

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

Cleon Xavier Pereira Junior<sup>1,2</sup>, Rafael Dias Araújo<sup>1</sup>, Fabiano Azevedo Dorça<sup>1</sup>

<sup>1</sup> Universidade Federal de Uberlândia (UFU)  
Uberlândia, MG – Brasil

<sup>2</sup>Instituto Federal Goiano (IF Goiano)  
Iporá, GO – Brasil

cleon.junior@ifgoiano.edu.br, {rafael.araujo, fabianodor}@ufu.br

**Abstract.** *This paper presents an approach that makes use of Semantic Web technologies and a bio-inspired algorithm to perform personalized recommendation of Learning Objects (LO). Unlike approaches already proposed, this research combines Virtual Learning Environment (VLE) repositories and materials available on the Web (Youtube and Wikipedia), structured in LO format, with the purpose of covering topics of a given content with materials in different formats. The main experiment considered three recommendation processes intending to observe preference possibilities. The overall average of the recommendation evaluation was relatively better disregarding the use of learning styles, but there was no statistical significance.*

**Resumo.** *Este trabalho apresenta uma abordagem que faz uso de tecnologias de Web Semântica e um algoritmo bioinspirado para realizar recomendação personalizada de Objetos de Aprendizagem (OA). Diferente de abordagens já propostas, esta pesquisa combina repositórios de Ambiente Virtual de Aprendizagem (AVA) e materiais disponibilizados na Web (Youtube e Wikipedia), estruturados em formato de OA, com o propósito de cobrir tópicos de um determinado conteúdo com materiais em formatos distintos. Foram realizados experimentos distintos sendo que o principal experimento considerou três processos de recomendação na intenção de observar possibilidades de preferências. A média geral da avaliação da recomendação foi relativamente melhor desconsiderando o uso dos estilos de aprendizagem, porém não houve significância estatística.*

## 1. Introdução

O uso de técnicas computacionais para suporte no processo de ensino e aprendizagem é cada vez mais recorrente. É de praxe utilizar 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 estudantes deve estar em paralelo com a evolução computacional de tal forma que o ensino ocorra cada vez mais personalizado às necessidades individuais.

Uma das formas de personalizar o processo de aprendizagem é através do uso de recomendações. Com relação à recomendação personalizada em ambientes educacionais, essa tem apresentado avanços significativos. Um motivo que facilita o processo

de personalização no processo de recomendação é a quantidade de dados disponíveis [Drachsler et al. 2015]. Os Cursos On-line Abertos e Massivos (MOOC) são exemplos em geração de dados, pois cursos nesse formato possuem um alto número de estudantes conectados que, além de fornecer informações pessoais, ainda geram dados de comportamento desses aprendizes no ambiente.

Existe um crescimento de exploração de dados de estudantes que são relevantes e têm colaborado para o processo de personalização da aprendizagem [Drachsler et al. 2015]. 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 ambientes de aprendizagem. Uma vez que há uma alta quantidade de materiais na Web, é importante que a recomendação de conteúdo significativo à aprendizagem não seja limitada somente a repositórios de Objetos de Aprendizagem (OA), por vezes específicos de uma plataforma [De 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, por ambientes de aprendizagem.

Nos AVA, recursos educacionais são constantemente recomendados em forma de OA. Recomendar os melhores objetos de aprendizagem, 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 [Belizário and Dorça 2018]. Nesse caso, o problema se torna NP-difícil [Bernhard and Vygen 2008]. Soluções utilizando algoritmos bioinspirados (principalmente que consideram meta-heurísticas) costumam ser viáveis nessas circunstâncias, pois o problema envolve um processo de busca e seleção.

Ainda sobre sistemas de recomendação, uma das estratégias utilizadas para prover recursos ao usuário é conhecida por Filtragem Baseada em Conteúdo (FBC) [Lops et al. 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 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 Moodle<sup>1</sup>, 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.

No intuito de colaborar com a pesquisa de Informática na Educação (IE), este trabalho explora o processo de recomendação personalizada de materiais educacionais, utilizando FBC, através do desenvolvimento de uma abordagem que consegue recuperar materiais da Web e recomendar em formato de OA, a partir das necessidades individuais de estudantes. Além disso, a abordagem desenvolvida não é de uso exclusivo do ambiente

---

<sup>1</sup><https://moodle.org/>

utilizado como teste, evitando problemas de alta acoplagem, já apontados na literatura.

## 2. Trabalhos Correlatos

Foi realizada uma busca por pesquisas na área de computação aplicada à 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 1.

**Tabela 1. Síntese dos trabalhos correlatos**

Trabalho	A	B	C	D	E	F
[El-Bishouty et al. 2014]	○	○	●	●	○	●
[Kurilovas et al. 2014]	○	○	○	●	○	●
[Song et al. 2016]	○	○	○	●	○	○
[García-Floriano et al. 2017]	○	●	●	○	○	○
[Ince et al. 2017]	○	○	●	●	○	●
[Bhaskaran and Santhi 2017]	○	○	○	●	○	●
[Rastegarmoghadam and Ziarati 2017]	○	○	●	●	○	●
[Gordillo et al. 2017]	○	○	●	●	○	○
[Rodríguez et al. 2017]	○	○	●	●	●	○
[Hassan and Hamada 2017]	○	○	○	●	○	○
[de Borba et al. 2017]	○	○	○	●	○	○
[Bocanegra et al. 2017]	●	○	○	●	●	○
[Dwivedi et al. 2018]	○	○	○	●	○	●
[Beldjoudi et al. 2018]	●	○	○	●	●	●
[Wan and Niu 2018]	○	○	●	●	○	○
[Rivero-Albarrán et al. 2018]	○	○	○	●	○	○
[Pal et al. 2019]	●	●	○	○	●	○
[Nafea et al. 2019]	○	○	●	●	○	○
[Hameed and El-Ameer 2019]	○	○	●	●	○	○
[EL AISSAOUI and OUGHDIR 2020]	○	○	○	●	●	○
[Doja et al. 2020]	○	○	○	●	○	○
[Morillo-Palacios and Gutiérrez-Cárdenas 2020]	○	○	●	●	●	○
[Gordillo et al. 2020]	○	○	●	●	○	○
[Jordán et al. 2020]	○	○	●	●	○	○
[Slimani et al. 2020]	○	○	○	●	○	○
<b>Abordagem Desenvolvida</b>	●	●	●	●	●	●

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

A Tabela 1 está dividida em sete colunas. A primeira coluna é a referência do trabalho, já as demais colunas são as características 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, em simultâneo, 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.

Nota-se que, apesar da grande exploração de técnicas computacionais de otimização para o processo de recomendação, a maioria 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 quantidade significativa 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 Estilos de Aprendizagem (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 esforçam 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 Inteligência Artificial (IA) [Obeid et al. 2018, Belizário and Dorça 2018, Tambe and Kadam 2016].

### 3. Abordagem Proposta

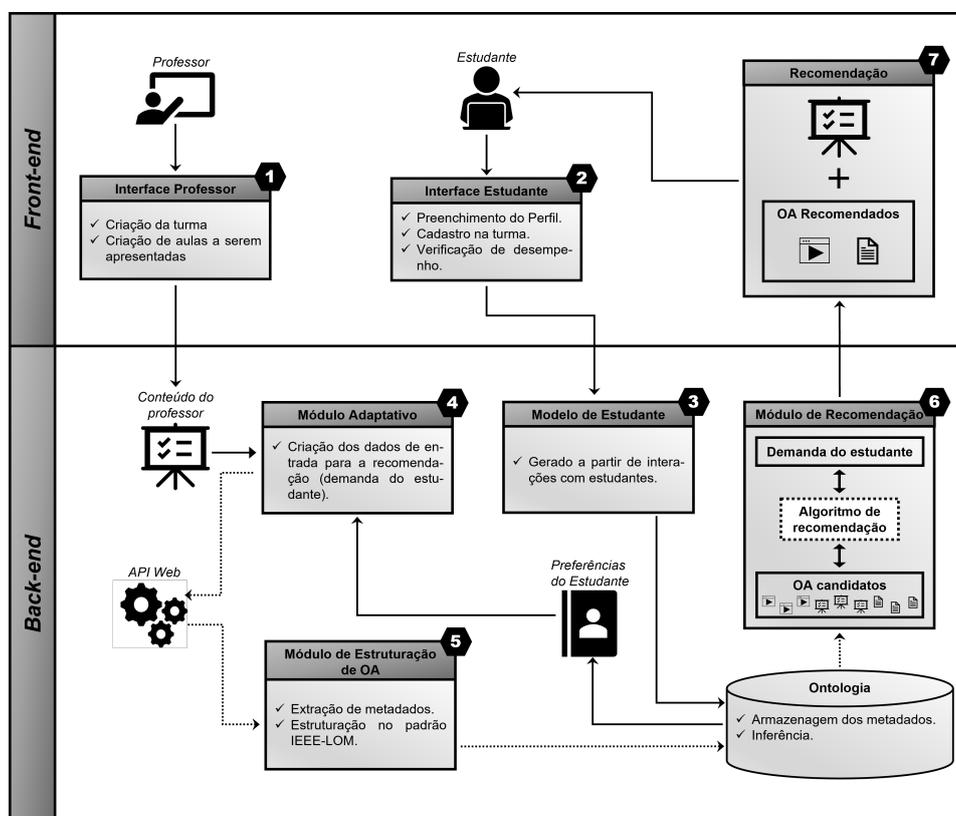


Figura 1. Visão geral do SR baseado em FBC.

Este trabalho apresenta a proposta de uma abordagem para recomendação personalizada de materiais adicionais, a partir de um determinado conteúdo e preferências do

estudante. O SR conta com FBC e consegue recomendar OA presentes no repositório da aplicação e também em páginas da Web. A Figura 1 é uma visão geral da abordagem.

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 2018] foi modificada na intenção de armazenar e representar metadados e realizar inferências.

A Figura 1 apresenta uma visão geral da abordagem. Considerando que é o primeiro acesso do estudante na ferramenta, ele será estimulado a preencher um questionário para coleta manual dos EA (o questionário é conhecido como *Index of Learning Styles* ou ILS) para uma definição inicial desses estilos conforme os modelo de Felder e Silverman. O preenchimento é facultativo e pode ser realizado a qualquer momento, inclusive de forma fracionada, de acordo com o AVA utilizado. Independente do preenchimento do questionário ILS, o estudante deve cadastrar em uma disciplina que deseja acompanhar pelo AVA (marcador 2 da Figura 1). Na 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 e o SR poderá recomendar materiais de acordo com esse conhecimento.

Na marcação 1 da Figura 1 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). O objetivo da seleção é encontrar um subconjunto de OA, a um custo mínimo, que cubra todos os conceitos apontados na demanda do estudante. Assim, a solução proposta está usando a teoria do Problema de Cobertura por Conjunto (PCC) [Cormen et al. 2009]. A partir de uma matriz binária  $a_{ij}$  com  $m$  linhas e  $n$  colunas, o PCC tenta cobrir todas as linhas usando um subconjunto das colunas a um custo mínimo.

Após realizar o processo de seleção, podem ser recomendados OA conforme o nível de conhecimento do estudante e os EA (marcador 7). O método de recomendação pode utilizar somente os metadados armazenados na ontologia ou recuperar materiais da Web que serão 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 material 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.

Um modelo resumido da abordagem foi apresentado em [Pereira et al. 2019] e traz uma visão geral da proposta desta pesquisa, porém sem muitos detalhes. Posteriormente um trabalho mais completo foi apresentado em [Pereira et al. 2020a] e detalha os módulos destacados pelos marcadores 4, 5, 6 e 7.

#### 4. Experimentos e Resultados

O primeiro experimento da pesquisa consistiu na análise comparativa de algoritmos bi-oinspirados que pudessem dar suporte no processo de recomendação considerando o PCC. Tal experimento está diretamente ligado ao marcador 6 da Figura 1. Outro experimento se deu em validar a possibilidade de recomendação de materiais utilizando dados de um 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. Ambos os experimentos foram publicados e os resultados podem ser acessados em [Pereira et al. 2020b] e [Pereira et al. 2020a].

Uma vez validada a abordagem no AVA Classroom eXperience (CX), foi criado um componente também para o AVA Moodle para verificar se o SR cumpria com o requisito de ser fracamente acoplado a um determinado AVA, isto é, se é possível utilizar em diferentes AVA. O recurso criado para o Moodle conseguiu conectar no servidor onde a abordagem apresentada aqui foi hospedada e, a partir de dados de entrada, retornou saídas esperadas, sendo um resultado satisfatório para validar a questão de acoplagem. A Figura 2 apresenta uma visualização do retorno de materiais extras, a partir de um conteúdo específico, no AVA Moodle.

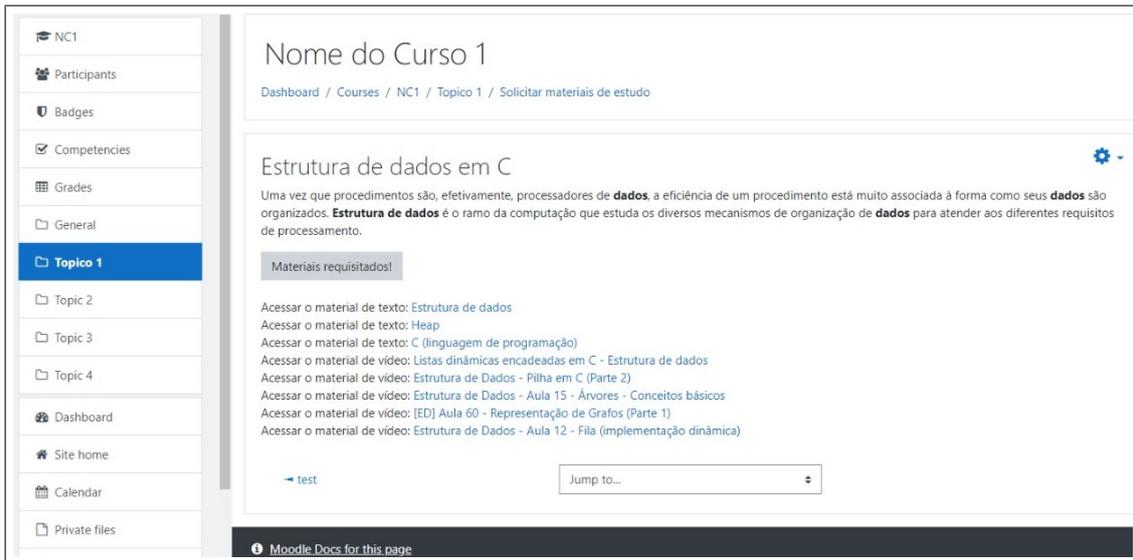
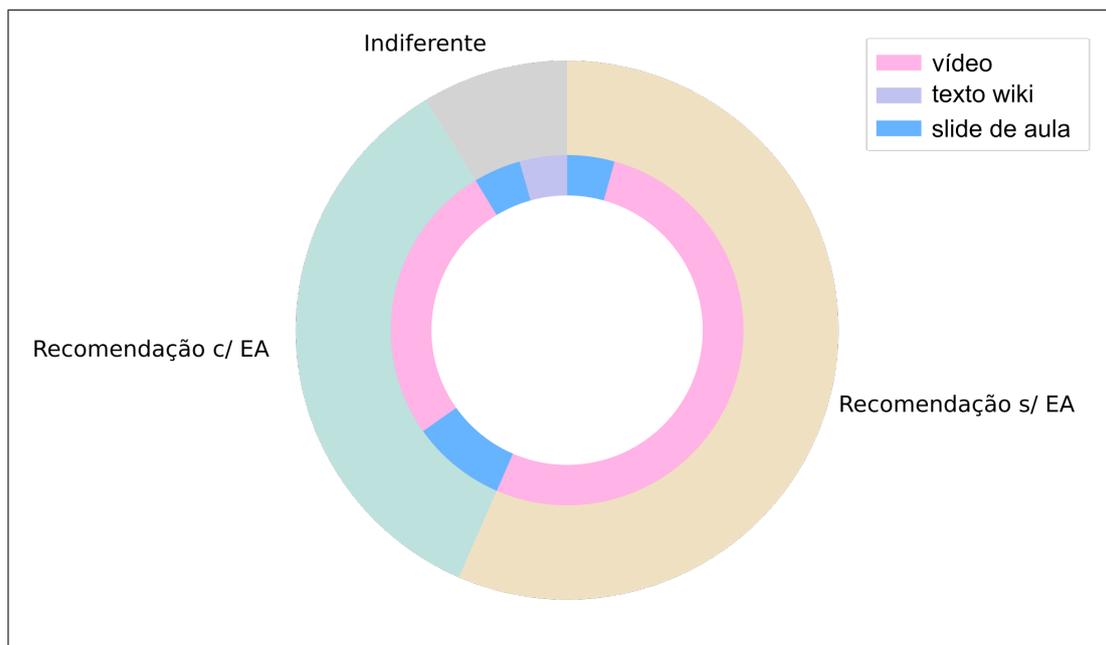


Figura 2. Apresentação para estudantes no Moodle.

O experimento seguinte iniciou com a criação de uma turma no AVA CX, a criação de uma rede bayesiana para auxiliar na modelagem do estudante e testes com estudantes voluntários dessa turma. 17 estudantes participaram da pesquisa. 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. Cada estudante poderia avaliar uma ou mais recomendações. Após um período de adaptação com a ferramenta, estudantes voluntários responderam questionários da percepção sobre a recomendação. 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 3 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 3. Gráfico comparativo das preferências de recomendação e de materiais.**

Ainda observando a Figura 3, 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.

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 (*Recommender systems' Quality of user experience* [Pu et al. 2011]) foi aplicado no último experimento para sumarizar a experiência do usuário no processo de recomendação.

Cada estudante foi submetido a três recomendações distintas: 1) Recomendação

de materiais a partir de um conteúdo sem considerar EA. 2) Recomendação de materiais a partir de um conteúdo considerando os EA. 3) Recomendação de materiais, considerando os EA, e trazendo no mínimo um material de cada formato. Para este experimento foram utilizados 23 estudantes. O número baixo se deu pela aplicação ter sido realizada durante o período de distanciamento social causado pela COVID-19, dificultando encontrar voluntários. A Tabela 2 traz os resultados do questionário.

**Tabela 2. 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 responderam 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
<b>Desempenho Geral</b>		<b>4.01</b>		<b>3.77</b>		<b>3.84</b>

No geral, observou-se que todas as recomendações tiveram desempenho final acima de 3.5 (para uma escala de 1 a 5), o que pode ser considerado um bom resultado. Para a recomendação que aparentou ser relativamente melhor, o único critério de seleção era a cobertura de conteúdo considerando 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 foram consideradas, procurando melhorar o recomendador em geral.

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 and 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. 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.

## 5. 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 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.

## Referências

- Beldjoudi, S., Seridi, H., and Karabadjji, N. E. I. (2018). Recommendation in collaborative e-learning by using linked open data and ant colony optimization. In *International Conference on Intelligent Tutoring Systems*, pages 23–32. Springer. [https://doi.org/10.1007/978-3-319-91464-0\\_3](https://doi.org/10.1007/978-3-319-91464-0_3).
- Belizário Júnior, C. (2018). 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. Master's thesis, Universidade Federal de Uberlândia. <https://doi.org/10.5753/cbie.sbie.2018.1533>.
- Belizário Júnior, C. and Dorça, F. (2018). 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)*, volume 29, page 1533. <https://doi.org/10.5753/cbie.sbie.2018.1533>.
- Bernhard, K. and Vygen, J. (2008). Combinatorial optimization: Theory and algorithms. *Springer, Third Edition, 2005*.
- Bhaskaran, S. and Santhi, B. (2017). An efficient personalized trust based hybrid recommendation (tbhr) strategy for e-learning system in cloud computing. *Cluster Computing*, pages 1–13. <https://doi.org/10.1007/s10586-017-1160-5>.
- Bocanegra, C. L. S., Ramos, J. L. S., Rizo, C., Civit, A., and Fernandez-Luque, L. (2017). Healthrecsys: A semantic content-based recommender system to complement health

- videos. *BMC medical informatics and decision making*, 17(1):1–10. <https://doi.org/10.1186/s12911-017-0431-7>.
- Cormen, T. H., Leiserson, C. E., Rivest, R. L., and Stein, C. (2009). *Introduction to algorithms*. MIT press.
- de Borba, E. J., Gasparini, I., and Lichtnow, D. (2017). The use of time dimension in recommender systems for learning. In *International Conference on Enterprise Information Systems*, volume 2, pages 600–609. SCITEPRESS.
- De Medio, C., Limongelli, C., Marani, A., and Taibi, D. (2019). Retrieval of educational resources from the web: A comparison between google and online educational repositories. In *International Conference on Web-Based Learning*, pages 28–38. Springer. [https://doi.org/10.1007/978-3-030-35758-0\\_3](https://doi.org/10.1007/978-3-030-35758-0_3).
- Doja, M. et al. (2020). An improved recommender system for e-learning environments to enhance learning capabilities of learners. In *Proceedings of ICETIT 2019*, pages 604–612. Springer. [https://doi.org/10.1007/978-3-030-30577-2\\_53](https://doi.org/10.1007/978-3-030-30577-2_53).
- Drachler, H., Verbert, K., Santos, O. C., and Manouselis, N. (2015). *Panorama of Recommender Systems to Support Learning*, pages 421–451. Springer US, Boston, MA. [https://doi.org/10.1007/978-1-4899-7637-6\\_12](https://doi.org/10.1007/978-1-4899-7637-6_12).
- Dwivedi, P., Kant, V., and Bharadwaj, K. K. (2018). Learning path recommendation based on modified variable length genetic algorithm. *Education and Information Technologies*, 23(2):819–836. <https://doi.org/10.1007/s10639-017-9637-7>.
- EL AISSAOUI, O. and OUGHDIR, L. (2020). A learning style-based ontology matching to enhance learning resources recommendation. In *2020 1st International Conference on Innovative Research in Applied Science, Engineering and Technology (IRASET)*, pages 1–7. IEEE. <https://doi.org/10.1109/IRASET48871.2020.9092142>.
- El-Bishouty, M. M., Chang, T.-W., Graf, S., Chen, N.-S., et al. (2014). Smart e-course recommender based on learning styles. *Journal of Computers in Education*, 1(1):99–111. <https://doi.org/10.1007/s40692-014-0003-0>.
- García-Floriano, A., Ferreira-Santiago, A., Yáñez-Márquez, C., Camacho-Nieto, O., Aldape-Pérez, M., and Villuendas-Rey, Y. (2017). Social web content enhancement in a distance learning environment: intelligent metadata generation for resources. *International Review of Research in Open and Distributed Learning*, 18(1):161–176. <https://doi.org/10.19173/irrodl.v18i1.2646>.
- Gordillo, A., Barra, E., and Quemada, J. (2017). A hybrid recommendation model for learning object repositories. *IEEE Latin America Transactions*, 15(3):462–473. <https://doi.org/10.1109/TLA.2017.7867596>.
- Gordillo, A., López-Fernández, D., and Verbert, K. (2020). Examining the usefulness of quality scores for generating learning object recommendations in repositories of open educational resources. *Applied Sciences*, 10(13):4638. <https://doi.org/10.3390/app10134638>.
- Hameed, M. R. and El-Ameer, A. S. (2019). Proposed recommender system for open educational resources for informatics institute for postgraduate studies. In *2019 International Engineering Conference (IEC)*, pages 126–130. IEEE. <https://doi.org/10.1109/IEC47844.2019.8950569>.

- Hassan, M. and Hamada, M. (2017). Smart media-based context-aware recommender systems for learning: A conceptual framework. In *2017 16th International Conference on Information Technology Based Higher Education and Training (ITHET)*, pages 1–4. IEEE. <https://doi.org/10.1109/ITHET.2017.8067805>.
- İnce, M., Yiğit, T., and Işık, A. H. (2017). A hybrid ahp-ga method for metadata-based learning object evaluation. *Neural Computing and Applications*, pages 1–11. <https://doi.org/10.1007/s00521-017-3023-7>.
- Jordán, J., Valero, S., Turró, C., and Botti, V. (2020). Recommending learning videos for moocs and flipped classrooms. In *International Conference on Practical Applications of Agents and Multi-Agent Systems*, pages 146–157. Springer. [https://doi.org/10.1007/978-3-030-49778-1\\_12](https://doi.org/10.1007/978-3-030-49778-1_12).
- Kirschner, P. A. (2017). Stop propagating the learning styles myth. *Computers & Education*, 106:166–171. <https://doi.org/10.1016/j.compedu.2016.12.006>.
- Kurilovas, E., Zilinskiene, I., and Dagiene, V. (2014). Recommending suitable learning scenarios according to learners’ preferences: An improved swarm based approach. *Computers in Human Behavior*, 30:550–557.
- Lops, P., De Gemmis, M., and Semeraro, G. (2011). Content-based recommender systems: State of the art and trends. In *Recommender systems handbook*. Springer. [https://doi.org/10.1007/978-0-387-85820-3\\_3](https://doi.org/10.1007/978-0-387-85820-3_3).
- Morillo-Palacios, B. and Gutiérrez-Cárdenas, J. (2020). Content-based learning object recommendation system using a user profile ontology for high school students. In *Proceedings of the Future Technologies Conference*, pages 838–858. Springer. [https://doi.org/10.1007/978-3-030-63128-4\\_63](https://doi.org/10.1007/978-3-030-63128-4_63).
- Nafea, S. M., Siewe, F., and He, Y. (2019). On recommendation of learning objects using felder-silverman learning style model. *IEEE Access*, 7:163034–163048. <https://doi.org/10.1109/ACCESS.2019.2935417>.
- Obeid, C., Lahoud, I., El Khoury, H., and Champin, P.-A. (2018). Ontology-based recommender system in higher education. In *Companion Proceedings of the The Web Conference 2018*, pages 1031–1034. <https://doi.org/10.1145/3184558.3191533>.
- Pal, S., Pramanik, P. K. D., Majumdar, T., and Choudhury, P. (2019). A semi-automatic metadata extraction model and method for video-based e-learning contents. *Education and Information Technologies*, 24(6):3243–3268. <https://doi.org/10.1007/s10639-019-09926-y>.
- Pereira Júnior, C., Araújo, R. D., and Dorça, F. A. (2020a). Recomendação personalizada de conteúdo instrucional complementar usando repositório de objetos de aprendizagem e recursos da web. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação*, pages 1293–1302. SBC. <https://doi.org/10.5753/cbie.sbie.2020.1293>.
- Pereira Júnior, C., Belizario Júnior, C., Araújo, R., and Dorça, F. (2020b). 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*, pages 1333–1342, Porto Alegre, RS, Brasil. SBC. <https://doi.org/10.5753/cbie.sbie.2020.1333>.
- Pereira Junior, C. X., Dorça, F. A., and Araujo, R. D. (2019). Towards an adaptive approach that combines semantic web technologies and metaheuristics to create and recommend learning objects. In *2019 IEEE 19th International Conference on Advanced Learning Technologies (ICALT)*, volume 2161, pages 395–397. IEEE. <https://doi.org/10.1109/ICALT.2019.00118>.
- Pu, P., Chen, L., and Hu, R. (2011). A user-centric evaluation framework for recommender systems. In *Proceedings of the fifth ACM conference on Recommender systems*, pages 157–164. <https://doi.org/10.1145/2043932.2043962>.
- Rastegarmoghadam, M. and Ziarati, K. (2017). Improved modeling of intelligent tutoring systems using ant colony optimization. *Education and Information Technologies*, 22(3):1067–1087. <https://doi.org/10.1007/s10639-016-9472-2>.
- Rivero-Albarrán, D., Rivas-Echeverria, F., Guerra, L., Arellano, B., and Arciniegas, S. (2018). Design of a recommender system for intelligent classrooms based on multiagent systems. In *International Conference on Information Technology & Systems*, pages 973–982. Springer. [https://doi.org/10.1007/978-3-319-73450-7\\_92](https://doi.org/10.1007/978-3-319-73450-7_92).
- Rodríguez, P., Heras, S., Palanca, J., Poveda, J. M., Duque, N., and Julián, V. (2017). An educational recommender system based on argumentation theory. *AI Communications*, 30(1):19–36. <https://doi.org/10.3233/AIC-170724>.
- Slimani, H., Hamal, O., El faddouli, N.-e., Bennani, S., and Amrous, N. (2020). 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*, pages 1–9. <https://doi.org/10.1145/3419604.3419621>.
- Song, B., Zhuo, Y., and Li, X. (2016). A personalized intelligent tutoring system of primary mathematics based on perl. In *International Conference on Swarm Intelligence*, pages 609–617. Springer. [https://doi.org/10.1007/978-3-319-41009-8\\_66](https://doi.org/10.1007/978-3-319-41009-8_66).
- Tambe, S. S. and Kadam, G. V. (2016). An efficient framework for e-learning recommendation system using fuzzy logic and ontology. *International Research Journal of Engineering and Technology (IRJET)*, 3(6):2062–2067.
- Vargha, A. and Delaney, H. D. (1998). The kruskal-wallis test and stochastic homogeneity. *Journal of Educational and behavioral Statistics*, 23(2):170–192. <https://doi.org/10.3102/10769986023002170>.
- Wan, S. and Niu, Z. (2018). An e-learning recommendation approach based on the self-organization of learning resource. *Knowledge-Based Systems*, 160:71 – 87. <https://doi.org/10.1016/j.knosys.2018.06.014>.