemática da literatura. In Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE) (Vol. 28, No. 1, p. 183). (PEREIRA JUNIOR et al., 2017)
- NOGUEIRA, S. P.; FRANCISCO, R. E.; SILVA, L. F.; FERNANDES, M. A.; **PEREIRA JÚNIOR, C. X.** Big data com learning analytics para apoiar o planejamento pedagógico acadêmico. In: Anais do VII Workshop de Desafios da Computação Aplicada à Educação. Porto Alegre, RS, Brasil: SBC, 2018. (NOGUEIRA et al., 2018)
- FRANCISCO, R. E.; AMBRÓSIO, A. P. L.; **PEREIRA JUNIOR, C. X.**; FERNANDES, M. A. Juiz Online no ensino de CS1 - lições aprendidas e proposta de uma ferramenta. REVISTA BRASILEIRA DE INFORMÁTICA NA EDUCAÇÃO, v. 26, p. 163, 2018. (FRANCISCO et al., 2018)
- **PEREIRA JÚNIOR, C. X.**; DANTAS, A. C. ; ABREU, A. S. L.; REIS, M.; MELO, S. L.; NASCIMENTO, M. Z.; DORÇA, F. A.; FERNANDES, M. A. Personalização das interações de um agente conversacional utilizando emoções e perfis de personalidade. In: XXX Simpósio Brasileiro de Informática na Educação (Brazilian Symposium on Computers in Education), 2019, Brasília. Anais do XXX Simpósio Brasileiro de Informática na Educação (SBIE 2019), 2019. p. 1092. (PEREIRA JÚNIOR et al., 2019)

- ❑ COSTA, N. T.; **PEREIRA JUNIOR, C. X.**, DIAS Araujo, R.; Fernandes, M. A. Application of AI planning in the context of e-learning. In: IEEE COMPUTER SOCIETY. 2019 IEEE 19th International Conference on Advanced Learning Technologies (ICALT). 2019. p. 57–59. (COSTA et al., 2019)
- ❑ COSTA, N., **PEREIRA JÚNIOR, C.**; Fernandes, M. Recomendação de ações pedagógicas utilizando planejamento automático e taxonomia digital de bloom. In: Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação - SBIE). 2019. v. 30, n. 1, p. 1531. (COSTA; JÚNIOR; FERNANDES, 2019)

Referências

- AISSAOUI, O. E.; OUGHDIR, L. A learning style-based ontology matching to enhance learning resources recommendation. In: **IEEE. 2020 1st International Conference on Innovative Research in Applied Science, Engineering and Technology (IRASET)**. [S.l.], 2020. p. 1–7. <<https://doi.org/10.1109/IRASET48871.2020.9092142>>.
- ALMAHAIRI, A. et al. Learning distributed representations from reviews for collaborative filtering. In: **Proceedings of the 9th ACM Conference on Recommender Systems**. [S.l.: s.n.], 2015. p. 147–154. <<https://doi.org/10.1145/2792838.2800192>>.
- ALMEIDA, C. d. M. e.; CARVALHO, N. A. d. Avaliação da duração das videoaulas na perspectiva dos alunos do consórcio cederj. In: **Anais do vigésimo quarto CIAED Congresso Internacional ABED de Educação a Distância**. [S.l.: s.n.], 2018.
- AN, D.; CARR, M. Learning styles theory fails to explain learning and achievement: Recommendations for alternative approaches. **Personality and Individual Differences**, Elsevier, v. 116, p. 410–416, 2017. <<https://doi.org/10.1016/j.paid.2017.04.050>>.
- ARAÚJO, R. D. **Uma Arquitetura Computacional para Autoria e Personalização de Objetos de Aprendizagem em Ambientes Educacionais Ubíquos**. Tese (Doutorado) — Universidade Federal de Uberlândia, 2017.
- ARAÚJO, R. D. et al. Using learning styles for creating and personalizing educational content in ubiquitous learning environments. **Revista Brasileira de Informática na Educação**, v. 28, p. 133, 2020. <<https://doi.org/10.5753/rbie.2020.28.0.133>>.
- ARAÚJO, R. D.; DORÇA, F.; CATTELAN, R. A computational architecture for learning objects authoring and personalization in ubiquitous learning environments. In: **Anais dos Workshops do Congresso Brasileiro de Informática na Educação**. [S.l.: s.n.], 2018. v. 7, p. 22. <<https://doi.org/10.5753/cbie.wcbie.2018.22>>.
- ARIYARATNE, M.; FERNANDO, T. A comparative study on nature inspired algorithms with firefly algorithm. **International Journal of Engineering and Technology**, Citeseer, v. 4, n. 10, p. 611–617, 2014.
- BALAJI, S.; REVATHI, N. A new approach for solving set covering problem using jumping particle swarm optimization method. **Natural Computing**, Springer, v. 15, n. 3, p. 503–517, 2016. <<https://doi.org/10.1007/s11047-015-9509-2>>.

BELDJOURI, S.; SERIDI, H.; KARABADJI, N. E. I. Recommendation in collaborative e-learning by using linked open data and ant colony optimization. In: SPRINGER. **International Conference on Intelligent Tutoring Systems**. [S.l.], 2018. p. 23–32. <https://doi.org/10.1007/978-3-319-91464-0_3>.

BELIZÁRIO JÚNIOR, C. **Reúso de conteúdo da Web na recomendação personalizada de objetos de aprendizagem: uma abordagem baseada em um algoritmo genético, tecnologias da Web Semântica e uma ontologia**. Dissertação (Mestrado) — Universidade Federal de Uberlândia, 2018. <<https://doi.org/10.5753/cbie.sbie.2018.1533>>.

BELIZÁRIO JÚNIOR, C.; DORÇA, F. Uma abordagem para a criação e recomendação de objetos de aprendizagem usando um algoritmo genético, tecnologias da web semântica e uma ontologia. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S.l.: s.n.], 2018. v. 29, p. 1533. <<https://doi.org/10.5753/cbie.sbie.2018.1533>>.

BERNARD, J. et al. Optimizing pattern weights with a genetic algorithm to improve automatic working memory capacity identification. In: SPRINGER. **International Conference on Intelligent Tutoring Systems**. [S.l.], 2016. p. 334–340. <https://doi.org/10.1007/978-3-319-39583-8_38>.

BERNERS-LEE, T. et al. A framework for web science. **Foundations and Trends® in Web Science**, Now Publishers, Inc., v. 1, n. 1, p. 1–130, 2006. <<https://doi.org/10.1561/1800000001>>.

BERNERS-LEE, T.; HENDLER, J.; LASSILA, O. The semantic web. **Scientific american**, JSTOR, v. 284, n. 5, p. 34–43, 2001. <<https://doi.org/10.1038/scientificamerican0501-34>>.

BERNHARD, K.; VYGEN, J. **Combinatorial optimization: Theory and algorithms**. Springer, **Third Edition, 2005.**, 2008.

BHASKARAN, S.; SANTHI, B. An efficient personalized trust based hybrid recommendation (tbhr) strategy for e-learning system in cloud computing. **Cluster Computing**, Springer, p. 1–13, 2017. <<https://doi.org/10.1007/s10586-017-1160-5>>.

BOCANEGRA, C. L. S. et al. Healthrecsys: A semantic content-based recommender system to complement health videos. **BMC medical informatics and decision making**, BioMed Central, v. 17, n. 1, p. 1–10, 2017. <<https://doi.org/10.1186/s12911-017-0431-7>>.

BODILY, R.; VERBERT, K. Review of research on student-facing learning analytics dashboards and educational recommender systems. **IEEE Transactions on Learning Technologies**, IEEE, v. 10, n. 4, p. 405–418, 2017. <<https://doi.org/10.1109/TLT.2017.2740172>>.

BORBA, E. J. de; GASPARINI, I.; LICHTNOW, D. The use of time dimension in recommender systems for learning. In: SCITEPRESS. **International Conference on Enterprise Information Systems**. [S.l.], 2017. v. 2, p. 600–609.

BROOKE, J. Sus: a “quick and dirty” usability. **Usability evaluation in industry**, v. 189, 1996.

BRUSILOVSKY, P.; PEYLO, C. Adaptive and intelligent web-based educational systems. **International Journal of Artificial Intelligence in Education (IJAIED)**, v. 13, p. 159–172, 2003.

COLCHESTER, K. et al. A survey of artificial intelligence techniques employed for adaptive educational systems within e-learning platforms. **Journal of Artificial Intelligence and Soft Computing Research**, De Gruyter Open, v. 7, n. 1, p. 47–64, 2017. <<https://doi.org/10.1515/jaiscr-2017-0004>>.

CORMEN, T. H. et al. **Introduction to algorithms**. [S.l.]: MIT press, 2009.

COSTA, N. et al. Application of ai planning in the context of e-learning. In: IEEE COMPUTER SOCIETY. **2019 IEEE 19th International Conference on Advanced Learning Technologies (ICALT)**. [S.l.], 2019. p. 57–59. <<https://doi.org/10.1109/ICALT.2019.00021>>.

COSTA, N.; JÚNIOR, C. P.; FERNANDES, M. Recomendação de ações pedagógicas utilizando planejamento automático e taxonomia digital de bloom. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S.l.: s.n.], 2019. v. 30, n. 1, p. 1531. <<https://doi.org/10.5753/cbie.sbie.2019.1531>>.

DEBORAH, L. J.; BASKARAN, R.; KANNAN, A. Learning styles assessment and theoretical origin in an e-learning scenario: a survey. **Artificial Intelligence Review**, Springer, v. 42, n. 4, p. 801–819, 2014. <<https://doi.org/10.1007/s10462-012-9344-0>>.

DECKER, S. et al. The semantic web: The roles of xml and rdf. **IEEE Internet computing**, IEEE, v. 4, n. 5, p. 63–73, 2000. <<https://doi.org/10.1109/4236.877487>>.

DIAS, L. L. et al. Uma abordagem para identificação de similaridade entre recursos educacionais utilizando bases de conhecimento externas. **Revista Brasileira de Informática na Educação**, v. 25, n. 02, p. 18, 2017. <<https://doi.org/10.5753/rbie.2017.25.02.18>>.

DOJA, M. et al. An improved recommender system for e-learning environments to enhance learning capabilities of learners. In: **Proceedings of ICETIT 2019**. [S.l.]: Springer, 2020. p. 604–612. <https://doi.org/10.1007/978-3-030-30577-2_53>.

DRACHSLER, H. et al. Panorama of recommender systems to support learning. In: _____. **Recommender Systems Handbook**. Boston, MA: Springer US, 2015. p. 421–451. ISBN 978-1-4899-7637-6. <https://doi.org/10.1007/978-1-4899-7637-6_12>.

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

EL-BISHOUTY, M. M. et al. Smart e-course recommender based on learning styles. **Journal of Computers in Education**, Springer, v. 1, n. 1, p. 99–111, 2014. <<https://doi.org/10.1007/s40692-014-0003-0>>.

- FABBRI, S. et al. Improvements in the start tool to better support the systematic review process. In: **Proceedings of the 20th international conference on evaluation and assessment in software engineering**. [S.l.: s.n.], 2016. p. 1–5. <<https://doi.org/10.1145/2915970.2916013>>.
- FELDER, R.; SOLOMAN, B. Index of learning styles questionnaire, north carolina state university,(2001). **Online at: <http://www2.ncsu.edu/unity/lockers/users/f/felder/public/ILSdir/ILS-a.htm>**, 2015.
- 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.
- FELDMAN, J.; MONTESERIN, A.; AMANDI, A. Automatic detection of learning styles: state of the art. **Artificial Intelligence Review**, Springer, v. 44, n. 2, p. 157–186, 2015. <<https://doi.org/10.1007/s10462-014-9422-6>>.
- FERRÉ, S. Sparklis: a sparql endpoint explorer for expressive question answering. In: . [S.l.: s.n.], 2014.
- FERREIRA, H. N. M. **Uma Abordagem Híbrida Baseada em Redes Bayesianas e Ontologias para Modelagem do Estudante em Sistemas Adaptativos e Inteligentes para Educação**. Tese (Doutorado) — Universidade Federal de Uberlândia, 2018. <<https://doi.org/10.5753/cbie.sbie.2017.1197>>.
- FERREIRA, J. P. B. et al. Análise de vídeos como recurso educacional em plataforma não formal de aprendizagem. In: SBC. **Anais do XXXI Simpósio Brasileiro de Informática na Educação**. [S.l.], 2020. p. 1733–1742. <<https://doi.org/10.5753/cbie.sbie.2020.1733>>.
- FRANCISCO, R. E. et al. Juiz online no ensino de cs1-lições aprendidas e proposta de uma ferramenta. **Revista Brasileira de Informática na Educação**, v. 26, n. 03, p. 163, 2018. <<https://doi.org/10.5753/rbie.2018.26.03.163>>.
- GARCÍA-FLORIANO, A. et al. Social web content enhancement in a distance learning environment: intelligent metadata generation for resources. **International Review of Research in Open and Distributed Learning**, Athabasca University Press (AU Press), v. 18, n. 1, p. 161–176, 2017. <<https://doi.org/10.19173/irrodl.v18i1.2646>>.
- GARDNER, H. **Frames of mind: The theory of multiple intelligences**. NY: **Basics**, 1983.
- GASPARETTI, F. et al. Prerequisites between learning objects: Automatic extraction based on a machine learning approach. **Telematics and Informatics**, Elsevier, v. 35, n. 3, p. 595–610, 2018. <<https://doi.org/10.1016/j.tele.2017.05.007>>.
- GILMAN, E. et al. Towards user support in ubiquitous learning systems. **IEEE Transactions on Learning Technologies**, IEEE, v. 8, n. 1, p. 55–68, 2014. <<https://doi.org/10.1109/TLT.2014.2381467>>.
- GIUSTOZZI, F. et al. Recommender system of educational resources: A critiquing-based proposal. In: IEEE. **2016 XI Latin American Conference on Learning Objects and Technology (LACLO)**. [S.l.], 2016. p. 1–8. <<https://doi.org/10.1109/LACLO.2016.7751779>>.

GORDILLO, A.; BARRA, E.; QUEMADA, J. A hybrid recommendation model for learning object repositories. **IEEE Latin America Transactions**, IEEE, v. 15, n. 3, p. 462–473, 2017. <<https://doi.org/10.1109/TLA.2017.7867596>>.

GORDILLO, A.; LÓPEZ-FERNÁNDEZ, D.; VERBERT, K. Examining the usefulness of quality scores for generating learning object recommendations in repositories of open educational resources. **Applied Sciences**, Multidisciplinary Digital Publishing Institute, v. 10, n. 13, p. 4638, 2020. <<https://doi.org/10.3390/app10134638>>.

GROUP, N. E. T. P. T. W. et al. **Transforming American education: Learning powered by technology**. [S.l.]: Washington, DC: Office of Educational Technology, US Department of Education. <http://tech.ed.gov/wp-content/uploads/2013/10/netp2010.pdf> (accessed april 4, 2016), 2010.

HAMEED, M. R.; EL-AMEER, A. S. Proposed recommender system for open educational resources for informatics institute for postgraduate studies. In: IEEE. **2019 International Engineering Conference (IEC)**. [S.l.], 2019. p. 126–130. <<https://doi.org/10.1109/IEC47844.2019.8950569>>.

HARMAN, K.; KOOHANG, A. **Learning objects: standards, metadata, repositories, and LCMS**. [S.l.]: Informing Science, 2007.

HASSAN, M.; HAMADA, M. Smart media-based context-aware recommender systems for learning: A conceptual framework. In: IEEE. **2017 16th International Conference on Information Technology Based Higher Education and Training (ITHET)**. [S.l.], 2017. p. 1–4. <<https://doi.org/10.1109/ITHET.2017.8067805>>.

HITZLER, P. et al. Owl 2 web ontology language primer. **W3C recommendation**, World Wide Web Consortium (W3C), v. 27, n. 1, p. 123, 2009.

HORROCKS, I. et al. Swrl: A semantic web rule language combining owl and ruleml. **W3C Member submission**, v. 21, n. 79, p. 1–31, 2004.

İNCE, M.; YIĞİT, T.; İŞİK, A. H. A hybrid ahp-ga method for metadata-based learning object evaluation. **Neural Computing and Applications**, Springer, p. 1–11, 2017. <<https://doi.org/10.1007/s00521-017-3023-7>>.

INITIATIVE, D. C. M. et al. Dublin core metadata element set, version 1.1. Dublin Core Metadata Initiative, 2012.

JORDÁN, J. et al. Recommending learning videos for moocs and flipped classrooms. In: SPRINGER. **International Conference on Practical Applications of Agents and Multi-Agent Systems**. [S.l.], 2020. p. 146–157. <https://doi.org/10.1007/978-3-030-49778-1_12>.

KALOGERAKI, E.-M. et al. Ontology-based model for learning object metadata. In: IEEE. **2016 7th International Conference on Information, Intelligence, Systems & Applications (IISA)**. [S.l.], 2016. p. 1–6. <<https://doi.org/10.1109/IISA.2016.7785383>>.

KARABOGA, D.; AKAY, B. A survey: algorithms simulating bee swarm intelligence. **Artificial intelligence review**, Springer, v. 31, n. 1-4, p. 61, 2009. <<https://doi.org/10.1007/s10462-009-9127-4>>.

KELLY, D.; TANGNEY, B. Adapting to intelligence profile in an adaptive educational system. **Interacting with Computers**, Elsevier, v. 18, n. 3, p. 385–409, 2006. <<https://doi.org/10.1016/j.intcom.2005.11.009>>.

KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: IEEE. **Proceedings of ICNN'95-International Conference on Neural Networks**. [S.l.], 1995. v. 4, p. 1942–1948.

KIRSCHNER, P. A. Stop propagating the learning styles myth. **Computers & Education**, Elsevier, v. 106, p. 166–171, 2017. <<https://doi.org/10.1016/j.compedu.2016.12.006>>.

KITCHENHAM, B. Procedures for performing systematic reviews. **Keele, UK, Keele University**, v. 33, n. 2004, p. 1–26, 2004.

KOLB, A. Y.; KOLB, D. A. Learning styles and learning spaces: Enhancing experiential learning in higher education. **Academy of management learning & education**, Academy of Management, v. 4, n. 2, p. 193–212, 2005. <<https://doi.org/10.1016/j.chb.2013.06.036>>.

KURILOVAS, E.; ZILINSKIENE, I.; DAGIENE, V. Recommending suitable learning scenarios according to learners' preferences: An improved swarm based approach. **Computers in Human Behavior**, Elsevier, v. 30, p. 550–557, 2014.

LOPS, P.; GEMMIS, M. D.; SEMERARO, G. Content-based recommender systems: State of the art and trends. In: **Recommender systems handbook**. [S.l.]: Springer, 2011. <https://doi.org/10.1007/978-0-387-85820-3_3>.

LTSC, I. **1484.12.1-2020 - IEEE Standard for Learning Object Metadata**. 2020. Learning Technology Standards Committee of the IEEE. Available on <https://standards.ieee.org/standard/1484_12_1-2020.html>.

MANOUSELIS, N. et al. Recommender systems in technology enhanced learning. In: **Recommender systems handbook**. [S.l.]: Springer, 2011. p. 387–415. <https://doi.org/10.1007/978-0-387-85820-3_12>.

MCCLELLAND, M. Metadata standards for educational resources. **Computer**, IEEE, v. 36, n. 11, p. 107–109, 2003. <<https://doi.org/10.1109/MC.2003.1244540>>.

MCGUINNESS, D. L.; HARMELEN, F. V. et al. Owl web ontology language overview. **W3C recommendation**, v. 10, n. 10, p. 2004, 2004.

MEDIO, C. D. et al. Retrieval of educational resources from the web: A comparison between google and online educational repositories. In: SPRINGER. **International Conference on Web-Based Learning**. [S.l.], 2019. p. 28–38. <https://doi.org/10.1007/978-3-030-35758-0_3>.

MING, D. Z. T. S. Z.; JIE, Y. D. C. Overview of ontology [j]. **Acta Scientiarum Naturalum Universitatis Pekinesis**, v. 5, p. 027, 2002.

MORILLO-PALACIOS, B.; GUTIÉRREZ-CÁRDENAS, J. Content-based learning object recommendation system using a user profile ontology for high school students. In: SPRINGER. **Proceedings of the Future Technologies Conference**. [S.l.], 2020. p. 838–858. <https://doi.org/10.1007/978-3-030-63128-4_63>.

- MOURÃO, A. B.; NETTO, J. F. M. Simroaa multi-agent recommendation system for recommending accessible learning objects. In: IEEE. **2019 IEEE Frontiers in Education Conference (FIE)**. [S.l.], 2019. p. 1–9. <<https://doi.org/10.1109/FIE43999.2019.9028504>>.
- NAFEA, S. M.; SIEWE, F.; HE, Y. On recommendation of learning objects using felder-silverman learning style model. **IEEE Access**, IEEE, v. 7, p. 163034–163048, 2019. <<https://doi.org/10.1109/ACCESS.2019.2935417>>.
- NEVEN, F.; DUVAL, E. Reusable learning objects: a survey of lom-based repositories. In: ACM. **Proceedings of the tenth ACM international conference on Multimedia**. [S.l.], 2002. p. 291–294. <<https://doi.org/10.1145/641007.641067>>.
- NOGUEIRA, S. P. et al. Big data com learning analytics para apoiar o planejamento pedagógico acadêmico. In: **Anais do VII Workshop de Desafios da Computação aplicada à Educação**. Porto Alegre, RS, Brasil: SBC, 2018. <<https://doi.org/10.5753/desafie.2018.3101>>.
- OBEID, C. et al. Ontology-based recommender system in higher education. In: **Companion Proceedings of the The Web Conference 2018**. [S.l.: s.n.], 2018. p. 1031–1034. <<https://doi.org/10.1145/3184558.3191533>>.
- PAL, S. et al. A semi-automatic metadata extraction model and method for video-based e-learning contents. **Education and Information Technologies**, Springer, v. 24, n. 6, p. 3243–3268, 2019. <<https://doi.org/10.1007/s10639-019-09926-y>>.
- PAPPAS, I. O. et al. The interplay of online shopping motivations and experiential factors on personalized e-commerce: A complexity theory approach. **Telematics and Informatics**, Elsevier, v. 34, n. 5, p. 730–742, 2017. <<https://doi.org/10.1016/j.tele.2016.08.021>>.
- PEREIRA JÚNIOR, C.; ARAÚJO, R. D.; DORÇA, F. A. Recomendação personalizada de conteúdo instrucional complementar usando repositório de objetos de aprendizagem e recursos da web. In: SBC. **Anais do XXXI Simpósio Brasileiro de Informática na Educação**. [S.l.], 2020. p. 1293–1302. <<https://doi.org/10.5753/cbie.sbie.2020.1293>>.
- PEREIRA JÚNIOR, C. et al. Personalização das interações de um agente conversacional utilizando emoções e perfis de personalidade. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S.l.: s.n.], 2019. v. 30, n. 1, p. 1092. <<https://doi.org/10.5753/cbie.sbie.2019.1092>>.
- PEREIRA JUNIOR, C. et al. Uso de ontologias para agentes conversacionais no contexto de ensino-aprendizagem: Uma revisão sistemática da literatura. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S.l.: s.n.], 2017. v. 28, p. 183. <<https://doi.org/10.5753/cbie.sbie.2017.183>>.
- PEREIRA JÚNIOR, C. et al. Personalized recommendation of learning objects through bio-inspired algorithms and semantic web technologies: an experimental analysis. In: **Anais do XXXI Simpósio Brasileiro de Informática na Educação**. Porto Alegre, RS, Brasil: SBC, 2020. p. 1333–1342. <<https://doi.org/10.5753/cbie.sbie.2020.1333>>.

- PEREIRA JUNIOR, C. X.; DORÇA, F. A.; ARAUJO, R. D. Towards an adaptive approach that combines semantic web technologies and metaheuristics to create and recommend learning objects. In: IEEE. **2019 IEEE 19th International Conference on Advanced Learning Technologies (ICALT)**. [S.l.], 2019. v. 2161, p. 395–397. <<https://doi.org/10.1109/ICALT.2019.00118>>.
- PONTES, W. L. et al. Filtragens de recomendação de objetos de aprendizagem: uma revisão sistemática do cbie. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S.l.: s.n.], 2014. v. 25, n. 1, p. 549. <<https://doi.org/10.5753/cbie.sbie.2014.549>>.
- PU, P.; CHEN, L.; HU, R. A user-centric evaluation framework for recommender systems. In: **Proceedings of the fifth ACM conference on Recommender systems**. [S.l.: s.n.], 2011. p. 157–164. <<https://doi.org/10.1145/2043932.2043962>>.
- RASTEGARMOGHADAM, M.; ZIARATI, K. Improved modeling of intelligent tutoring systems using ant colony optimization. **Education and Information Technologies**, Springer, v. 22, n. 3, p. 1067–1087, 2017. <<https://doi.org/10.1007/s10639-016-9472-2>>.
- RIVERO-ALBARRÁN, D. et al. Design of a recommender system for intelligent classrooms based on multiagent systems. In: SPRINGER. **International Conference on Information Technology & Systems**. [S.l.], 2018. p. 973–982. <https://doi.org/10.1007/978-3-319-73450-7_92>.
- RODRÍGUEZ, P. et al. An educational recommender system based on argumentation theory. **AI Communications**, IOS Press, v. 30, n. 1, p. 19–36, 2017. <<https://doi.org/10.3233/AIC-170724>>.
- ROY, D.; SARKAR, S.; GHOSE, S. Automatic extraction of pedagogic metadata from learning content. **Int. J. Artif. Intell. Ed.**, IOS Press, NLD, v. 18, n. 2, p. 97–118, abr. 2008. ISSN 1560-4292.
- SCHMIDT, M.; MEIER, M.; LAUSEN, G. Foundations of sparql query optimization. In: **Proceedings of the 13th International Conference on Database Theory**. [S.l.: s.n.], 2010. p. 4–33. <<https://doi.org/10.1145/1804669.1804675>>.
- SIMPERL, E. Reusing ontologies on the semantic web: A feasibility study. **Data & Knowledge Engineering**, Elsevier, v. 68, n. 10, p. 905–925, 2009. <<https://doi.org/10.1016/j.datak.2009.02.002>>.
- SLIMANI, H. et al. The hybrid recommendation of digital educational resources in a distance learning environment: the case of mooc. In: **Proceedings of the 13th International Conference on Intelligent Systems: Theories and Applications**. [S.l.: s.n.], 2020. p. 1–9. <<https://doi.org/10.1145/3419604.3419621>>.
- SONG, B.; ZHUO, Y.; LI, X. A personalized intelligent tutoring system of primary mathematics based on perl. In: SPRINGER. **International Conference on Swarm Intelligence**. [S.l.], 2016. p. 609–617. <https://doi.org/10.1007/978-3-319-41009-8_66>.
- TALIESIN, B. **CLEO Extensions to the IEEE Learning Object Metadata**. [S.l.]: Version, 2003.

- TAMBE, S. S.; KADAM, G. V. An efficient framework for e-learning recommendation system using fuzzy logic and ontology. **International Research Journal of Engineering and Technology (IRJET)**, v. 3, n. 6, p. 2062–2067, 2016.
- 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. <<https://doi.org/10.1142/S021962201450031X>>.
- VALASKI, J.; MALUCELLI, A.; REINEHR, S. Revisão dos modelos de estilos de aprendizagem aplicados à adaptação e personalização dos materiais de aprendizagem. In: **Anais do Simpósio Brasileiro de Informática na Educação**. [S.l.: s.n.], 2011. v. 1, n. 1.
- VARGHA, A.; DELANEY, H. D. The kruskal-wallis test and stochastic homogeneity. **Journal of Educational and behavioral Statistics**, Sage Publications Sage CA: Los Angeles, CA, v. 23, n. 2, p. 170–192, 1998. <<https://doi.org/10.3102/10769986023002170>>.
- VIEIRA, M. A. **Modelagem de Espaços Inteligentes Pessoais e Espaços Inteligentes Fixos no contexto de Cenários de Computação Ubíqua**. Dissertação (Mestrado) — Universidade Federal de Goiás, 2016.
- VIKHAR, P. A. Evolutionary algorithms: A critical review and its future prospects. In: IEEE. **2016 International conference on global trends in signal processing, information computing and communication (ICGTSPICC)**. [S.l.], 2016. p. 261–265. <<https://doi.org/10.1109/ICGTSPICC.2016.7955308>>.
- WAN, S.; NIU, Z. An e-learning recommendation approach based on the self-organization of learning resource. **Knowledge-Based Systems**, v. 160, p. 71 – 87, 2018. ISSN 0950-7051. <<https://doi.org/10.1016/j.knosys.2018.06.014>>.
- WHITLEY, D. A genetic algorithm tutorial. **Statistics and computing**, Springer, v. 4, n. 2, p. 65–85, 1994. <<https://doi.org/10.1007/BF00175354>>.
- YUE, L. et al. A fuzzy document clustering approach based on domain-specified ontology. **Data & Knowledge Engineering**, Elsevier, v. 100, p. 148–166, 2015. <<https://doi.org/10.1016/j.datak.2015.04.008>>.

Apêndices

Uso de Filtragem Baseada em Conteúdo para Recomendação de Materiais Educacionais: uma Revisão Sistemática da Literatura

A.1 Introdução

A linha de pesquisa de Sistemas de Recomendação (SR) abrange aplicações em diversas áreas. Em geral, os SR buscam, através de algumas métricas, recomendar itens para usuários (LOPS; GEMMIS; SEMERARO, 2011). Os SR utilizam estratégias distintas a depender da base que está trabalhando e a finalidade da recomendação. Por exemplo, em bases com um número grande de usuários e com constante alimentação de dados, comumente encontra-se técnicas de Filtragem Colaborativa (FC) ou Filtragem Híbrida (FH) (que é a combinação da FC com outra técnica). Outra estratégia utilizada em SR para prover recursos, e que demanda menos de um conjunto de usuários, é a Filtragem Baseada em Conteúdo (FBC). Quando aplicada à educação para, por exemplo, realizar a recomendação de Objetos de Aprendizagem (OA), a FBC objetiva encontrar os recursos que mais se aproximam do perfil do estudante.

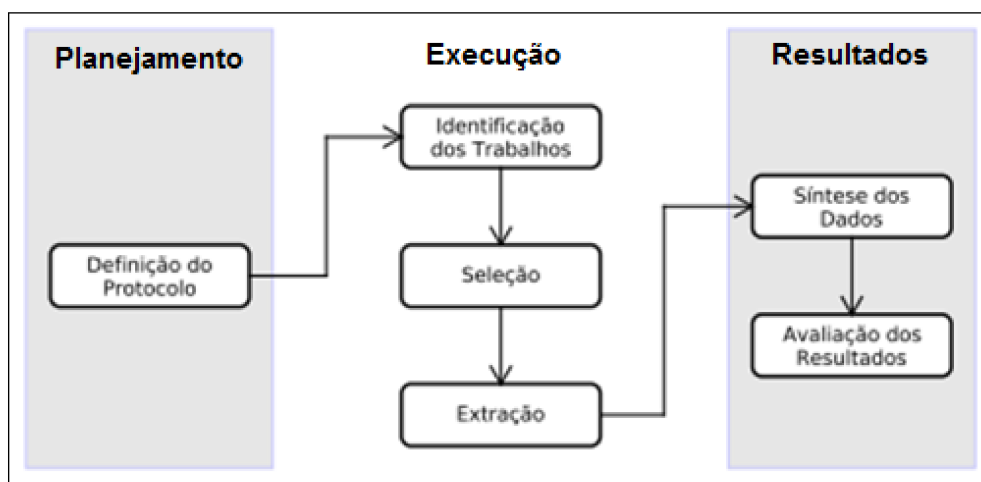
Diante da rápida expansão dos SR, principalmente no comércio eletrônico, conforme observado em Pappas et al. (2017), é interessante um esforço em entender como estão as pesquisas para a área de educação. Como observado por Wan e Niu (2018), quando direcionada à educação, FBC é comumente encontrado como técnica de filtragem no processo de recomendação. Isto se dá, principalmente, pela não dependência de um vasto número de usuário para realizar a entrega personalizada de algum conteúdo. Diante disso, este trabalho visa, através de uma Revisão Sistemática da Literatura (RSL), analisar o andamento dos trabalhos de FBC para recomendação de materiais educacionais. As seções

a seguir apresentam a metodologia adotada e os resultados obtidos.

A.2 Metodologia

Esta seção apresenta a metodologia aplicada na RSL sobre o uso de FBC para recomendação personalizada de materiais educacionais. Como procedimento para busca e seleção dos trabalhos, foram considerados os aspectos apresentados por Kitchenham (2004). Para auxiliar no gerenciamento do protocolo, a ferramenta STaRT foi utilizada (FABBRI et al., 2016). De acordo com Kitchenham (2004), há três etapas principais para a realização de uma RSL, sendo elas: planejamento, execução e resultados. A Figura 34 apresenta as fases da RSL.

Figura 34 – Fases da RSL. Adaptado de (VIEIRA, 2016)



A.2.1 Planejamento

Durante o planejamento de uma RSL é esperado que o protocolo seja definido. Para esta pesquisa, a seguinte questão principal foi levantada: *Como a filtragem baseada em conteúdo tem contribuído no processo de recomendação de materiais educacionais?* Para responder esta pergunta, é necessário que sejam criadas questões de pesquisa. A seguir, cada QP que foi criada para dar suporte à questão principal.

- QP1: Quais técnicas têm sido utilizadas para o processo de recomendação?
- QP2: Como os sistemas de recomendação de conteúdo têm sido avaliados?
- QP3: Quais dados têm sido utilizados para a FBC?

Assim, foram realizadas buscas por trabalhos completos, disponíveis em bases de artigos científicos. A busca se limitou aos trabalhos publicados a partir de 2016 (com última busca em 18 de janeiro de 2021). As bases utilizadas foram IEEE, Springer, Web of Science, Scopus, ACM e repositório da CEIE. Além disso, limitou-se a busca ao idioma inglês, porém aceitando também trabalhos retornados em português e espanhol. Para o repositório da CEIE a busca foi realizada em português. A *string* de busca a seguir foi projetada na intenção de retornar o máximo de trabalhos acerca do assunto. Para o repositório da CEIE foi adaptada a String para o idioma português e com critérios aceitáveis nas bases.

Tabela 16 – *String* de busca para a seleção de artigos

Idioma	String
Inglês	(“content-based” OR “content based”) AND (recommend*) AND (“learning object*” OR “educational resource*” OR “learning resource*” OR “personalized information”)

A Tabela 17 apresenta os critérios de inclusão e exclusão para esta pesquisa. Os critérios de inclusão contém limitação de idiomas, formato de publicação e assunto.

Tabela 17 – Critérios de exclusão e inclusão

Critério	Descrição
Exclusão	Artigo completo não disponível, capítulo de livro sem resumo ou artigo sem vínculo com periódico. Trabalhos duplicados e/ou com versão de publicação mais recente. Publicações fora do período de 2016 a 2021.
Inclusão	Íntegra do texto em Português ou Inglês. Aborda recomendação de materiais educacionais com FBC. Aborda avaliação de sistema de recomendação.

Os critérios de inclusão e exclusão fazem parte da etapa de planejamento da RSL. A busca foi realizada nas bases científicas que apresentam trabalhos relevantes na área de computação e possuem a função de busca avançada. A *string* de busca foi adaptada para atender os comandos de cada uma das bases. As buscas permitiram vislumbrar o andamento das pesquisas com relação ao processo de recomendação de conteúdo educacional usando FBC.

A.2.2 Execução

Uma vez finalizada a etapa de planejamento, o próximo passo é a etapa de execução. A etapa de execução, de acordo com os parâmetros de Kitchenham (2004), consiste em três partes: identificação, seleção e extração. Para a identificação dos trabalhos, as *strings* de busca foram executadas nas bases científicas selecionadas para a RSL. Nesta etapa,

um total de 92 trabalhos foram levantados. A busca se deu através dos títulos, resumos e palavras-chave.

Após a identificação dos trabalhos, foram realizadas leituras de títulos e resumos para a seleção de pesquisas relevantes para esta RSL. Nesta etapa, um total de 27 trabalhos foram selecionados por apresentarem indícios que poderiam contribuir para a presente investigação. Por fim, ao realizar a leitura na íntegra, 15 trabalhos foram incluídos, seguindo os critérios de inclusão e exclusão apresentados no protocolo. A Tabela 18 apresenta o número de trabalhos detalhado por base de busca.

Tabela 18 – Número de publicações por base nas etapas do processo de execução.

Base	Identificação	Seleção	Extração
ACM Digital Library	0	0	0
IEEE Xplore	10	3	2
Science Direct	2	1	1
Scopus	31	16	12
Springer Link	49	1	0
CEIE	0	0	0
Total	92	21	15

Vários trabalhos retornados pelas busca apresentaram não somente sistemas que utilizam FBC, mas uma combinação com outras técnicas de filtragem, sendo classificados como sistemas híbridos. Apesar desta busca ter focado em FBC, trabalhos retornados que combinam mais de uma técnica durante o processo de recomendação, mas que detalharam a etapa do uso da FBC se manteve na RSL.

A.3 Resultados da RSL

Esta RSL buscou explorar a recomendação de conteúdo educacional com apoio de FBC, pois, ao explorar o estado da arte, viu-se que este tipo de filtragem é mais frequentemente utilizada em ambientes educacionais por ser um cenário que não se tem tantos dados para utilizar facilmente outras técnicas de filtragem. Nesse sentido, a pesquisa buscou integrar o máximo de trabalhos possíveis para que seus resultados fossem mais sólidos. O artigo de Mourão e Netto (2019), apesar de não apresentar explicitamente o uso de FBC para um sistema de recomendação personalizada de OA acessíveis, utiliza de preferências do docente para a busca de OA. Após leitura no íntegra, observou que os pesquisadores não tinham intenção de associar a FBC nessa etapa do trabalho e que ficaria como trabalhos futuros. Desta forma, o trabalho acabou sendo rejeitado para este protocolo, mas traz uma visão interessante sobre recomendação com foco em acessibilidade.

Uma parcela considerável dos trabalhos aceitos foram somente propostas, não trazendo testes e validação dos resultados. Além disso, esses trabalhos não apresentaram detalhes se foram implementados. Desta forma, para estes trabalhos, ficou difícil apontar

as contribuições. Mesmo assim, houve um esforço em extrair quais dados pretendiam utilizar para a FBC. A seguir, as respostas, para as questões de pesquisa levantadas, de acordo com os resultados obtidos a partir do levantamento realizado nesta RSL. A Tabela 19 apresenta os trabalhos selecionados.

Tabela 19 – Trabalhos incluídos na RSL.

Título	Implementado?	Referência
A personalized intelligent tutoring system of primary mathematics based on perl	Não	Song, Zhuo e Li (2016)
A hybrid recommendation model for learning object repositories	Sim	Gordillo, Barra e Quemada (2017)
An educational recommender system based on argumentation theory	Sim	Rodríguez et al. (2017)
Smart media-based context-aware recommender systems for learning: A conceptual framework	Não	Hassan e Hamada (2017)
The use of time dimension in recommender systems for learning	Não	Borba, Gasparini e Lichtnow (2017)
An e-learning recommendation approach based on the self-organization of learning resource	Sim	Wan e Niu (2018)
Design of a Recommender System for Intelligent Classrooms Based on Multiagent Systems	Não	Rivero-Albarrán et al. (2018)
On Recommendation of Learning Objects Using Felder-Silverman Learning Style Model	Sim	Nafea, Siewe e He (2019)
Proposed Recommender System for Open Educational Resources for Informatics Institute for Postgraduate Studies	Sim	Hameed e El-Ameer (2019)
A learning style-based Ontology Matching to enhance learning resources recommendation	Não	AISSAOUI e OUGHDIR (2020)
An Improved Recommender System for E-Learning Environments to Enhance Learning Capabilities of Learners	Não	Doja et al. (2020)
Content-Based Learning Object Recommendation System Using a User Profile Ontology for High School Students	Sim	Morillo-Palacios e Gutiérrez-Cárdenas (2020)
Examining the Usefulness of Quality Scores for Generating Learning Object Recommendations in Repositories of Open Educational Resources	Sim	Gordillo, López-Fernández e Verbert (2020)
Recommending Learning Videos for MOOCs and Flipped Classrooms	Sim	Jordán et al. (2020)
The hybrid recommendation of digital educational resources in a distance learning environment: the case of MOOC	Não	Slimani et al. (2020)

A.3.0.1 QP1: Quais técnicas têm sido utilizadas para o processo de recomendação?

A primeira QP visou investigar quais técnicas computacionais são empregadas na recomendação de conteúdo educacional utilizando FBC. Por se tratar de uma filtragem, onde é recomendado um conteúdo semelhante ao perfil do usuário e/ou outro conteúdo, técnicas de similaridade foram as mais observadas no trabalho (GORDILLO; LÓPEZ-FERNÁNDEZ; VERBERT, 2020; GORDILLO; BARRA; QUEMADA, 2017; MORILLO-PALACIOS; GUTIÉRREZ-CÁRDENAS, 2020; JORDÁN et al., 2020; SLIMANI et al., 2020). As técnicas de similaridade nestas abordagem, em sua maioria, consistem em comparar metadados de OA em busca de encontrar o mais similar possível ao esperado pelo usuário.

Além da técnica de similaridade, já previamente esperada, foi possível encontrar aplicações com uso de Web Semântica (RODRÍGUEZ et al., 2017; MORILLO-PALACIOS; GUTIÉRREZ-CÁRDENAS, 2020; AISSAOUI; OUGHDIR, 2020). No caso do trabalho de Rodríguez et al. (2017) as regras de inferência OWL foram utilizadas para realização da filtragem. Já a pesquisa de Morillo-Palacios e Gutiérrez-Cárdenas (2020) explorou as consultas semânticas do tipo SPARQL em seu trabalho. Por fim, a pesquisa de AISSAOUI e OUGHDIR (2020) utilizou de ontologias para modelagem do domínio.

Outras técnicas de IA observadas nos trabalhos foram multiagentes e uso de aprendizado de máquina (RIVERO-ALBARRÁN et al., 2018; NAFFEA; SIEWE; HE, 2019; HAMEED; EL-AMEER, 2019). O trabalho de Hameed e El-Ameer (2019), por exemplo, utilizou de KNN e redes bayesianas para classificação dos conteúdos e posterior recomendação de forma mais personalizada. Apesar de menos frequente, foi possível observar que a área de aprendizado de máquina pode ser explorada nesse tipo de domínio.

A.3.0.2 QP2: Como os SR de conteúdo têm sido avaliados?

Um ponto importante nos SR é a forma de avaliação utilizada para validar se aquele sistema está sendo útil ou não. Em geral, os SR utilizam de *feedbacks* de usuários, independente se é resultado de pesquisa ou apenas uma ferramenta técnica desenvolvida. O *feedback* dado pelo usuário auxilia para melhoria no processo de recomendação. Para esta RSL o foco desta seção é levantar quais métodos foram utilizados para avaliar pesquisas que envolvem os SR de conteúdos educacionais.

Em se tratando de pesquisas com SR, nota-se duas principais preocupações com relação à avaliação: 1- comparativo de diferentes técnicas de recomendação; 2- análise da usabilidade e/ou satisfação do usuário. Com relação ao item 1, análises estatísticas são frequentemente utilizadas para concluir qual tipo de técnica realizou melhor recomendação (RODRÍGUEZ et al., 2017; GORDILLO; LÓPEZ-FERNÁNDEZ; VERBERT, 2020). Já o item 2 existem alguns questionários já validados para obter informações do usuário.

Com relação à avaliação de usabilidade dos SR, dois trabalhos tiveram essa preocupação com essa análise (MORILLO-PALACIOS; GUTIÉRREZ-CÁRDENAS, 2020; GORDILLO; BARRA; QUEMADA, 2017). Ambos os trabalhos que se preocuparam com análise da usabilidade do sistema, utilizaram a escala *System Usability Scale (SUS)* (BROOKE, 1996). A escala SUS possui a vantagem de apresentar um questionário já validado e é possível dos pesquisadores terem uma percepção da visão do usuário nesse quesito.

Em muitas pesquisas o uso de análise estatística, principalmente das métricas de *precision*, *recall* e *f1-score*. As medidas são utilizadas para verificar se as recomendações fornecidas foram positivas e também para comparar diferentes técnicas (RODRÍGUEZ et al., 2017; JORDÁN et al., 2020; HAMEED; EL-AMEER, 2019). O trabalho de Hassan e Hamada (2017) somente propõe o uso das medidas citadas anteriormente mas não usa de fato. Já o trabalho de Gordillo, López-Fernández e Verbert (2020) teste U de Mann-Whitney Para a análise da qualidade e relevância.

A pesquisa de Gordillo, Barra e Quemada (2017), além das análises anteriormente apontadas, também chamou atenção por aplicar um questionário desenvolvido e validado para análise de sistemas de recomendação. O questionário utilizado foi o ResQue (PU; CHEN; HU, 2011). Este questionário possui afirmações para os usuários responderem em uma escala *Likert* acerca da recomendação. As afirmações levam em consideração os interesses do usuário, usabilidade, a significância da recomendação, etc.

Alguns trabalhos desenvolveram questões próprias para análise (GORDILLO; LÓPEZ-FERNÁNDEZ; VERBERT, 2020; WAN; NIU, 2018). Para estes trabalhos, a escala *Likert* também foi priorizada. Quase metade dos trabalhos que foram incluídos nesta RSL não apresentaram nenhum tipo de coleta de resultados e avaliação. Também foram encontrados trabalhos que realizaram análise subjetiva de satisfação, relevância, relevância, efetividade e eficiência das recomendações (GORDILLO; LÓPEZ-FERNÁNDEZ; VERBERT, 2020; WAN; NIU, 2018).

A.3.0.3 QP3: Quais dados têm sido utilizados para a FBC?

A pesquisa de Wan e Niu (2018) traz uma visão importante do que é esperado de um SR que utiliza FBC para recomendação de conteúdos educacionais. Na arquitetura apresentada, o trabalho aponta a importância da modelagem do OA e também da modelagem do aprendiz. Isto é, espera-se os metadados dos OA e um modelo de aprendiz. A partir disso, é recomendado ao aprendiz os conteúdos que mais se assemelham com o modelo dele. A partir disso, esta RSL buscou investigar quais dados têm sido utilizados para a FBC.

Nota-se uma predominância dos EA tanto para traçar perfil de preferências de estudantes, quanto para modelar OA, isto é, indicar para qual perfil aquele OA deve ser recomendado. FLSM foi o mais predominante dentre os trabalhos que utilizaram EA (HASSAN; HAMADA, 2017; NAFEA; SIEWE; HE, 2019; JORDÁN et al., 2020; AISSA-

OUI; OUGHDIR, 2020). Alguns trabalhos utilizaram os EA do tipo VARK como um dos atributos para modelagem do aprendiz (RODRÍGUEZ et al., 2017; DOJA et al., 2020). O trabalho de Song, Zhuo e Li (2016) também propõe o uso de estilos de aprendizagem como dados a serem levantados do estudante, porém não especifica qual modelo.

Além dos EA, alguns trabalhos têm utilizado de experiências anteriores, com relação à interação com o material educacional, como dado relevante para a criação do modelo do estudante (GORDILLO; BARRA; QUEMADA, 2017; JORDÁN et al., 2020; BORBA; GASPARINI; LICHTNOW, 2017). O nível de conhecimento/formação, idioma de preferência e nível de dificuldade foram encontrados como dados relevantes do aprendiz para o processo de recomendação (GORDILLO; BARRA; QUEMADA, 2017; HAMEED; EL-AMEER, 2019; AISSAOUI; OUGHDIR, 2020).

Com relação aos OA, com exceção do trabalho de Nafea, Siewe e He (2019) que utilizou FSLSM, todos os outros trabalhos utilizaram metadados de OA. Título, palavras-chave e idioma são frequentemente citados nos trabalhos e aparentemente fundamentais para a modelagem de OA e posterior recomendação de um conteúdo educacional. Por exemplo, no trabalho de Rodríguez et al. (2017) foram utilizados o tipo de recurso educacional, o nível e tipo de interatividade, contexto, descrição, idioma e formato. Já no trabalho de Gordillo, López-Fernández e Verbert (2020) e Gordillo, Barra e Quemada (2017) utilizaram título, idioma e palavras-chave dos OA. Gordillo, Barra e Quemada (2017) também utilizou a descrição.

A.3.0.4 QP: Como a FBC tem contribuído no processo de recomendação de materiais educacionais?

No trabalho de Rodríguez et al. (2017) a FBC foi combinada com outras técnicas para criação de uma abordagem capaz de recomendar e gerar argumentos para justificar a recomendação. A pesquisa de Gordillo, López-Fernández e Verbert (2020) parte do pressuposto da importância da FBC, como já confirmada em outras pesquisas, e apresenta a contribuição do uso de avaliações pedagógicas para somar durante o processo de recomendação. Os autores apontam que o acréscimo do uso de avaliações pedagógicas para cada REA torna a abordagem híbrida.

Nos trabalhos de Gordillo, Barra e Quemada (2017) e Hassan e Hamada (2017), a FBC contribui para a recomendação de OA semelhantes com as preferências dos usuários. Além disso, na proposta apresentada por Hassan e Hamada (2017), a partir da FBC, dados acerca do contexto do usuário devem ser aplicados para melhor filtragem dos OA. Em Gordillo, Barra e Quemada (2017), a FBC é feita a partir de dados como idioma, áreas de interesse e OA previamente classificados como interessantes no passado.

No trabalho de Nafea, Siewe e He (2019) a FBC, a partir de um conjunto de OA avaliados pelo estudante, o algoritmo de recomendação, a partir de técnicas de clusterização, recomenda os OA mais relacionados. Caso o estudante não tenha um conjunto de OA

avaliados, a recomendação é feita a partir dos seus EA. Nesta pesquisa, a técnica de FBC foi combinada com a FC.

A.4 Considerações Finais

Esta RSL apresentou resultados de como tem sido o uso da FBC em SR para entrega de materiais educacionais. Observou que os EA tem sido comumente utilizados como critério para personalização durante o processo de recomendação e que algumas vezes são combinados com nível de conhecimento e outros dados que auxiliam a traçar o modelo de estudante. Em geral os trabalhos têm limitado a recomendação de materiais educacionais a partir de repositórios acoplados à aplicação ou outros repositórios de OA. Nenhum trabalho visou explorar conteúdos da Web. Os metadados do IEEE-LOM também são encontrados, neste caso para filtragem de OA. Com relação às técnicas utilizadas para validar as abordagens, *recall*, *f1-score* e *precision*, vistas inicialmente em sistemas de recuperação da informação, foram adaptas para SR e são frequentemente adotadas. Também observou o alto uso da satisfação do usuário com o conteúdo recebido através do uso de escala likert. Por último, observou também a existência de alguns questionários validados para avaliar SR.

Nota-se o uso de FBC para recomendação de materiais educacionais em formatos distintos e um esforço em combinar com outras filtragens para melhorar o processo de recomendação. A RSL, por outro lado, observou o quão ainda as abordagens são presas em analisar somente repositórios desenvolvidos e estruturados para OA. Além disso, foi notado o alto número de trabalhos que apresentam propostas de SR porém não traz implementação e/ou resultado.

Regras de Inferência SWRL

As regras a seguir foram desenvolvidas com o auxílio da ferramenta protégé e são utilizadas para realizar inferências durante a execução da abordagem. As regras de 1 a 6 inferem a lista de tipos de recursos de aprendizagem ideais de acordo com os EAs do aprendiz. As regras 7 e 9 inferem o tipo de interatividade esperado pelo OA de acordo com o perfil do estudante. Por último, as regras 8 e 10 inferem o nível de interatividade esperado para o estudante que está sendo recomendado o conteúdo.

1. $\text{Student}(?student) \wedge \text{IdealLOs}(?idealLO) \wedge \text{hasState}(?idealLO, \text{activeIdealLO}) \wedge \text{isRecommendedFor}(?idealLO, ?student) \wedge \text{Profile}(?profile) \wedge \text{hasProfile}(?student, ?profile) \wedge \text{hasProcessing}(?profile, \text{activeProcessing}) \rightarrow \text{ListResourcesIdealLO}(\text{exercise}) \wedge \text{ListResourcesIdealLO}(\text{simulation}) \wedge \text{ListResourcesIdealLO}(\text{questionnaire}) \wedge \text{ListResourcesIdealLO}(\text{exam}) \wedge \text{ListResourcesIdealLO}(\text{experiment}) \wedge \text{ListResourcesIdealLO}(\text{problemStatement}) \wedge \text{ListResourcesIdealLO}(\text{selfAssessment}) \wedge \text{ListResourcesIdealLO}(\text{assessment}) \wedge \text{ListResourcesIdealLO}(\text{assessmentItem}) \wedge \text{ListResourcesIdealLO}(\text{community}) \wedge \text{ListResourcesIdealLO}(\text{practice})$
2. $\text{Student}(?student) \wedge \text{IdealLOs}(?idealLO) \wedge \text{hasState}(?idealLO, \text{activeIdealLO}) \wedge \text{isRecommendedFor}(?idealLO, ?student) \wedge \text{Profile}(?profile) \wedge \text{hasProfile}(?student, ?profile) \wedge \text{hasProcessing}(?profile, \text{reflective}) \rightarrow \text{ListResourcesIdealLO}(\text{diagram}) \wedge \text{ListResourcesIdealLO}(\text{figure}) \wedge \text{ListResourcesIdealLO}(\text{summary}) \wedge \text{ListResourcesIdealLO}(\text{graph}) \wedge \text{ListResourcesIdealLO}(\text{index}) \wedge \text{ListResourcesIdealLO}(\text{slide}) \wedge \text{ListResourcesIdealLO}(\text{table}) \wedge \text{ListResourcesIdealLO}(\text{narrativeText}) \wedge \text{ListResourcesIdealLO}(\text{lecture}) \wedge \text{ListResourcesIdealLO}(\text{analogy}) \wedge \text{ListResourcesIdealLO}(\text{definition}) \wedge \text{ListResourcesIdealLO}(\text{demonstration}) \wedge \text{ListResourcesIdealLO}(\text{example}) \wedge \text{ListResourcesIdealLO}(\text{glossary}) \wedge \text{ListResourcesIdealLO}(\text{guideline}) \wedge \text{ListResourcesIdealLO}(\text{nonexample}) \wedge \text{ListResourcesIdealLO}(\text{note}) \wedge \text{ListResourcesIdealLO}(\text{presentation}) \wedge \text{ListResourcesIdealLO}(\text{scenario})$
3. $\text{Student}(?student) \wedge \text{IdealLOs}(?idealLO) \wedge \text{hasState}(?idealLO, \text{activeIdealLO})$

-) ^ isRecommendedFor(?idealLO, ?student) ^ hasProfile(?student, ?profile) ^ hasUnderstanding(?profile, sequential) -> ListResourcesIdealLO(guidance)
4. Student(?student) ^ IdealLOs(?idealLO) ^ hasState(?idealLO, activeIdealLO) ^ isRecommendedFor(?idealLO, ?student) ^ Profile(?profile) ^ hasProfile(?student, ?profile) ^ hasUnderstanding(?profile, global) -> ListResourcesIdealLO(outline) ^ ListResourcesIdealLO(overview) ^ ListResourcesIdealLO(summary)
 5. Student(?student) ^ IdealLOs(?idealLO) ^ hasState(?idealLO, activeIdealLO) ^ isRecommendedFor(?idealLO, ?student) ^ Profile(?profile) ^ hasProfile(?student, ?profile) ^ hasInput(?profile, verbal) -> ListResourcesIdealLO(exercise) ^ ListResourcesIdealLO(questionnaire) ^ ListResourcesIdealLO(exam) ^ ListResourcesIdealLO(problemStatement) ^ ListResourcesIdealLO(selfAssessment) ^ ListResourcesIdealLO(index) ^ ListResourcesIdealLO(table) ^ ListResourcesIdealLO(narrativeText) ^ ListResourcesIdealLO(lecture) ^ ListResourcesIdealLO(assessment) ^ ListResourcesIdealLO(community) ^ ListResourcesIdealLO(definition) ^ ListResourcesIdealLO(demonstration) ^ ListResourcesIdealLO(glossary) ^ ListResourcesIdealLO(introduction) ^ ListResourcesIdealLO(note) ^ ListResourcesIdealLO(objective)
 6. Student(?student) ^ IdealLOs(?idealLO) ^ hasState(?idealLO, activeIdealLO) ^ isRecommendedFor(?idealLO, ?student) ^ Profile(?profile) ^ hasProfile(?student, ?profile) ^ hasInput(?profile, visual) -> ListResourcesIdealLO(experiment) ^ ListResourcesIdealLO(diagram) ^ ListResourcesIdealLO(figure) ^ ListResourcesIdealLO(graph) ^ ListResourcesIdealLO(attractor) ^ ListResourcesIdealLO(illustration)
 7. Student(?student) ^ IdealLOs(?idealLO) ^ hasState(?idealLO, activeIdealLO) ^ isRecommendedFor(?idealLO, ?student) ^ Profile(?profile) ^ hasProfile(?student, ?profile) ^ hasProcessing(?profile, activeProcessing) -> ListInteractivityTypeIdealLO(active) ^ ListInteractivityTypeIdealLO(mixed)
 8. Student(?student) ^ IdealLOs(?idealLO) ^ hasState(?idealLO, activeIdealLO) ^ isRecommendedFor(?idealLO, ?student) ^ Profile(?profile) ^ hasProfile(?student, ?profile) ^ hasProcessing(?profile, activeProcessing) -> ListInteractivityLevelIdealLO(medium) ^ ListInteractivityLevelIdealLO(high) ^ ListInteractivityLevelIdealLO(veryHigh)
 9. Student(?student) ^ IdealLOs(?idealLO) ^ hasState(?idealLO, activeIdealLO) ^ isRecommendedFor(?idealLO, ?student) ^ Profile(?profile) ^ hasProfile(?student, ?profile) ^ hasProcessing(?profile, reflective) -> ListInteractivityTypeIdealLO(expositive) ^ ListInteractivityTypeIdealLO(mixed)

-
10. Student(?student) ^ IdealLOs(?idealLO) ^ hasState(?idealLO, activeIdealLO) ^ isRecommendedFor(?idealLO, ?student) ^ Profile(?profile) ^ hasProfile(?student, ?profile) ^ hasProcessing(?profile, reflective) -> ListInteractivityLevelIdealLO(medium) ^ ListInteractivityLevelIdealLO(low) ^ ListInteractivityLevelIdealLO(veryLow)

Questionário 1

Parte 1:

1. Nome completo

2. Número de matrícula

3. O nível do meu conhecimento que o sistema está informando em cada um dos conceitos da disciplina está correto. 1 - Discordo totalmente 5 - Concordo totalmente

1 2 3 4 5

4. Ao término de uma aula, eu costumo buscar materiais extras para aprofundar no conteúdo. 1 - Discordo totalmente 5 - Concordo totalmente

1 2 3 4 5

5. As aulas que foram recomendadas para mim como reforço são aulas que possuem conteúdo que apresento dificuldades. 1 - Discordo totalmente 5 - Concordo totalmente

1 2 3 4 5

Questionário 2

1. Nome completo

2. Número de matrícula

3. Título da aula

4. No fim da apresentação dessa aula você recebeu recomendações personalizadas de materiais extras acerca do assunto da aula. Qual você preferiu?

- Recomendação personalizada com EA
- Recomendação sem EA e com mais de um formato de material
- Indiferente

5. Em geral, os vídeos recomendados para esta aula estão relacionados com o conteúdo apresentado. 1 - Discordo totalmente (nada relacionados) 5 - Concordo totalmente (totalmente relacionados)

- 1 2 3 4 5

6. Em geral, os textos recomendados para esta aula estão relacionados com o conteúdo apresentado. 1 - Discordo totalmente (nada relacionados) 5 - Concordo totalmente (totalmente relacionados).

- 1 2 3 4 5

7. Se eu utilizar os materiais extras recomendados nesta aula como fonte complementar de estudos, acredito que vou ter melhor rendimento acerca do conteúdo. 1 - Discordo

totalmente (não há nenhum ganho de aprendizagem) 5 - Concordo totalmente (vou ter um desempenho bem melhor).

1 2 3 4 5

8. No fim da apresentação dessa aula você recebeu recomendações personalizadas de materiais extras acerca do assunto da aula. Qual você preferiu?

- Vídeos
- Textos
- Slides de aula

9. Sobre a recomendação de material adicional com EA, a quantidade de materiais recomendados foi:

- Pouco, gostaria de mais
- Quantidade boa
- Alta, gostaria de menos materiais

10. Sobre a recomendação de material adicional sem EA, a quantidade de materiais recomendados foi:

- Pouco, gostaria de mais
- Quantidade boa
- Alta, gostaria de menos materiais

11. Gostaria de deixar alguma observação?

Questionário 3

Identificação:

Número de matrícula

Curso

Título da aula

O questionário a seguir (ResQue) é baseado no trabalho de Pu, Chen e Hu (2011). Para as questões, você responderá de 1 a 5 de acordo com a seguinte escala:

- 1- Discordo totalmente
- 2- Discordo
- 3- Nem discordo e nem concordo
- 4- Concordo
- 5- Concordo totalmente

1. Os materiais recomendados para mim corresponderam aos meus interesses.

	1	2	3	4	5
Recomendação de Material 1	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 2	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 3	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

2. O sistema de recomendação me ajudou a descobrir novos materiais.

	1	2	3	4	5
Recomendação de Material 1	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 2	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 3	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

3. Os materiais recomendados para mim foram diversificados.

	1	2	3	4	5
Recomendação de Material 1	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 2	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 3	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

4. O layout da interface do sistema de recomendação é atrativo.

	1	2	3	4	5
Recomendação de Material 1	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 2	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 3	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

5. O sistema de recomendação explica porque os materiais foram recomendados para mim.

	1	2	3	4	5
Recomendação de Material 1	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 2	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 3	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

6. As informações fornecidas para os materiais recomendados são suficientes para eu tomar uma decisão de abri-los.

	1	2	3	4	5
Recomendação de Material 1	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 2	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 3	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

7. Eu achei fácil informar ao sistema se eu não gosto/gosto do item recomendado.

	1	2	3	4	5
Recomendação de Material 1	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 2	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 3	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

8. Eu me tornei familiar com o sistema de recomendação muito facilmente.

	1	2	3	4	5
Recomendação de Material 1	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 2	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 3	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

9. Me sinto no controle para modificar minhas preferências.

	1	2	3	4	5
Recomendação de Material 1	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 2	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 3	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

10. Eu entendi porque estes conteúdos foram recomendados para mim.

	1	2	3	4	5
Recomendação de Material 1	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 2	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 3	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

11. O recomendador me deu boas sugestões.

	1	2	3	4	5
Recomendação de Material 1	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 2	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 3	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

12. Em geral, eu estou satisfeito com o sistema de recomendação.

	1	2	3	4	5
Recomendação de Material 1	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 2	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 3	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

13. O sistema de recomendação é confiável.

	1	2	3	4	5
Recomendação de Material 1	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 2	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 3	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

14. Eu usarei este recomendador outra vez.

	1	2	3	4	5
Recomendação de Material 1	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 2	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Recomendação de Material 3	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

A seguir, as perguntas finais ainda sobre a recomendação.

1. Olhando a recomendação como um conjunto de materiais (não somente 1 item isolado). Alguma das recomendações foram iguais?
 - Pouco, gostaria de mais
 - Quantidade boa
 - Alta, gostaria de menos materiais
2. A Recomendação de Material 2 foi em sua maioria?
 - Quantidade igual para ambos
 - Vídeo
 - Texto
3. Caso queira, deixe aqui alguma observação que você julga relevante acerca das recomendações.
