

UNIVERSIDADE FEDERAL DE PELOTAS
Centro de Desenvolvimento Tecnológico
Programa de Pós-Graduação em Computação



Dissertação

Um framework de sistemas de recomendação para uso no ensino não-formal

Mateus Wachholz Noremberg

Pelotas, 2020

Mateus Wachholz Noremberg

Um framework de sistemas de recomendação para uso no ensino não-formal

Dissertação apresentada ao Programa de Pós-Graduação em Computação do Centro de Desenvolvimento Tecnológico da Universidade Federal de Pelotas, como requisito parcial à obtenção do título de Mestre em Ciência da Computação.

Orientador: Prof. Dr. Marilton Sanchotene de Aguiar
Coorientador: Prof. Dr. Tiago Thompsen Primo

Pelotas, 2020

Universidade Federal de Pelotas / Sistema de Bibliotecas
Catalogação na Publicação

N834f Noremberg, Mateus Wachholz

Um framework de sistemas de recomendação para uso no ensino não-formal / Mateus Wachholz Noremberg ; Marilton Sanchotene de Aguiar, orientador ; Tiago Thompsen Primo, coorientador. — Pelotas, 2020.

64 f.

Dissertação (Mestrado) — Programa de Pós-Graduação em Computação, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas, 2020.

1. Sistemas de recomendação. 2. Educação. 3. Ensino não-formal. 4. Aprendizado não-formal. I. Aguiar, Marilton Sanchotene de, orient. II. Primo, Tiago Thompsen, coorient. III. Título.

CDD : 005

Mateus Wachholz Noremberg

Um framework de sistemas de recomendação para uso no ensino não-formal

Dissertação aprovada, como requisito parcial, para obtenção do grau de Mestre em Ciência da Computação, Programa de Pós-Graduação em Computação, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas.

Data da Defesa: 4 de setembro de 2020

Banca Examinadora:

Prof. Dr. Marilton Sanchotene de Aguiar (orientador)

Doutor em Computação pela Universidade Federal do Rio Grande do Sul.

Prof. Dr. Tiago Thompsen Primo (coorientador)

Doutor em Computação pela Universidade Federal do Rio Grande do Sul.

Prof. Dra. Ana Marilza Pernas Fleischmann

Doutora em Computação pela Universidade Federal do Rio Grande do Sul.

Prof. Dra. Isabela Gasparini

Doutora em Computação pela Universidade Federal do Rio Grande do Sul.

RESUMO

NOREMBERG, Mateus Wachholz. **Um framework de sistemas de recomendação para uso no ensino não-formal**. Orientador: Marilton Sanchotene de Aguiar. 2020. 64 f. Dissertação (Mestrado em Ciência da Computação) – Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas, Pelotas, 2020.

Os sistemas de recomendação (SR) estão presentes nas mais diversas áreas. Entre elas, uma área na qual os SR vem ganhando cada vez mais relevância é a área da educação. Uma vez que as pessoas estão constantemente aprendendo, não só de maneira formal na escola/universidade, pode-se observar um interesse cada vez maior na busca de cursos, normalmente online, que forneçam alguma capacitação para o estudante. Essa área de ensino é classificada como ensino não-formal. Dessa forma, como o aluno pode estar aprendendo de diferentes maneiras e em diferentes lugares, a informação que está ao seu redor, no seu ambiente, ou seja, seu contexto, pode influenciar no modo como o aluno aprende. Em um primeiro momento, este trabalho apresenta uma revisão sistemática da literatura para identificar aspectos dos SR aplicados no ensino não-formal, bem como avaliar se, e como, a informação de contexto vem sendo aplicada nesses sistemas. A partir dessa análise, propõem-se um *framework* de recomendação que utilize a informação de contexto do aluno. O *framework* proposto consiste em quatro etapas, sendo elas a etapa de entrada e preparação dos dados, a etapa de filtragem e geração das recomendações preliminares, a etapa de hibridização do SR, onde a informação de contexto do aluno é aplicada para aproximar a realidade do aluno para as recomendações, e, por fim, a etapa de saída, onde são fornecidas as recomendações. Para avaliar o *framework* foram conduzidos experimentos de maneira *offline* em um *dataset* sintético, construído com informações de interação de usuários com objetos de aprendizagem, e com informações check-in dos usuários para simular as informações de contexto. Os resultados obtidos pelo *framework* foram avaliados em termos de cobertura das recomendações, similaridade entre os objetos de aprendizado recomendados, personalização, precisão e revocação. Conforme pode ser observado, o *framework* apresentou resultados promissores, tendo uma ótima cobertura, um equilíbrio na similaridade entre as recomendações, podendo assim gerar certa novidade nas recomendações e uma taxa de personalização das recomendações próxima a 65%.

Palavras-chave: Sistemas de Recomendação. Educação. Ensino não-formal. Aprendizado não-formal.

ABSTRACT

NOREMBERG, Mateus Wachholz. **A framework of recommender systems for use in non-formal education.** Advisor: Marilton Sanchotene de Aguiar. 2020. 64 f. Dissertation (Masters in Computer Science) – Technology Development Center, Federal University of Pelotas, Pelotas, 2020.

Recommender systems (RS) are present in the most diverse areas. Among them, an area in which RS is gaining more and more relevance is education. Since people are continually learning, not only in a formal way at school/university, one can observe an increasing interest in the search for courses, usually online, that provide some training for the student. We can classify this area of education as non-formal education. Thus, as the student may be learning in different ways and different places, the information that is around him, in his environment, that is, his context, can influence the way the student learns. Firstly, we realize a systematic review of the literature to identify aspects of RS applied in non-formal education. Also, to evaluate if, and how, researchers use the context information in these systems. From this analysis, we propose a recommendation framework that uses the student's context information. The proposed approach consists of four stages: i) data entry and preparation; ii) filtering and generation of preliminary recommendations; iii) RS hybridization, where we apply the student's context information to give a closer sense to the student's reality for the recommendations; and, iv) the exit step, where we provide the suggestions. To evaluate the framework experiments, we conducted an offline manner in a synthetic dataset, constructed with user interaction information with learning objects, and with user check-in information to simulate the context information. We evaluate the results obtained by the framework regarding coverage of the recommendations, the similarity between the recommended learning objects, customization, precision, and recall. As can be seen, the framework presented promising results, with excellent coverage, a balance in the similarity between the recommendations, thus generating some novelty in the recommendations and a recommendation customization rate close to 65%.

Keywords: Recommender Systems. Education. Non-formal education. Non-formal learning.

LISTA DE FIGURAS

Figura 1	Exemplo de itens recomendados na Amazon com base na filtragem baseada em conteúdo.	19
Figura 2	Exemplo de itens recomendados na Amazon com base na filtragem colaborativa.	20
Figura 3	Comparação entre filtragem colaborativa e filtragem baseada em conteúdo.	20
Figura 4	Estrutura da proposta de framework.	35
Figura 5	Exemplo de Objeto de Aprendizagem do dataset sintético.	41
Figura 6	Exemplo de Lugar do dataset sintético.	41
Figura 7	Interações do usuário 190 com objetos de aprendizagem.	42
Figura 8	Check-ins do usuário 190.	43
Figura 9	Check-ins do usuário 629 (à esquerda) e interações com objetos de aprendizagem (à direita).	44
Figura 10	Recomendações geradas para o usuário 190.	44
Figura 11	Ocorrência das categorias nos objetos de aprendizado: a) Categorias técnicas. b) Rótulos dos lugares relacionados.	47
Figura 12	Quantidade de interações com objetos de aprendizado por usuário.	48
Figura 13	Quantidade de usuários que interagiram com cada objeto de aprendizagem.	48
Figura 14	Quantidade de check-ins únicos em diferentes lugares por usuário é média de check-ins por local.	50
Figura 15	Quantidade de check-ins únicos por lugar.	51
Figura 16	Quantidade de lugares por categoria.	51

LISTA DE TABELAS

Tabela 1	Quadro comparativo dos trabalhos selecionados na revisão sistemática.	30
Tabela 2	Quadro comparativo dos trabalhos selecionados na revisão sistemática com o presente trabalho.	39
Tabela 3	Resultados das avaliações do <i>framework</i>	52

LISTA DE ABREVIATURAS E SIGLAS

FBC	Filtragem Baseada em Conteúdo
FC	Filtragem Colaborativa
KNN	<i>K Nearest Neighbors</i>
LOM	<i>Learning Object Metadata</i>
MAP@K	<i>Mean Average Precision at K</i>
MAR@K	<i>Mean Average Recall at K</i>
OA	Objeto de Aprendizagem
RSL	Revisão Sistemática da Literatura
SR	Sistemas de Recomendação

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Objetivos	12
1.2	Estrutura do Texto	13
2	REFERENCIAL TEÓRICO	14
2.1	Tipos de Aprendizado	14
2.2	Contexto	16
2.3	Sistemas de Recomendação	16
2.3.1	Filtragem Baseada em Conteúdo	18
2.3.2	Filtragem Colaborativa	19
2.3.3	Métodos de Hibridização	21
2.3.4	Problemas em Sistemas de Recomendação	23
2.3.5	Avaliação de Sistemas de Recomendação	24
2.4	Sistemas de Recomendação na Educação	26
2.5	Trabalhos Relacionados	27
2.5.1	Metodologia	27
2.5.2	Condução da revisão	28
2.5.3	Resultados	29
2.5.4	Discussão	31
3	O FRAMEWORK PROPOSTO	35
4	TESTES E RESULTADOS	40
4.1	Montagem do <i>Dataset</i>	40
4.2	Definição das Métricas	45
4.3	Análise do <i>Dataset</i>	46
4.4	Análise das Recomendações	52
5	CONCLUSÃO	55
	REFERÊNCIAS	57

1 INTRODUÇÃO

A crescente demanda por conteúdos personalizados tem feito com que sejam cada vez mais utilizados algoritmos que empregam diversas técnicas para entregar ao usuário o conteúdo mais adequado para ele naquele momento. Esse conjunto de técnicas, que incluem o uso de algoritmos de Inteligência Artificial, é conhecido como Sistema de Recomendação (SR) (RICCI et al., 2010).

Os SRs podem ser facilmente encontrados em sistemas de comércio eletrônico (do inglês, *e-commerce*) como, por exemplo, a loja da Amazon¹. Neste caso, os SRs são utilizados para sugerir produtos que o usuário possa ter interesse em comprar com base em seu histórico de interação com o site. Assim sendo, cria-se uma loja personalizada para o usuário, ou seja, com itens que são mais adequados para ele.

Embora tenham uma aplicação mais visível e notável em *sites* de *e-commerce*, os SRs vêm sendo aplicados em diversas áreas, do entretenimento à educação. Surgindo a partir de pesquisas anteriores nas áreas de ciências cognitivas e recuperação de informação, entre outras, desde a década de 1990, os SRs têm sido tratados como uma área separada, conforme relata ADOMAVICIUS; TUZHILIN (2005). Já no início da década, em 1992, surgia o Tapestry (GOLDBERG et al., 1992), o qual introduziu o conceito de filtragem colaborativa.

Na área da educação, o uso de SR se dá através de sugestão de conteúdos, exercícios ou, inclusive, práticas educacionais com base no andamento do aluno no curso, por exemplo, visando melhorar o aprendizado do aluno ou a prática do professor, seja em um curso com base de aprendizado formal ou não-formal.

O aprendizado formal é aquele no qual o aluno possui uma grade a qual ele precisa cumprir e está ligado a uma instituição de ensino reconhecida e que emite uma certificação como, por exemplo, uma Universidade. Já o aprendizado não-formal, embora também possa seguir uma grade de conteúdo, não está ligado a uma instituição reconhecida por órgãos governamentais. Esse aprendizado se dá, na maioria das vezes, em cursos feitos *online* em alguma das diversas plataformas disponíveis (COLLEY; HODKINSON; MALCOLM, 2002).

¹<https://amazon.com>

Devido a grande demanda por cursos *online* nas mais diversas áreas, desde desenho à programação, seja por *hobby* ou para fins profissionais, a área de aprendizado não-formal é uma área com grande crescimento e com grande potencial de exploração dos recursos que os SR podem oferecer (MOOC-STATS, 2018).

Uma vez que muitos desses cursos são oferecidos por empresas privadas, a retenção e fidelização do aluno, que é o cliente final, se torna algo importante. Assim, melhorar as práticas pedagógicas é também melhorar a qualidade do serviço prestado para esse cliente de forma que ele queira se manter vinculado a empresa.

UNESCO (2015) reforça ainda o conceito de aprendizado ao longo da vida (do inglês, *lifelong learning*), conceito este já utilizado por COLLEY; HODKINSON; MALCOLM (2002). O documento da UNESCO diz que uma pessoa está sempre em busca de novos conhecimentos, mesmo após o término de um curso em uma Universidade, ou seja, após concluir o aprendizado formal. Para tal, utiliza-se do aprendizado não-formal em sites de cursos *online*, por exemplo.

Uma vez que o processo de aprendizagem é constante ao longo da vida, cada vez mais as informações de contexto do estudante vão se tornando ainda mais relevantes para recomendar algo. O contexto é tudo aquilo que está ao redor de alguém como, por exemplo, lugares que frequenta, amigos, entre outros, conforme é definido por SCHMIDT; BEIGL; GELLERSEN (1999).

No presente trabalho foi feito um levantamento sobre as aplicações de Sistemas de Recomendação no contexto do ensino/aprendizado não-formal na forma de uma revisão sistemática da literatura. Esse estudo buscou identificar o estado da arte da aplicação de SR na área da educação baseado no aprendizado não-formal.

Neste levantamento identificou-se que as recomendações em sua maioria são feitas para os alunos em aplicações web. Além disso, vários trabalhos utilizam-se de uma abordagem híbrida, utilizando-se de Filtragem Baseada em Conteúdo e Filtragem Colaborativa. Identificou-se também que a informação de contexto do aluno não vem sendo utilizada na recomendação e os algoritmos não permitem flexibilização para diferentes cenários.

Tomando como base o estudo iniciado em NOREMBERG; AGUIAR; PRIMO (2018), que neste documento foi aqui ampliado e discutido em maior profundidade, esse trabalho apresenta uma proposta de *framework* para aplicação de sistemas de recomendação no ensino não-formal utilizando informações baseadas no contexto dos estudantes para a construção da recomendação.

1.1 Objetivos

O objetivo principal desta dissertação é propor um *framework* para recomendação de objetos de aprendizagem para professores baseado nas informações de contexto

dos alunos voltado para o ensino não-formal.

Mais especificamente, os objetivos deste trabalho são:

1. Apresentar um levantamento bibliográfico acerca de sistemas de recomendação aplicados na área de estudo não-formal e das principais ferramentas, *frameworks* e técnicas utilizadas por estes sistemas;
2. Definição de um *dataset* apropriado ao contexto deste trabalho no que tange aos dados que serão coletados e analisados;
3. Desenvolver um sistema de recomendação que faça recomendações para os professores baseado no contexto de seus alunos; e,
4. Definir cenários para avaliação do sistema de recomendação.

1.2 Estrutura do Texto

Este trabalho é composto por 5 Capítulos apresentados como segue. No Capítulo 1 é feita uma exposição ao assunto deste trabalho, além de apresentar o tema, a justificativa e o objetivo deste trabalho. No Capítulo 2 são apresentados os conceitos fundamentais para a compreensão desse trabalho, bem como é apresentada a revisão sistemática da literatura realizada para a identificação do estado da arte. No Capítulo 3 é apresentado o principal resultado do desenvolvimento do presente trabalho: a proposta de *framework*. No Capítulo 4 são apresentados a metodologia de avaliação do *framework* proposto, bem como uma análise detalhada do *dataset* que foi criado para este trabalho, além dos resultados obtidos na avaliação do *framework*. Por fim, no Capítulo 5 são feitas as considerações finais deste trabalho.

2 REFERENCIAL TEÓRICO

Este Capítulo tem a finalidade de apresentar os conceitos de Sistemas de Recomendação em geral e aplicados na Educação. Além disso, discorre sobre a definição de tipos de aprendizado e de contexto. Esse Capítulo também apresenta um levantamento do estado da arte da área. Todos esses conceitos se fazem necessários para o entendimento do contexto e da abordagem proposta.

2.1 Tipos de Aprendizado

Existem diversas maneiras de se aprender algo. Em geral uma pessoa está em constante fase de aprendizado. Quando crianças, as pessoas começam a aprender a falar em casa. Depois elas aprendem a ler e a escrever na escola. Quando adolescentes, ingressam em uma Universidade e aprendem uma profissão.

Quando estão no trabalho, adquirem novas habilidades através da interação com seus colegas de trabalho ou então fazendo algum curso para se aperfeiçoar e possivelmente receber uma promoção. E dessa maneira as pessoas seguem aprendendo durante toda sua vida. Todo esse processo de aprendizado, do nascer ao morrer, é chamado de aprendizado ao longo da vida (do inglês, *life long learning*) (UNESCO, 2015).

Todas essas diferentes maneiras de se aprender são agrupadas por COLLEY; HODKINSON; MALCOLM (2002) em três categorias: aprendizado formal, aprendizado não-formal e aprendizado informal.

O **aprendizado formal** é aquele fornecido por uma instituição oficial, a qual é regulamentada e normalmente gera uma certificação. O aprendizado possui uma estrutura, ou seja, segue um objetivo e possui um tempo definido. O aprendizado formal é uma ação feita intencionalmente por quem está aprendendo, ou seja, o aprendiz busca por aprender.

Entre os exemplos citados anteriormente, se encaixam nessa categoria o aprendizado adquirido na escola quando criança ou em um curso na Universidade. Ambos são regulamentados, seguem objetivos e tem períodos definidos para cumprir esses

objetivos levando ao aprendizado.

O **aprendizado não-formal** não é fornecido por uma instituição regulamentada e também não necessariamente leva a uma certificação. Entretanto, assim como no aprendizado formal, o aprendizado não-formal é estruturado, ou seja, possui objetivo e tempo definido. Além disso, o aprendizado não-formal também é uma ação que parte do aprendiz, o qual busca o aprendizado.

Entre os exemplos citados anteriormente, podem ser categorizados como aprendizado não-formal algum curso feito *online* para obter melhorar alguma habilidade enquanto está na Universidade. Ou então um curso de idioma feito para conseguir uma promoção no emprego. Em ambos os casos, o aprendiz buscou o aprendizado. Além disso, ambos possuem uma estrutura com objetivos e tempo definidos e não possuem uma regulamentação.

O **aprendizado informal** se dá através de atividades do dia a dia de uma pessoa. Uma pessoa aprende informalmente, por exemplo, em uma conversa com um colega de trabalho, em casa com sua família ou até mesmo ao observar uma situação que acontece ao seu redor.

O aprendizado informal não possui uma estrutura, não tem um objetivo e um tempo de aprendizado. Por esse motivo, muitas vezes ele acontece de forma não intencional.

Vale ressaltar que, embora COLLEY; HODKINSON; MALCOLM (2002) defina essas três categorias, existem algumas interpretações diferentes quanto ao uso desses termos na literatura, os quais são elencados pelo próprio autor em seu trabalho.

Nesse trabalho, usou-se como definição de tipos de aprendizado as três categorias, conforme definidas por COLLEY; HODKINSON; MALCOLM (2002): formal, não-formal e informal.

O aprendizado pode se dar através de inúmeros recursos. Seja através de vídeos, através de um exercício, através de um texto lido, etc. IEEE (2002) define esses diferentes recursos utilizados para se aprender como objetos de aprendizagem (OA). “Um objeto de aprendizagem é definido como uma entidade qualquer, digital ou não, que pode ser usada para aprendizado, educação ou treinamento” (IEEE, 2002).

Uma sequência desses objetos de aprendizagem é definida em MUHAMMAD et al. (2016) como um caminho de aprendizagem (em inglês, *learning path*), o qual tem como objetivo auxiliar o estudante a adquirir o conhecimento em determinado assunto.

Um objeto de aprendizagem pode ser representado através de um conjunto de metadados. IEEE (2002) propõe um padrão de metadados para representação dos objetos de aprendizagem que ficou conhecido como LOM (acrônimo do termo em inglês, *Learning Object Metadata*). O LOM, descreve características relevantes do objeto de aprendizagem ao qual ele se aplica.

Além do LOM, existem outros padrões utilizados para descrever um objeto de

aprendizagem como, por exemplo, o Dublin Core¹ e também o padrão brasileiro OBAA², o qual é baseado no padrão LOM.

Conforme o relatório da UNESCO (2015), uma pessoa está em constante aprendizado ao longo da vida e, dessa forma, a informação do contexto no qual a pessoa (o estudante) está inserido se torna uma informação cada vez mais relevante, dada a definição de conceito.

2.2 Contexto

Conforme explicado por SCHMIDT; BEIGL; GELLERSEN (1999), entende-se como contexto tudo aquilo que está ao redor e que dá um significado a alguma coisa, influenciando no modo de interagir com o ambiente e com outras pessoas. Em outras palavras, pode ser considerado como contexto “qualquer informação que possa ser usada para caracterizar a situação de uma entidade” (FLEISCHMANN, 2012). O contexto descreve a situação e/ou ambiente em que uma determinada pessoa ou objeto se encontra.

Por vezes, o conceito de contexto é confundido com a informação de localização do usuário, uma vez que esta é uma das informações mais exploradas. Entretanto, não está limitada somente a esse tipo de informação.

Conforme descrito em FLEISCHMANN (2012), o contexto pode ser dividido em duas dimensões: **externa** e **interna**. Na dimensão **externa** encontram-se informações como localização, mencionada anteriormente, informações temporais, ou seja, instante em que a instância de contexto ocorre, e informações do ambiente, como temperatura e espaço ocupado, por exemplo.

Já na dimensão **interna** são exploradas informações como preferências do usuário (se prefere ver um vídeo ou ler um texto, por exemplo), as competências do mesmo, e o modo como ele interagiu com o ambiente, por exemplo. Nessa dimensão também se pode incluir informações como páginas de redes sociais que alguém segue, pessoas com as quais se está conectado, entre diversas outras possíveis.

2.3 Sistemas de Recomendação

Os SRs são um conjunto de técnicas e ferramentas que tem como objetivo dar uma sugestão de um novo conteúdo/item a um usuário com base em eventos que tenham ocorrido anteriormente, sejam eles eventos aos quais o próprio usuário está relacionado ou então eventos aos quais algum usuário com características semelhantes tem relação.

Conforme RICCI et al. (2010), para que um SR alcance seu propósito, é necessá-

¹<http://dublincore.org/>

²<http://www.portalobaa.org/>

rio ter um objetivo bem definido. Por exemplo, se um *e-commerce* tem como objetivo aumentar o número de vendas, mas possui um SR configurado de tal forma que ele apenas aumente o número de produtos visualizados pelo usuário, pode ser que não funcione da maneira esperada, pois uma maior gama de produtos vistos não necessariamente quer dizer que o usuário irá comprar. Por outro lado, se ele ver determinado produto várias vezes, pode ser que ele reflita sobre o produto e acabe comprando.

Segundo ADOMAVICIUS; TUZHILIN (2005), que fala também sobre o surgimento dos SRs, o problema de recomendação – que é o problema que os SRs visam resolver – pode ser reduzido ao problema de estimar avaliações de itens que um determinado usuário ainda não interagiu. Essa estimativa é baseada, normalmente, em interações do usuário com outros itens. Assim sendo, uma vez que se possa estimar a avaliação para um item que ainda não foi avaliado, pode-se recomendar para um usuário o item com a maior avaliação estimada.

Os principais conceitos que estão relacionados aos SRs são os conceitos de usuário, item e transação. Esses conceitos são definidos por RICCI et al. (2010), como segue. Um **usuário** em SR é definido como alguém, uma pessoa, que está interagindo com o sistema, essa pessoa possui preferências e outros atributos que podem servir como fonte de dados para o SR.

Em SR, um **item** é um objeto qualquer com o qual o usuário já interagiu ou com o qual poderá interagir. Por exemplo, um item pode ser um livro ou uma roupa comprados pelo usuário em um *e-commerce*, uma atividade feita em um curso ou uma música escutada.

Para se distinguir um item do outro, esses itens normalmente são descritos por seus próprios atributos/características, o que os diferenciam uns dos outros. No caso de um item comprado em *e-commerce*, este item poderia ter, por exemplo, atributos como a categoria na qual ele está presente como “livros” ou “sapatos”, por exemplo. No caso do item ser uma música escutada, esse item poderia ter atributos como “álbum”, “banda” e “estilo”, por exemplo.

O conceito de **transação**, por vezes chamado de interação, é definido como alguma ação feita pelo usuário com relação a algum item. Seguindo os exemplos citados anteriormente, possíveis transações/interações seriam a compra de um item na loja e possivelmente uma posterior avaliação deste item comprado.

Assim, para representar de uma maneira mais formal (Equação 1) o conceito de sistemas de recomendação, a definição de ADOMAVICIUS; TUZHILIN (2005) diz: considere U o conjunto de todos os usuários e I o conjunto de todos os itens que podem ser recomendados. Da mesma forma, considere a função de utilidade f , que mede o quão útil um item i é para um usuário u , ou seja, $f : U \times I \rightarrow R$, onde R é um conjunto ordenado. Assim, para cada usuário $u \in U$, se deseja encontrar o item $i \in I$ que maximiza o função de utilidade para o usuário.

$$\forall u \in U, i'_u = \max_{i \in I} f(u, i) \quad (1)$$

Uma métrica bastante utilizada para a função de utilidade é a similaridade dos cossenos, a qual mede a similaridade entre dois itens considerando vetores não-zeros. Essa métrica é representada formalmente na Equação 2.

$$\cos(\mathbf{A}, \mathbf{B}) = \frac{\mathbf{A} \cdot \mathbf{B}}{\|\mathbf{A}\| \|\mathbf{B}\|} = \frac{\sum_{i=1}^n \mathbf{A}_i \mathbf{B}_i}{\sqrt{\sum_{i=1}^n \mathbf{A}_i^2} \sqrt{\sum_{i=1}^n \mathbf{B}_i^2}} \quad (2)$$

onde \mathbf{A} e \mathbf{B} são vetores contendo as informações de cada item.

A partir do resultado do cálculo da similaridade entre os itens, é possível encontrar quais são os itens mais similares a um determinado item. Para isso, pode ser usada a técnica dos vizinhos mais próximos, conhecida como KNN (do inglês, acrônimo de *K Nearest Neighbors*). Através do algoritmo KNN seleciona-se, como o próprio nome sugere, os K itens mais similares.

Conforme foi mencionado anteriormente, os SRs podem se utilizar de informações de itens com os quais o usuário interagiu ou então de informações de outros usuários que possuem preferências semelhantes a ele. Dessa forma os SRs podem ser divididos, basicamente, em duas categorias: SR de filtragem baseada em conteúdo (FBC) e SR de filtragem colaborativa (FC), os quais serão explicados nas Seções a seguir.

2.3.1 Filtragem Baseada em Conteúdo

A filtragem baseada em conteúdo mostra um item ainda não visto pelo usuário com base em suas preferências, ou seja, baseado em itens semelhantes que o usuário já teve algum contato. A Figura 1 mostra um exemplo de aplicação da filtragem baseada em conteúdo aplicado na loja da Amazon. Normalmente os sites mostram os itens relacionados a itens que uma pessoa já interagiu em seções como “Relacionado aos itens visualizados” ou “Sugerido para você”, conforme pode ser visto na Figura 1.

Na FBC são exploradas as características próprias do conteúdo como, por exemplo, sua categoria e/ou descrição entre muitos outros atributos possíveis. Quando se utiliza de uma característica textual, por exemplo, é bastante utilizada para recuperação de informação uma medida estatística conhecida como TF-IDF (do inglês, *term frequency-inverse document frequency*).

Com esta métrica é possível identificar o quão importante uma palavra é para um documento considerando um conjunto de documentos. Sendo N o número total de documentos, d um documento e t um termo, formalmente, a medida TF-IDF pode ser representada na Equação 3.



Figura 1 – Exemplo de itens recomendados na Amazon com base na filtragem baseada em conteúdo.

$$\text{tf-idf}_{t,d,N} = \text{tf}_{t,d} \times \log\left(\frac{N}{df_t}\right) \quad (3)$$

onde $\text{tf}_{t,d}$ uma função que calcula a frequência que t aparece em d e df_t uma função que retorna em quantos documentos o termo t é encontrado.

Após a informação ser extraída, aplica-se alguma métrica para calcular a similaridade entre os itens. Uma métrica normalmente utilizada é a similaridade dos cossenos, mencionada anteriormente. A partir de então é possível construir uma matriz que contém a similaridade dos itens entre si.

2.3.2 Filtragem Colaborativa

A filtragem colaborativa mostra um item ainda não visto pelo usuário com base em preferências de usuários que tenham gosto/preferência parecido com o seu. A Figura 2 mostra um exemplo de aplicação da filtragem colaborativa na loja da Amazon. Normalmente estas seções são encontradas dentro de um item que está sendo visualizado e tem como título “Pessoas que compraram este item também compraram”, conforme ilustrado na Figura 2.

A Figura 3 foi adaptada de KUMAR CHATURVEDI; PELEJA; FREIRE (2017) para ilustrar as diferenças entre os dois tipos de filtragem utilizados em SR.

Como pode ser visto, a filtragem colaborativa identifica usuários com alguma similaridade – nesse caso um artigo lido por ambos os usuários, azul e lilás, e talvez mais algum atributo que possuam em comum, como faixa-etária, por exemplo – e recomenda, para o usuário de cor azul, um artigo que ele ainda não leu e que foi lido



Figura 2 – Exemplo de itens recomendados na Amazon com base na filtragem colaborativa.

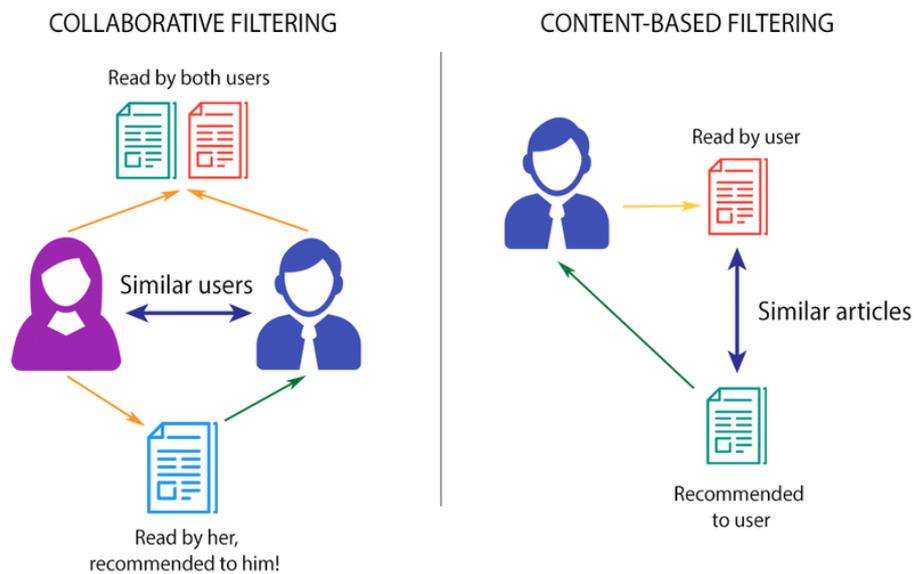


Figura 3 – Comparação entre filtragem colaborativa e filtragem baseada em conteúdo.

pelo usuário de cor lilás que tem preferências parecidas com as suas.

No lado direito da Figura 3, onde se encontra a filtragem baseada em conteúdo, pode ser visto que é recomendado para o usuário um artigo ainda não lido que possui alguma similaridade com algum artigo já lido pelo usuário.

Existem duas maneiras de abordar a FC: abordagem **item-item** e abordagem **usuário-usuário**. Ambas possuem a mesma finalidade, que é dizer quais os itens mais recomendados de acordo com usuários semelhantes, mas são diferentes no modo em que são abordadas.

De acordo com PRIMO (2013), a FC baseada em itens (item-item) busca prever se um determinado usuário irá gostar de um item baseado no histórico de interações dos usuários. Em outras palavras, é traçada a similaridade entre itens com base em interações de diferentes usuários.

Para calcular a similaridade entre dois itens baseados nas interações dos usuários

com esses itens, pode se utilizar também da métrica de similaridade dos cossenos e, com isso, é possível obter uma matriz que traz a informação de quão similar um item é a outro, baseado nos usuários que interagiram com esses itens. Em outras palavras, dessa maneira é possível obter a informação de “usuários que interagiram com esse item também interagiram com estes outros itens”.

Já a FC baseada em usuários (usuário-usuário), conforme descreve PRIMO (2013), busca-se a similaridade entre usuários com base nos itens consumidos. Nessa abordagem, o algoritmo tenta prever a interação de um determinado usuário com um determinado item baseado nas interações de outros usuários que possuem interações semelhantes e que também interagiram com o item em questão.

Por isso, além das duas abordagens apresentadas até aqui, existem aplicações que se utilizam de uma filtragem híbrida. A filtragem híbrida busca utilizar as melhores características tanto da abordagem baseada em conteúdo quando da abordagem colaborativa com o objetivo de minimizar, assim, os pontos fracos de cada uma delas.

2.3.3 Métodos de Hibridização

Utilizar de uma filtragem híbrida, ou seja, utilizar algum método de hibridização, significa a combinação dos resultados para reduzir os problemas encontrados nos diferentes métodos, conforme mencionado anteriormente. Dessa forma, combinando os resultados de uma FBC com uma FC, pode-se reduzir os problemas inerentes a cada uma dessas técnicas.

Existem diversas maneiras de realizar a combinação dos resultados como, por exemplo, o método balanceado, o método de permuta, o método mesclado, entre outros. Estes métodos serão explicados a seguir, de acordo com as definições de BURKE (2002).

O **método aleatório**, seleciona de forma aleatória N itens (onde N é o número de itens que se deseja recomendar), dentre as opções geradas pelas abordagens de filtragem colaborativa e filtragem baseada em conteúdo. Um problema comumente encontrado neste método, é que não se tem controle sobre o que será recomendado, se serão os melhores itens ou os piores.

O **método balanceado** (do inglês, *weighted*) combina linearmente os resultados obtidos através das outras técnicas de recomendação aplicadas no SR. Embora seja de fácil implementação, algo que é assumido implicitamente com essa técnica é que o valor relativo às diferentes técnicas de recomendação é mais ou menos uniforme, o que nem sempre é verdade como, por exemplo, para a filtragem colaborativa para aqueles itens com um pequeno número de interações.

O **método de permuta** (em inglês, *switching*) utiliza-se de alguns critérios para escolher qual técnica de filtragem utilizar. Ele busca analisar o desempenho de cada técnica empregada no recomendador para cada usuário. Assim, obedecendo aos

critérios, dependendo da avaliação, a técnica de FBC pode ser escolhida, ou então pode ser escolhida a técnica de FC.

O **método do mesclado** (do inglês, *mixed*) não seleciona e nem classifica os itens. Ele une todas as recomendações das diferentes técnicas empregadas e retorna para o usuário. Assim sendo, conforme explica BURKE (2002), o método mesclado é uma alternativa para resolver o problema de partida a frio encontrado na FC, quando não se tem interações de outros usuários com determinado item, pois além das recomendações da FC, traz informações relacionadas ao conteúdo através da FBC. Entretanto, não resolve o problema do novo usuário, ou seja, quando não se tem nenhuma informação de um novo usuário no sistema.

O **método de combinação de características** (em inglês, *feature combination*) tem como objetivo combinar diferentes métodos de filtragem em um único algoritmo. Dessa forma, as características de diferentes técnicas são combinadas de forma a produzir uma única recomendação. Em outras palavras, consiste em tratar a informação de um método colaborativo, por exemplo, simplesmente como uma característica adicional e aplicar técnicas de FBC sobre essas informações.

O **método de cascata** (do inglês, *cascade*) envolve um processo de estágios. Nesse método, uma técnica é aplicada após a outra, e a primeira produz um primeiro ranking de candidatos e a segunda técnica refina as recomendações entre o conjunto de candidatos. O método de cascata permite que o recomendador evite aplicar a segunda técnica, que tem menor prioridade, em itens que já foram classificados pela primeira técnica como não sendo relevantes e que possivelmente nunca serão recomendados. Assim, a segunda etapa foca nos itens para a qual uma descrição adicional é necessária.

No **método de aumento de características** (em inglês, *feature augmentation*), uma técnica de filtragem é aplicada para produzir uma classificação ou avaliação de um item e, então, essa informação é passada para a próxima técnica de filtragem. Embora o método de aumento de características e o método de cascata sequenciem duas técnicas de filtragem, onde a primeira técnica tem influência sobre a segunda, eles são fundamentalmente diferentes.

Enquanto no método de aumento de características as características usadas pela segunda técnica incluem a saída da primeira técnica, o método de cascata não usa nenhuma informação de saída da primeira técnica na segunda técnica para produzir seu ranking e sim os resultados são combinados de forma a priorizar determinada técnica.

O **método de níveis** (do inglês, *meta-level*) também pode combinar duas técnicas de filtragem. Isso é feito utilizando o modelo gerado por uma das técnicas como entrada para outra técnica. A diferença para o método de aumento de características é que, enquanto esse usa o modelo para fornecer características como entrada para a

segunda técnica, o método de níveis passa o modelo em si como entrada.

2.3.4 Problemas em Sistemas de Recomendação

Tanto a abordagem de filtragem baseada em conteúdo quanto a abordagem de filtragem colaborativa tem seus pontos fortes e fracos. A seguir são apresentados mais detalhes sobre os problemas comumente encontrados em SR, conforme as definições trazidas por ADOMAVICIUS; TUZHILIN (2005).

O problema de **partida a frio** ocorre, por exemplo, quando um novo item é inserido no sistema. Nesse caso, nenhum usuário interagiu com esse item o que dificulta fazer inferências sobre ele. Ele ocorre na FC, pela falta ou pouca quantidade de interações dos usuários com o item em específico. Entretanto, esse problema não ocorre na FBC, pois esta leva em consideração características do próprio item.

No problema de **análise limitada de conteúdo**, as técnicas de FBC são limitadas pelas características que estão associadas aos itens. Assim, quando não existe informação relacionada a um item, é difícil de inferir a quais itens ele é similar. Outro problema é que se dois itens possuem as mesmas características eles acabam se tornando indistinguíveis.

O mesmo pode ocorrer quando existem itens no sistema os quais possuem características/atributos que não tem relação com outros itens. No contexto de *e-commerce*, se existe apenas um exemplar de um livro e um exemplar de um eletrodoméstico, por exemplo, não é possível dizer que o usuário que comprou o livro pode vir a ter interesse em eletrodomésticos.

O problema de **esparsidade** pode ser encontrado, por exemplo, quando os usuários possuem preferências e atributos bastante distintos. Um usuário compra apenas livros, outro apenas celulares, ainda, outro apenas eletrodomésticos, por exemplo. Isso faz com que não se possa relacionar os usuários e fazer inferências para determinado usuário com base em outros, já que não existem outros usuários similares.

Outro problema é que, quando se tem muitos itens possíveis de serem recomendados, existirão poucos usuários que possuem o mesmo gosto, pois as interações podem estar muito espalhadas por esses itens, não sendo possível traçar similaridade entre os usuários.

O problema do **novo usuário** ocorre, como o próprio nome diz, quando um novo usuário é inserido no sistema. Assim que é inserido, não existe nenhuma interação com nenhum item e, dessa forma, não se consegue recomendar nenhum item com base em itens com os quais já se interagiu (pois ainda não se interagiu com nenhum item). Ainda, nem se consegue achar usuários similares, pois não se tem itens com os quais interagiu, logo não se consegue traçar essa similaridade com usuários que interagiram com os mesmos itens. Como explicado, esse problema ocorre tanto na FC quanto na FBC, pois não se têm dados o suficiente para fazer qualquer tipo de

inferência.

O problema da **superespecialização** pode ser encontrado nos métodos de FBC e ele está relacionado à falta de novidade nos itens que são recomendados a um determinado usuário, ou seja, recomenda sempre o mesmo tipo de informação por causa do histórico de interações do usuário. Dessa forma, se um usuário interage sempre com itens de mesma característica como, por exemplo, assiste sempre filmes de ação, o sistema dificilmente irá indicar uma comédia, mesmo que ele possa vir a adquirir ou tenha também um gosto por comédia.

Para conseguir lidar com esses tipos problemas característicos a uma ou outra técnica de filtragem, as recomendações de ambas as técnicas (FBC e FC) podem ser combinadas de maneira a extrair as melhores recomendações de ambas, conforme dito anteriormente. Essa técnica é chamada de hibridização, ou então filtragem híbrida. Assim busca-se unir as diferentes técnicas para formar uma recomendação.

2.3.5 Avaliação de Sistemas de Recomendação

A avaliação dos SRs é uma das etapas mais importantes para saber se as recomendações que estão sendo dadas fazem sentido para os usuários. Entretanto, essa não é uma tarefa fácil de ser feita, pois existem diversas maneiras de se avaliar um SR. Segundo GUNAWARDANA; SHANI (2015), os métodos de avaliação de um SR podem ser divididos em três categorias: experimentos offline, estudos com usuários e o uso real do sistema pelos usuários finais, também conhecido como experimentos online (PRIMO, 2013).

A avaliação é feita usualmente na ordem já mencionada onde, a cada etapa, tem-se um custo e complexidade maior de realização. Primeiramente, são aplicados os experimentos offline, usando conjuntos de dados existentes para medir a performance do SR, permitindo descartar as abordagens inapropriadas. Depois, são aplicados estudos com um pequeno conjunto de usuários que são instruídos a realizar determinadas tarefas, o que normalmente envolve algum custo para realização. Por fim, são aplicados testes online, ou seja, em ambiente real, para avaliar a performance das recomendações em um cenário com usuários reais (GUNAWARDANA; SHANI, 2015).

2.3.5.1 Experimentos Offline

Os experimentos offline consistem em avaliar a capacidade de predição das escolhas dos usuários de um SR, em algum domínio em específico, de forma objetiva. Para a realização de tal tarefa são utilizados conjuntos de dados pré-coletados, os quais contém as interações dos usuários. Assim, é possível simular o comportamento dos usuários e avaliar, através de uma ou várias medidas objetivas (por exemplo, como acurácia), o quão próxima a predição do SR foi do comportamento real esperado.

Entretanto, avaliar somente a acurácia das predições, embora crucial, não é o su-

ficiente para um bom SR. Existem diversas considerações a serem feitas além da correta antecipação do gosto do usuário: é necessário levar em consideração questões relacionadas à experiência do usuário (em inglês, *user experience*) e à interface do usuário (em inglês, *user interface*) (BORBA; GASPARINI, 2019). Por isso, a aplicação dos outros dois tipos de avaliação se torna importante.

O principal objetivo da realização dos experimentos offline é filtrar abordagens inapropriadas, deixando um conjunto pequeno de algoritmos a serem testados com estudos com usuários e/ou testes online. Um exemplo desse processo de experimento offline é o ajuste de determinados parâmetros para melhorar a saída do SR e, assim, a melhor combinação de parâmetros é a que continua para as próximas etapas.

2.3.5.2 *Estudos com Usuários*

A realização de experimentos com usuários tem como objetivo a realização de interações desses usuários com o SR. Enquanto as tarefas são feitas, o comportamento do usuário é observado e gravado, coletando todo o tipo de medidas quantitativas como, por exemplo, se o usuário clicou na recomendação, o tempo que o usuário levou para realizar a tarefa, entre outros. Nessa etapa, também é possível testar o comportamento com e sem o uso do SR. E por fim, podem ser feitas perguntas diretamente para o usuário, questionando se a recomendação foi relevante, por exemplo.

Entretanto, mesmo os estudos com usuários podem continuar sendo uma simulação da realidade. Como a quantidade de usuários normalmente é pequena, eles podem não representar o uso do sistema num ambiente real. Por isso, são feitos também os experimentos online, ou seja, em ambiente real.

2.3.5.3 *Experimentos Online*

A avaliação de algoritmos e SR em um cenário real pode ser considerada a alternativa mais eficiente para identificar o quanto o SR beneficia os seus usuários. Para fazer essa avaliação, normalmente são realizados os testes conhecidos como Teste A/B, onde um percentual de usuários é selecionado para utilizar uma variação do SR e outro percentual de usuários é direcionado para outra variação do SR. Assim é possível medir e comparar o desempenho de cada uma das versões do SR para saber qual melhor atinge o seu objetivo.

O efeito que o uso de um SR terá depende de uma série de fatores como, a intenção do usuário, o contexto do usuário e a interface através da qual a recomendação é apresentada. Assim, esse é o tipo de experimento que traz a evidência mais forte do valor real do SR.

Entretanto, é preciso ter cuidado ao se utilizar desse tipo de experimento, pois, por acontecer em ambiente de produção com usuários reais, caso uma recomendação seja irrelevante o experimento pode ter um efeito negativo. Por esse motivo, esta

etapa deve ser executada após a realização de estudos offline que indiquem quais as melhores abordagens, as que provavelmente terão uma melhor aplicação num cenário real.

2.4 Sistemas de Recomendação na Educação

Da mesma forma como SRs vêm sendo usados nas mais diversas áreas, a aplicação deles também pode ser encontrada na área da educação. Não só para fins de venda, como são utilizados em algumas plataformas de cursos online – o que acaba por igualar a sites de *e-commerce*, os SRs também podem ser utilizados para auxiliar o aluno no aprendizado. Essa Seção tem como objetivo exemplificar possíveis aplicações dos SRs na área da educação.

Um dos problemas da aplicação de SRs na educação é a avaliação de sua efetividade, e como medir se a recomendação realmente ajudou o aluno a aprender ou se foi algum outro conteúdo que acabou levando ele ao aprendizado do assunto em específico. Além disso, como saber se a recomendação realmente ajudou e não atrapalhou no aprendizado do aluno? O aluno realmente precisava ver aquele recurso naquele momento? Essas são questões que tornam o uso de SRs na educação um pouco mais difíceis do que em algumas outras áreas.

Um SR pode ser usado na educação tanto para a parte de ensino como para a parte de aprendizado, ou seja, ele pode ser usado para recomendar conteúdos para o professor a se trabalhar com os alunos, melhorando assim o ensino, bem como pode recomendar conteúdos para os alunos, ajudando-os na aprendizagem.

Como apresentado na Seção 2.3, para ser efetiva a utilização de SR precisa ter um objetivo definido. No contexto da educação, o objetivo poderia ser a melhoria do desempenho dos alunos nas avaliações. Então, com base nesse objetivo é possível construir uma aplicação que cumpra com sua função de fazer com que as notas dos alunos nas avaliações finais sejam melhores. Para isso, pode ser recomendada uma sequência de atividades especificadas de acordo com a necessidade de cada aluno baseando-se, por exemplo, no grau de dificuldade.

Pensando em um SR que se utiliza de filtragem baseada em conteúdo, a recomendação poderia ser um determinado exercício baseado nas atividades que o aluno mais tem dificuldade. Já no contexto de filtragem colaborativa, por exemplo, poderia ser recomendada uma leitura que tenha ajudado algum outro aluno a melhorar o desempenho.

Um item, no contexto de SR da educação, pode ser um *objeto de aprendizagem*, ou seja, um exercício, um vídeo ou uma outra atividade qualquer, ou então caminhos de aprendizado completo, por exemplo.

O usuário no contexto de recomendação pode ser o próprio aluno, que recebe uma

recomendação de atividade, e/ou então o professor ou entidade que oferece o curso, o qual pode receber como recomendação alguma parte do curso em que os alunos estão tendo maiores dificuldades, por exemplo. Uma transação/interação no contexto de SR na educação pode ser o aluno concluir um exercício, ler um texto, entre outros.

2.5 Trabalhos Relacionados

Foi realizada uma revisão sistemática da literatura (RSL) com o objetivo de identificar os trabalhos que vêm sendo desenvolvidos na área de aprendizado não-formal utilizando-se SR.

Para a definição da metodologia a ser empregada, foi utilizado como base para elaboração as definições trazidos por LOUREIRO (2018). Dessa forma, são definidos os passos para a realização da revisão sistemática, bem como as fontes de busca dos artigos e os critérios de seleção.

2.5.1 Metodologia

A realização desta RSL se deu seguindo as diretrizes de KITCHENHAM et al. (2009) por estas ajudarem na identificação e análise de estudos para identificar o estado da arte.

Definição da questão de pesquisa: A questão de pesquisa dessa RSL é “Como os sistemas de recomendação vêm sendo aplicados na área de ensino não formal?”, e como questão secundária, “Quais as ferramentas e técnicas que estão sendo utilizadas?”.

Busca: A primeira etapa consiste na definição das palavras-chave para a realização da busca e a definição das bases nas quais serão buscados os trabalhos da área de SR na educação. Uma das bases de artigos utilizadas foi a IEEE (do inglês, *Institute of Electrical and Electronics Engineers*)³. Outra base de artigos utilizada foi a base da Elsevier, concentrando-se na revista *Computers & Education*, a qual possui publicações na área de SR voltada para a educação. Além dessas bases, utilizou-se também a base de dados de ACM (do inglês, *Association for Computing Machinery*)⁴ e também do Portal de Publicações da Comissão Especial de Informática na Educação (CEIE)⁵. Essas bases foram utilizadas por estarem relacionadas a área deste trabalho.

As palavras-chave utilizadas para a realização da pesquisa foram *recommendation systems*, *recommender systems* e *education*. A busca realizada consistiu na seguinte expressão: (“recommender systems” OR “recommender system” OR

³<https://ieeexplore.ieee.org>

⁴<https://dl.acm.org/>

⁵<http://www.br-ie.org>

“*recommendation systems*” OR “*recommendation system*”) AND (*education*)).

Nessa busca, optou-se por não se utilizar da expressão *non-formal*, pois ela poderia fazer com que resultados que não se utilizem diretamente dessa expressão, mas que fazem parte do aprendizado não-formal, não fossem encontrados.

Cr terios de inclus o e exclus o: Foram considerados como cr terios de inclus o aqueles artigos que definissem o uso de sistemas de recomenda o em sistemas de ensino/aprendizado n o formal. Os cr terios de exclus o foram: (i) os artigos que mencionavam a aplica o de SR para o ensino formal (universidades, escolas regulares); (ii) trabalhos que n o continham as express es de busca no t tulo, no resumo ou nas palavras-chave; (iii) os trabalhos que consistiam em revis es da  rea; (iv) os trabalhos relacionados a outras  rea que n o   da educa o; e, (v) trabalhos que n o tratavam da  rea de SR.

Extra o dos Dados: Nessa RSL, buscou-se identificar algumas caracter sticas dos SR. Buscou-se caracterizar quem   o destinat rio da recomenda o. Em outras palavras, observar se quem vai receber a recomenda o   o aluno ou o professor.

Al m disso, analisou-se qual foi a t cnica de filtragem utilizada, ou seja, se utilizou a FBC, a FC ou alguma outra t cnica. Outra caracter stica analisada foi a plataforma utilizada: Web, Mobile ou alguma outra. Tamb m se averiguou se foram utilizadas ontologias para a representa o do conhecimento da base de dados.

Foi analisado tamb m em que consistia o item que estava sendo recomendado como, por exemplo, um OA, um curso ou algum outro tipo de item. Al m disso foi analisada a etapa em que se encontrava o projeto na publica o dos trabalhos, ou seja, se estava em fase de projeto, de simula o com algum conjunto de dados ou se o mesmo j  havia sido implementado/testado com usu rio reais.

2.5.2 Condu o da revis o

A revis o foi conduzida de forma manual, fazendo-se a leitura de t tulo, resumo e palavras-chave, para posteriormente realizar a leitura completa dos artigos. Assim, a execu o da RSL constituiu-se basicamente de quatro passos.

Passo 1: Busca. Nessa etapa   executada a busca propriamente dita, fazendo uso da express o de busca e das bases previamente mencionadas.

Passo 2: Filtrar resultados pelas express es de busca. O primeiro filtro aplicado aos resultados obtidos com a aplica o do Passo 1 consiste na remo o dos artigos que n o continham em seu t tulo, resumo ou palavras-chave as express es utilizadas na busca pelos artigos, o qual   dos cr terios de exclus o estabelecidos no planejamento. Dadas as express es de busca “*recommender system*”, bem como suas

variações, e “education”, foram removidos os artigos que não possuíam essas expressões em seus título, resumo ou palavras-chave. Isso permite chegar aos artigos que tenham maior chance de tratar do assunto de aplicação de SR na educação. É importante observar que não necessariamente os artigos resultantes da aplicação desta etapa serão focados especificamente no aprendizado/ensino não-formal.

Passo 3: Leitura dos resumos. Realizada a primeira filtragem nos resultados no Passo 2, o terceiro passo consiste na leitura dos resumos dos artigos resultantes da aplicação da etapa anterior. Essa leitura visa identificar todos os artigos que não sejam da área da educação, uma vez que podem existir artigos que mencionem as expressões de busca mas apenas de forma genérica, sem necessariamente ter uma ligação com a aplicação de SR na área da educação.

Além disso, essa etapa permite identificar alguns dos artigos que são aplicados no ensino/aprendizado informal ou no ensino/aprendizado formal. Como o foco é em ensino/aprendizado não-formal essa etapa auxilia na identificação de artigos que possuam ligação com esta área de aplicação de SR.

Passo 4: Leitura completa dos artigos. Com base na aplicação do Passo 3, os artigos que foram identificados como os mais promissores com relação a área de SR no ensino não-formal foram lidos por completo e analisados para ver seu enquadramento no tema deste trabalho.

Os artigos resultantes da aplicação dessas quatro etapas e que realmente fazem parte do escopo do tema deste trabalho foram então dispostos em uma Tabela para que se possa visualizar o estado da arte dos SRs aplicados no ensino não-formal.

2.5.3 Resultados

Como resultado da aplicação do Passo 1 da condução da revisão – etapa de busca, foram obtidos um total de 1002 artigos compreendendo todas as bases mencionadas anteriormente.

Com a aplicação do Passo 2 – filtragem por artigos que possuíam as expressões de busca no título, resumo ou palavras chave, do total de 1002 artigos encontrados na etapa anterior, 306 se enquadraram nos parâmetros da filtragem, ou seja, 306 artigos provavelmente falam da aplicação de SR na educação.

Na sequência, no Passo 3, a partir dos 306 artigos resultantes do Passo 2, foi feita a leitura dos resumos dos trabalhos. Com isso, houve uma redução para 100 artigos que já estão com uma maior probabilidade de estarem relacionados a área de ensino/aprendizado não-formal.

Com a leitura dos resumos dos trabalhos, restaram 100 artigos, conforme mencionado anteriormente. Esses 100 artigos foram lidos completamente. A partir dessa

leitura completa identificaram-se 46 artigos que estão relacionados à aplicação de SR no ensino não-formal.

Dessa forma, após a leitura dos artigos e a análise dos dados extraídos, mencionados no planejamento da revisão, foi elaborada a Tabela 1 com o objetivo de mostrar comparativamente os resultados finais dessa revisão sistemática da literatura.

Tabela 1 – Quadro comparativo dos trabalhos selecionados na revisão sistemática.

Trabalho	Dest.	Filtragem	Plat.	Recom.	Fase	Onto.
(ANSARI et al., 2016)	Sistema ¹ , Aluno	FBC, FC	Web	Melhorias ¹ , Amigos, Exercícios, Cursos, Livros	Implement.	ND
(AVILA; GATTO; ZORZO, 2010)	Aluno	FBC	TV	Programas de TV	Implement.	ND
(BANNO; YANG, 2016)	Aluno	Contex.	Mobile	OA	Proj.	ND
(BHATTACHARYA et al., 2018)	Aluno	FBC, FC	Web	Curso	Simul.	ND
(CAI; ZHANG; DAI, 2019)	Professor	ND	ND	Recursos	Proj.	ND
(CAO et al., 2018)	Aluno	Híbrida	Web	Recurso	Implement.	ND
(CHAVARRIAGA; FLORIAN-GAVIRIA; P., 2014)	Aluno	FC, Conhec.	Web	Recursos	Implem.	Não
(CHENG; ZHANG; SHI, 2018)	Aluno	Conhec.	ND	LP	Implement.	Sim
(DANG, 2018)	Aluno ¹ , Professor	AS	Web	Conteúdos ¹ , Perfis	Proj.	ND
(DURÁN; ÁLVAREZ, 2017)	Aluno	FBC, Contex.	Mobile	Profissional	Simul.	Sim
(EPSTEIN et al., 2013)	Aluno	ND	Web	Conteúdo	Proj.	ND
(FU et al., 2015)	Aluno	FBC, FC	ND	Curso	Proj.	ND
(GEDDAWY et al., 2019)	Aluno	<i>Deep Learning</i>	ND	LP	Simul.	ND
(GOGO; NDERU; MWANGI, 2018)	Alunos	Fuzzy	ND	Conteúdos	Sim.	ND
(HASSAN; HAMADA, 2017)	Aluno	FBC	Mobile	OA	Proj.	ND
(HOIC-BOZIC; DLAB; MORNAR, 2016)	Aluno	FBC, FC	Web	Colaborador, Ferramenta	Proj.	ND
(JAIN; ANIKA, 2018)	Aluno	Min. Dados	ND	Cursos	Simul.	ND
(KARGA; SATRATZEMI, 2014)	Professor	FBC, FC	Web	Templates	Proj.	ND
(LI; MEI; WANG, 2012)	Aluno	AS	ND	Conteúdos	Implement.	Sim
(LI; LI, 2017)	Aluno	FC	Web	Curso	Proj.	ND
(LI; SUN, 2018)	Aluno, Professor	FBC	ND	Conteúdo	Simul.	ND
(LIANG; CHEN, 2014)	Aluno	FBC, FC	ND	Video	Simul.	ND
(LIN; CHEN, 2020)	Aluno	<i>Deep Learning</i>	Mobile	LP	Implement.	ND
(LI et al., 2017)	Aluno	FBC, FC	ND	Recursos	Simul.	ND
(NETO; SALES, 2015)	Aluno	FBC, FC, Contex.	Mobile	Conteúdo	Simul.	ND
(MONDAL et al., 2020)	Aluno	Híbrida	ND	Curso	Simul.	ND
(MONTUSCHI et al., 2015)	Aluno	ND	Web	Curso	Simul.	ND
(NADEEM; STANSBURY; MOONEY, 2018)	Aluno	FC, FBC	ND	Recurso	Simul.	ND
(OUALI; OUMAIRA, 2020)	Aluno	ND	ND	LP	Proj.	ND
(PARYUDI; C.N, 2011)	Aluno	FBC	Web	Recursos	Proj.	Sim
(POTTS et al., 2018)	Aluno	ND	Web	Aluno	Simul.	ND
(PRISCO et al., 2017)	Aluno	ND	Web	OA	Implement.	ND
(PRISCO et al., 2019)	Aluno	ND	Web	Recurso	Proj.	ND
(QIAO; GUO; ZHAO, 2018)	ND	FC	ND	Video	Simul.	ND
(QOMARIYAH; FAJAR, 2019)	Alunos	Regras	ND	Conteúdos	Proj.	Sim
(RAHMA; KOUTHEAIR, 2019)	Aluno	FBC	Web	Conteúdo	Implement.	ND
(SAITO; WATANOBE, 2018)	Aluno	<i>Deep Learning</i>	Web	LP	Simul.	ND
(SAMMOUR et al., 2015)	Aluno	ND	Web	Curso	Proj.	Sim
(SHI et al., 2018)	Alunos	FC, Conhec.	ND	Cursos	Implement.	ND
(STRICKROTH; PINKWART, 2012)	Aluno	Híbrida	Web	Conteúdo	Implement.	ND
(TORRE; TORSANI, 2016)	Professor	FBC	Web	Ferramentas, Ações	Implement.	Sim
(WAI, 2016)	Aluno	FC	Web	Curso	Implement.	ND
(ZHANG et al., 2014)	Aluno	Híbrida	Web	Recurso	Simul.	Sim
(ZHANG; LIU; WANG, 2020)	Aluno	<i>Deep Learning</i>	ND	Recurso	Simul.	ND
(ZHAO et al., 2018)	Aluno	FBC	Web	Video	Implement.	ND
(ZIQI et al., 2015)	ND	Híbrida	ND	Recurso	Simul.	ND

Na Tabela 1 onde se lê ND, entende-se como Não Definido. A coluna que mais

apresenta dados ND é a coluna que define o uso de ontologias. Além disso, LP leia-se *Learning Path* ou caminho de aprendizado.

Como pode ser observado na Tabela 1, a maioria dos trabalhos foca em recomendar algo para os alunos. Mas os trabalhos de KARGA; SATRATZEMI (2014), de TORRE; TORSANI (2016), de DANG (2018), de LI; SUN (2018) e de CAI; ZHANG; DAI (2019) também fazem recomendações para os professores.

Em sua maioria, as plataformas de aplicação dos sistemas de recomendação são utilizadas na Web, com alguns casos aplicados a dispositivos móveis, os quais falam do uso do contexto para se fazer a recomendação.

Na Tabela 1, quando se fala de recomendação de vídeos, recursos e conteúdos, pode-se considerar essas recomendações como objetos de aprendizagem, embora alguns dos trabalhos não utilizem este conceito.

Na Tabela 1 onde se lê ND, entende-se como Não Definido. A coluna que mais apresenta dados ND é a coluna que define o uso de ontologias. Além disso, LP leia-se *Learning Path* ou caminho de aprendizado.

Como pode ser observado na Tabela 1, a maioria dos trabalhos foca em recomendar algo para os alunos. Mas os trabalhos de KARGA; SATRATZEMI (2014), de TORRE; TORSANI (2016), de DANG (2018), de LI; SUN (2018) e de CAI; ZHANG; DAI (2019) também fazem recomendações para os professores.

Em sua maioria, as plataformas de aplicação dos sistemas de recomendação são utilizadas na Web, com alguns casos aplicados a dispositivos móveis, os quais falam do uso do contexto para se fazer a recomendação.

Na Tabela 1, quando se fala de recomendação de vídeos, recursos e conteúdos, pode-se considerar essas recomendações como objetos de aprendizagem, embora alguns dos trabalhos não utilizem este conceito.

2.5.4 Discussão

De acordo com o levantamento apresentado na Tabela 1, pode-se identificar que os SRs são focados principalmente na recomendação de itens para alunos/estudantes. Dentre as recomendações apresentadas para os estudantes, destacam-se a recomendação de cursos e OA, bem como colaboradores/pares.

BHATTACHARYA et al. (2018), por exemplo, recomenda cursos para que empregados possam melhorar suas habilidades no meio corporativo. Através dos pontos em que falta conhecimento para o empregado, é feita a recomendação de cursos que ele poderia fazer para avançar em sua carreira com base em informações de seu perfil. Para tal, é utilizada uma técnica chamada de Árvores de Predição Compactas, a qual é treinada se utilizando das informações de outros usuários no passado. Mais precisamente, é recomendada uma sequência de cursos para que o empregado possa atingir o nível de conhecimento em cada habilidade. Para avaliação desta técnica foi

gerado um conjunto de dados de teste, simulando um cenário do mundo real.

Um trabalho similar, que se utiliza da recomendação de sequências é realizado por ZHAO et al. (2018). Ao invés de indicar cursos, como feito no trabalho anterior, neste trabalho são recomendados vídeos, que podem ser considerados OA. Neste trabalho, os autores coletam informações dos cursos aos quais os vídeos pertencem, e fazem uma ligação entre os vídeos. Assim, com base no vídeo que está sendo assistido, são recomendados outros vídeos com conteúdo similar, fazendo também uma reordenação das recomendações com base nas sequências identificadas entre os vídeos. Para validar as técnicas utilizadas o sistema foi testado com um grupo de usuários reais.

Ainda em recomendação de sequências, nota-se que os recomendadores começam a aplicar técnicas de aprendizado profundo (do inglês, *Deep Learning*), utilizando-se de RNN (do inglês, *Recurrent Neural Networks*) de forma a gerar um grafo direcionado que prevê uma sequência temporal de ações ou, no contexto de SRs, a sequência de itens que serão consumidos em cada momento. Exemplos de trabalhos que utilizam-se desse tipo de técnica são os trabalhos desenvolvidos por SAITO; WATANOBE (2018), ZHANG; LIU; WANG (2020), LIN; CHEN (2020) e GEDDAWY et al. (2019). Esse último fala ainda da possibilidade de uso de informações de contexto, incluindo informações de redes sociais para a aproximação de professores para que esses possam colaborar entre si.

Pode-se identificar também, através dos artigos lidos, a aplicação de SR em cenários de aplicações para dispositivos móveis. Tais trabalhos, como os realizados por NETO; SALES (2015), BANNO; YANG (2016) e DURÁN; ÁLVAREZ (2017) se utilizam de informações de contexto para fazer uma recomendação. No caso de DURÁN; ÁLVAREZ (2017), um professor especialista no assunto é recomendado e é informada a distância que se está deste professor. Já BANNO; YANG (2016) utiliza a informação da localização (se está em casa ou na escola) do usuário para fazer a recomendação de um item.

Outras categorias de filtragem apresentadas nos trabalhos avaliados são a filtragem baseada em conhecimento, a qual é encontrada em CHAVARRIAGA; FLORIAN-GAVIRIA; P. (2014) e CHENG; ZHANG; SHI (2018) e a análise semântica, a qual pode ser encontrada em DANG (2018) e LI; MEI; WANG (2012). Já (QOMARIYAH; FAJAR, 2019) faz recomendações de conteúdos para alunos baseadas em regras lógicas. GOGO; NDERU; MWANGI (2018) por outro lado, faz uso de lógica fuzzy para gerar recomendações de conteúdos para os alunos. Para tal, ele faz uso também de informações contextuais como o tempo que o aluno demora para fazer um teste inicial e o *score* obtido para nesse teste.

Trabalhos como os de SAMMOUR et al. (2015), TORRE; TORSANI (2016), PARYUDI; C.N (2011), DURÁN; ÁLVAREZ (2017), LI; MEI; WANG (2012), QOMA-

RIYAH; FAJAR (2019) e CHENG; ZHANG; SHI (2018) fazem o uso de ontologias para a representação dos dados do SR. O uso das ontologias nesses trabalhos permite a inserção de semântica às informações e também a realização de inferências a partir destas informações. TORRE; TORSANI (2016), por exemplo, faz uma FBC com o uso de ontologias para recomendar ao professor ferramentas e atividades que ele possa utilizar com seus alunos baseado em diferentes cenários, compostos por diferentes objetivos de aprendizado e restrições.

Os trabalhos realizados por ZHANG et al. (2014), STRICKROTH; PINKWART (2012), GOTARDO et al. (2013), ZIQI et al. (2015) e SUN et al. (2018) tem como objetivo resolver os problemas de esparsidade e de *cold start* para SRs aplicados na área de educação. Os trabalhos não estão necessariamente focados em definir a recomendação de algum recurso, e sim resolver esses problemas para conseguir recomendar algo quando se tem um novo recurso ou usuário no sistema.

A proposta de ZHANG et al. (2014) busca resolver o problema de *cold start* e esparsidade fazendo inferências do perfil do usuário com base nos itens que ele já consumiu e também na realização de inferências baseado na relação entre os itens. Dessa forma, utilizando-se de uma abordagem híbrida balanceada, consegue aproveitar características de ambas as abordagens utilizadas.

ZIQI et al. (2015) utiliza-se também de uma filtragem híbrida. Entretanto, a abordagem inicia com a aplicação de métodos clusterização para classificação dos dados. Com base no resultado dessa clusterização e na condensação dos dados de interação dos usuários com os itens de cada cluster é aplicada uma FC baseada em usuário, que gera as recomendações.

Já STRICKROTH; PINKWART (2012), por exemplo, propõe uma solução para aplicação quando se tem poucos dados, em pequenos grupos, utilizando-se para tal de um método híbrido e faz um teste no qual são recomendados recursos para os alunos de uma pequena comunidade em um projeto educacional. Para a resolução do problema de esparsidade este trabalho utiliza-se de uma abordagem híbrida. Para tal, o recomendador, em um primeiro momento, gera avaliações explícitas com base nas avaliações implícitas, ou seja, com base nas visitas dos usuários a determinados conteúdos é gerado uma avaliação que ele possivelmente daria para o item, aumentando a quantidade de interações dos usuários com os itens.

O presente trabalho se diferencia dos demais aqui listados por abordar a informação de contexto dos alunos como uma maneira de dar prioridade àquilo que faz sentido de acordo com as vivências do aluno. Além disso, por se tratar de um *framework*, a premissa é que ele forneça uma gama de possibilidades de aplicação, podendo habilitar e desabilitar etapas conforme cada realidade, pois nem sempre um modelo irá funcionar bem para todos os casos. Assim, dar a possibilidade de escolha de quais algoritmos usar, se torna um fator relevante nesse trabalho.

Para solucionar o problema de esparsidade, o método mais comum é utilizar a FBC, solução utilizada no *framework* proposto. Para solucionar o problema de *cold start*, o *framework* tem como um dos parâmetros um tópico de interesse, o qual irá gerar recomendações através de um FBC baseadas apenas nesse tópico.

3 O FRAMEWORK PROPOSTO

O *framework* proposto tem como propósito utilizar de informações relacionadas ao contexto dos alunos para produzir recomendações de objetos de aprendizado que façam sentido para eles, criando uma relação com o que eles vivem no dia a dia. Dessa forma, quando o professor visualizar as recomendações para determinado aluno, os itens recomendados estarão relacionados ao contexto do aluno. A Figura 4 apresenta esquematicamente as etapas do *framework*.

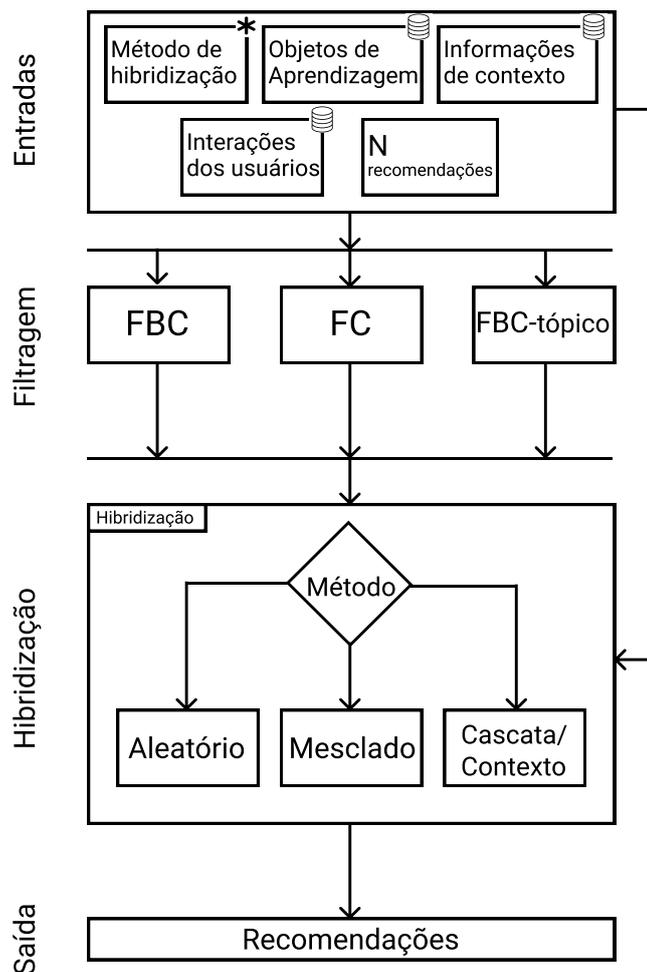


Figura 4 – Estrutura da proposta de framework.

O *framework* é composto por quatro etapas. A primeira etapa é responsável pela entrada do *framework*, mais especificamente pela preparação dos *datasets* e pela parametrização do *framework*. A segunda etapa consiste na aplicação das técnicas de filtragem para gerar as recomendações preliminares: são aplicadas aos dados duas Filtragens Baseadas em Conteúdo (FBC), sendo uma delas em sua aplicação definida na literatura, relacionada aos itens já consumidos pelo usuário e outra relacionada a um tópico de interesse informado pelo professor (FBC-tópico), e a Filtragem Colaborativa (FC). Na terceira etapa encontram-se os algoritmos responsáveis pela hibridização, sendo eles os métodos aleatório, mesclado e cascata, no qual é utilizada a informação de contexto. Por fim, na quarta etapa é onde se encontra a saída do *framework*, ou seja, as recomendações resultantes da execução das etapas anteriores.

A **primeira etapa** do funcionamento do *framework* é a preparação da entrada para a segunda etapa. Nesta etapa definem-se o tópico de interesse que o professor está buscando, a lista de objetos de aprendizado/conteúdo com todas as suas características (categorias, por exemplo), a relação de usuários e suas interações com os objetos de aprendizado. Além disso, é informado o método de hibridização que se deseja adotar. Essa seleção pode vir a ser gerenciada por algum outro algoritmo, podendo se tornar adaptativa a cada caso.

A **segunda etapa** executa as filtragens baseada em conteúdo, colaborativa e a baseada em conteúdo relacionado ao tópico informado. É possível executar todas as filtragens em paralelo, uma vez que elas são independentes. O resultado desta etapa são recomendações de cada um desses algoritmos.

A filtragem baseada em conteúdo recebe como entrada os objetos de aprendizado com suas características e as interações do usuário em questão com esses objetos. No *framework* proposto a característica do objeto de aprendizagem é uma informação em formato de texto (podem ser categorias por exemplo, ou a descrição do exercício), sobre a qual é executado o algoritmo TF-IDF, explicado anteriormente, para a extração de características e é calculada a similaridade, através da métrica de similaridade dos cossenos, entre os conteúdos que um determinado usuário já consumiu e são recomendados os itens com maior similaridade a estes conteúdos.

A filtragem colaborativa recebe os dados relacionados à interação de todos os usuários com os objetos de aprendizado. A partir de então, através da abordagem item-item, calcula as similaridades entre os objetos de aprendizado através da métrica de similaridade dos cossenos, tendo como base as interações de todos os usuários com esses itens.

A filtragem baseada em conteúdo relacionada ao tópico de interesse recebe como entrada os objetos de aprendizado e calcula, através do algoritmo TF-IDF e pela similaridade dos cossenos, os objetos com maior similaridade ao tópico informado e que o usuário em questão ainda não interagiu. Esse tópico de interesse não possui uma

semântica aplicada pelo *framework*, ou seja, o *framework* não dá um significado para essa informação. A semântica é dada pelo professor, que pode fornecer como entrada o tópico da próxima aula ou a dificuldade que o aluno tem, por exemplo.

Esta filtragem é considerada muito relevante no *framework* que está sendo proposto, pois ajuda a lidar com o problema de quando um novo usuário é inserido. Problema este que é encontrado tanto na filtragem baseada em conteúdo quanto na filtragem colaborativa, conforme foi relatado anteriormente. Assim, quando não se tem nenhuma informação de interação de um determinado usuário com nenhum objeto de aprendizagem, a informação de tópico de interesse ajuda a encontrar uma informação relevante.

Para a execução da **terceira etapa**, etapa de hibridização, é passado como entrada o resultado da execução da etapa anterior, ou seja as recomendações dadas por cada uma das filtragens, e as informações de contexto dos alunos. Além disso é informado qual o método de hibridização que se deseja utilizar. Com isso a etapa de hibridização consegue retornar os objetos de aprendizado que mais se assemelham com as características do aluno além de evitar os problemas de partida a frio e esparsidade, explicados anteriormente.

Portanto, esta etapa é responsável por reunir as informações das etapas anteriores e selecionar quais as recomendações que serão retornadas pelo *framework* para o professor. Como visto no referencial teórico, existem diversos métodos de hibridização. Nesse trabalho, foram desenvolvidos inicialmente três métodos: o método aleatório, o método mesclado e o método de cascata.

O método aleatório funciona exatamente como apresentado no referencial teórico. Sendo N a quantidade de recomendações desejadas, o método aleatório seleciona uma quantidade N de objetos de aprendizado no conjunto de todas as recomendações das etapas anteriores de forma aleatória. Já o método mesclado foi um pouco modificado e implementado de forma a selecionar na mesma quantidade os X melhores resultados de cada uma das etapas (sendo, $X = N/3$) para compor a sugestão dos N objetos de aprendizado como saída.

O método de cascata, na implementação deste trabalho, leva em consideração as características de contexto do aluno, no qual está focada a presente proposta de *framework* de recomendação. Nesse método foram aplicadas duas técnicas de filtragem: a FBC e a FC baseada em usuário (usuário-usuário).

A FBC aplicada na etapa de hibridização tem como objetivo identificar e priorizar informações relacionadas ao contexto do aluno que podem estar relacionadas ao objeto de aprendizagem que está sendo recomendado. Assim, por exemplo, considerando que a informação de contexto do aluno são os lugares frequentados, essa técnica busca identificar objetos de aprendizado que tenham alguma relação com esses lugares.

A FC aplicada nessa etapa visa identificar e priorizar itens que tenham relação com usuários que possuam informações de contexto similares. Por exemplo, prioriza itens relacionados a usuários que costumam frequentar os mesmos lugares que o usuário para o qual está sendo gerada uma recomendação.

A partir do resultado da aplicação dessas duas técnicas de filtragem foi feita uma média das similaridades de cada um e os melhores N resultados servem como saída, ou seja aplica-se uma estratégia balanceada de hibridização.

Na **quarta etapa** do *framework* tem-se como resultado final as recomendações de objetos de aprendizado fornecidas pelo *framework* ao professor, após a execução das etapas onde são aplicadas as técnicas de recomendação e as técnicas de hibridização.

É importante ressaltar que o *framework* não reproduz o exercício em si, ou seja, ele não apresenta o exercício em seu formato (vídeo, questão de múltipla escolha ou texto, por exemplo), apenas indica qual o exercício que está sendo recomendado através de um nome ou identificador. Assim, o professor consegue i) identificar qual objeto de aprendizagem que o recomendador está tratando e ii) enviar o conteúdo para o aluno ou mostrar para o mesmo onde encontrar esse conteúdo. Dessa forma, não é de responsabilidade exclusivamente do *framework* proposto questões relacionadas a *User Interface* e *User Experience* para apresentar os exercícios.

Outra característica do *framework* é que sua saída é apresentada aleatoriamente, ou seja, não segue a ordem do item mais similar para o menos similar, ou vice-versa. A aleatorização do resultado é feita para que o professor não escolha sempre o objeto de aprendizagem mais similar as características do aluno, mas experimente também coisas novas. Isso auxilia para evitar uma super-especialização do *framework*, a qual acabaria reforçando sempre a recomendação dos mesmos objetos de aprendizado. Com essa estratégia, mesmo se o professor selecionar sempre o primeiro item da lista, ele estará provavelmente recomendando itens diferentes para diferentes alunos.

Para comparar o *framework* apresentado acima com os resultados da revisão sistemática da literatura, foram adicionadas as informações da Tabela 1 uma nova linha na qual contém as características do *framework* apresentado nesse trabalho. Essas comparações podem ser visualizadas na Tabela 2.

Tabela 2 – Quadro comparativo dos trabalhos selecionados na revisão sistemática com o presente trabalho.

Trabalho	Dest.	Filtragem	Plat.	Recom.	Fase	Onto.
(ANSARI et al., 2016)	Sistema ¹ , Aluno	FBC, FC	Web	Melhorias ¹ , Amigos, Exercícios, Cursos, Livros	Implement.	ND
(AVILA; GATTO; ZORZO, 2010)	Aluno	FBC	TV	Programas de TV	Implement.	ND
(BANNO; YANG, 2016)	Aluno	Contex.	Mobile	OA	Proj.	ND
(BHATTACHARYA et al., 2018)	Aluno	FBC, FC	Web	Curso	Simul.	ND
(CAI; ZHANG; DAI, 2019)	Professor	ND	ND	Recursos	Proj.	ND
(CAO et al., 2018)	Aluno	Híbrida	Web	Recurso	Implement.	ND
(CHAVARRIAGA; FLORIAN-GAVIRIA; P., 2014)	Aluno	FC, Conhec.	Web	Recursos	Implem.	Não
(CHENG; ZHANG; SHI, 2018)	Aluno	Conhec.	ND	LP	Implement.	Sim
(DANG, 2018)	Aluno ¹ , Professor	AS	Web	Conteúdos ¹ , Perfis	Proj.	ND
(DURÁN; ÁLVAREZ, 2017)	Aluno	FBC, Contex.	Mobile	Profissional	Simul.	Sim
(EPSTEIN et al., 2013)	Aluno	ND	Web	Conteúdo	Proj.	ND
(FU et al., 2015)	Aluno	FBC, FC	ND	Curso	Proj.	ND
(GEDDAWY et al., 2019)	Aluno	<i>Deep Learning</i>	ND	LP	Simul.	ND
(GOGO; NDERU; MWANGI, 2018)	Alunos	Fuzzy	ND	Conteúdos	Sim.	ND
(HASSAN; HAMADA, 2017)	Aluno	FBC	Mobile	OA	Proj.	ND
(HOIC-BOZIC; DLAB; MORNAR, 2016)	Aluno	FBC, FC	Web	Colaborador, Ferramenta	Proj.	ND
(JAIN; ANIKA, 2018)	Aluno	Min. Dados	ND	Cursos	Simul.	ND
(KARGA; SATRATZEMI, 2014)	Professor	FBC, FC	Web	Templates	Proj.	ND
(LI; MEI; WANG, 2012)	Aluno	AS	ND	Conteúdos	Implement.	Sim
(LI; LI, 2017)	Aluno	FC	Web	Curso	Proj.	ND
(LI; SUN, 2018)	Aluno, Professor	FBC	ND	Conteúdo	Simul.	ND
(LIANG; CHEN, 2014)	Aluno	FBC, FC	ND	Video	Simul.	ND
(LIN; CHEN, 2020)	Aluno	<i>Deep Learning</i>	Mobile	LP	Implement.	ND
(LI et al., 2017)	Aluno	FBC, FC	ND	Recursos	Simul.	ND
(NETO; SALES, 2015)	Aluno	FBC, FC, Contex.	Mobile	Conteúdo	Simul.	ND
(MONDAL et al., 2020)	Aluno	Híbrida	ND	Curso	Simul.	ND
(MONTUSCHI et al., 2015)	Aluno	ND	Web	Curso	Simul.	ND
(NADEEM; STANSBURY; MOONEY, 2018)	Aluno	FC, FBC	ND	Recurso	Simul.	ND
(OUALI; OUMAIRA, 2020)	Aluno	ND	ND	LP	Proj.	ND
(PARYUDI; C.N, 2011)	Aluno	FBC	Web	Recursos	Proj.	Sim
(POTTS et al., 2018)	Aluno	ND	Web	Aluno	Simul.	ND
(PRISCO et al., 2017)	Aluno	ND	Web	OA	Implement.	ND
(PRISCO et al., 2019)	Aluno	ND	Web	Recurso	Proj.	ND
(QIAO; GUO; ZHAO, 2018)	ND	FC	ND	Vídeo	Simul.	ND
(QOMARIYAH; FAJAR, 2019)	Alunos	Regras	ND	Conteúdos	Proj.	Sim
(RAHMA; KOUTHEAIR, 2019)	Aluno	FBC	Web	Conteúdo	Implement.	ND
(SAITO; WATANOBE, 2018)	Aluno	<i>Deep Learning</i>	Web	LP	Simul.	ND
(SAMMOUR et al., 2015)	Aluno	ND	Web	Curso	Proj.	Sim
(SHI et al., 2018)	Alunos	FC, Conhec.	ND	Cursos	Implement.	ND
(STRICKROTH; PINKWART, 2012)	Aluno	Híbrida	Web	Conteúdo	Implement.	ND
(TORRE; TORSANI, 2016)	Professor	FBC	Web	Ferramentas, Ações	Implement.	Sim
(WAI, 2016)	Aluno	FC	Web	Curso	Implement.	ND
(ZHANG et al., 2014)	Aluno	Híbrida	Web	Recurso	Simul.	Sim
(ZHANG; LIU; WANG, 2020)	Aluno	<i>Deep Learning</i>	ND	Recurso	Simul.	ND
(ZHAO et al., 2018)	Aluno	FBC	Web	Vídeo	Implement.	ND
(ZIQI et al., 2015)	ND	Híbrida	ND	Recurso	Simul.	ND
Este trabalho	Professor	Híbrida	Web, Mobile	OA	Simul.	Não

4 TESTES E RESULTADOS

Neste Capítulo serão apresentadas uma análise do *dataset* montado para a validação do *framework* proposto neste trabalho, bem como a preparação dos testes que foram realizados e a análise dos resultados obtidos com os testes realizados.

4.1 Montagem do *Dataset*

A primeira fase para conseguir validar o *framework* proposto nesse trabalho é a montagem de um *dataset*. Como não foi encontrado um *dataset* que pudesse ser usado como referência e comparação para este trabalho, foi necessário construir um *dataset* sintético para simular as situações a quais o *framework* tem a intenção de lidar.

Esse trabalho contou com o apoio de uma empresa privada com relação a cessão de informações que pudessem ser utilizadas nos testes e no estudo de caso. Porém, essas informações não são suficientemente completas para a amplitude desse trabalho. Sendo assim, diversos pontos precisam ser considerados na construção desse *dataset*.

O primeiro ponto considerado na construção do *dataset* é que ele precisa conter informações básicas a respeito dos objetos de aprendizagem, uma vez que o *framework* tem como objetivo fazer a recomendação dos mesmos. Assim, foram coletados dados de objetos de aprendizagem de um aplicativo de uma franquia de escolas de inglês para compor essa parte dos dados.

No cenário da aplicação desse trabalho, para a realização dos testes, os objetos de aprendizado precisam conter ao menos duas informações: uma categorização técnica, ou seja, qual/quais o(s) tópico(s) que o objeto de aprendizagem está relacionado e a qual/quais lugares ele está ligado.

Como a empresa que forneceu as informações não possuía o costume de categorizar e ampliar metadados relativos aos seus conteúdos, foi necessário acessar esses conteúdos e fazer uma categorização manual dos mesmos para se encaixar nos critérios acima descritos.

Assim, os objetos de aprendizagem são representados por um identificador, um nome utilizado para identificação no processo de recomendação, uma categorização relacionada ao conteúdo abordado e rótulos de lugares relacionados ao OA.

ID: 25
Nome: Contato 1 - Day 5 - Book 1
Categorias: how questions, do, does
Lugares relacionados: home (private),
 supermarket, Convenience Store

Figura 5 – Exemplo de Objeto de Aprendizagem do dataset sintético.

A Figura 5 apresenta um exemplo de um objeto de aprendizagem que consta nesse dataset. O OA em questão é definido pelo ID de número 25, o nome “Contato 1 - Day 5 - Book 1”, as categorias “how questions, do, does” e os lugares relacionados “home (private), supermarket, Convenience Store”.

O segundo ponto considerado foi a necessidade de informações a respeito das interações dos alunos com os conteúdos. Assim, foram capturadas nesse mesmo aplicativo as interações dos estudantes com os objetos de aprendizagem acima mencionados. Assim, foram capturadas a identificação dos estudantes e a identificação dos objetos de aprendizagem com os quais os mesmos interagiram.

Se faz importante ressaltar que todos os dados referentes aos alunos estão anonimizados. Em outras palavras, não se tem nenhum dado sensível a respeito do aluno, como nome, idade, sexo, entre outros. Tem-se apenas a informação de identificador do usuário (ID) no banco de dados. Dessa forma a identificação e privacidade do estudante não é comprometida.

Assim, com esses dados acima mencionados, já seria possível fazer o uso de um SR completo (com FCB e FC e métodos de hibridização, inclusive) que levasse em conta apenas as informações da relação entre estudantes e os objetos de aprendizado. Entretanto, como o *framework* se dispõe a lidar com informação de contexto, é necessário uma maior abrangência de informações.

Como nos dados fornecidos pelo aplicativo dessa empresa que se disponibilizou a ceder a informação não é possível encontrar informações relacionadas a contexto dos estudantes, foi necessário emular essa informação de alguma maneira. Para fazer isso, foi utilizado um *dataset* de check-ins em lugares de Nova York. Esses dados são disponibilizados por YANG et al. (2015).

ID: 49bbd6c0f964a520f4531fe3
Categorias: Arts & Crafts Store

Figura 6 – Exemplo de Lugar do dataset sintético.

Neste trabalho, foram utilizadas as informações de um identificador e de categorias daquele lugar, para caracterizar os lugares. Um exemplo de lugar nesse dataset é apresentado na Figura 6, a qual demonstra um lugar com identificador “49bbd6c0f964a520f4531fe3” e com a categoria “Arts & Crafts Store”.

Assim, com as informações de locais que os usuários frequentam, foi possível gerar sinteticamente a informação de contexto. As informações desse *dataset* consistem na relação (check-in/interação) dos usuários com os lugares e as informações a respeito rótulos associados a cada lugar.

Para que fosse possível mesclar as diferentes bases, os identificadores de usuários de um *dataset* foram mapeados para corresponder com os identificadores de outro. Dessa forma, foi completado o *dataset* contendo informações de usuários com os objetos de aprendizado e a informação de contexto (nesse caso, informações de localização) desses usuários. A partir disso, foi possível realizar a tarefa do *framework* de recomendar objetos de aprendizagem que façam sentido para o contexto do aluno.

Dessa forma, para exemplificar o comportamento do *framework*, a seguir será apresentado o fluxo do processo de recomendação para um determinado usuário. Nesse exemplo, os dados apresentados a seguir dizem respeito ao usuário de identificador 190. Tal usuário tem diversos objetos de aprendizagem, conforme apresentado na Figura 7. Entre tantos outros OA, ele interagiu com o objeto de nome “Contato 1 - Day 11 - Book 2”, o qual possui as categorias “more than, the most” e está relacionado aos lugares “music shop, music store, instrument shop, music venue”.

User 190

Recomendações
Exercícios
Lugares
Usuários Similares

- Contato 1 - Day 11 - Book 2 - more than, the most - music shop, music store, instrument shop, music venue
- Contato 2 - Day 11 - Book 2 - more than, the most - music shop, music store, instrument shop, music venue
- Contato 3 - Day 11 - Book 2 - more than, the most - music shop, music store, instrument shop, music venue
- Contato 4 - Day 11 - Book 2 - more than, the most - music shop, music store, instrument shop, music venue
- Contato 5 - Day 11 - Book 2 - more than, the most - music shop, music store, instrument shop, music venue
- Contato 6 - Day 11 - Book 2 - more than, the most, question words - music shop, music store, instrument shop, music venue
- Contato 1 - Day 12 - Book 2 - was, were, verb+ing, past - police station, car park
- Contato 2 - Day 12 - Book 2 - was, were, verb+ing, past - police station, car park
- Contato 3 - Day 12 - Book 2 - was, were, verb+ing, past - police station, car park
- Contato 4 - Day 12 - Book 2 - was, were, verb+ing, past - police station, car park
- Contato 5 - Day 12 - Book 2 - was, were, verb+ing, past - police station, car park
- Contato 6 - Day 12 - Book 2 - was, were, verb+ing, past, question words, how questions - police station, university
- Contato 1 - Day 13 - Book 2 - supposed to, job interview - restaurant
- Contato 2 - Day 13 - Book 2 - supposed to, job interview - restaurant
- Contato 3 - Day 13 - Book 2 - supposed to, job interview - restaurant
- Contato 4 - Day 13 - Book 2 - supposed to, job interview - restaurant
- Contato 5 - Day 13 - Book 2 - supposed to, job interview - nan
- Contato 1 - Day 14 - Book 2 - ability - nan
- Contato 2 - Day 14 - Book 2 - ability - nan
- Contato 3 - Day 14 - Book 2 - ability - nan
- Contato 4 - Day 14 - Book 2 - ability - nan
- Contato 5 - Day 14 - Book 2 - ability, can, could, question words - nan
- Contato 1 - Day 15 - Book 2 - action completion - nan
- Contato 2 - Day 15 - Book 2 - action completion, have - nan
- Contato 3 - Day 15 - Book 2 - action completion - nan
- Contato 4 - Day 15 - Book 2 - action completion, have - nan
- Contato 5 - Day 15 - Book 2 - action completion, have, past - nan
- Contato 1 - Day 16 - Book 2 - life experiences - hospital, medical center
- Contato 2 - Day 16 - Book 2 - life experiences - hospital, medical center

Figura 7 – Interações do usuário 190 com objetos de aprendizagem.

Com base nas interações deste usuário com os OA em questão, é possível apli-

car a FBC. Ainda, considerando o tópico informado pelo professor, é possível aplicar também a FBC relacionada ao tópico de interesse. Também é possível aplicar a FC ao fazer uso das interações de outros usuários com esses OA, ou seja, com os dados dos objetos de aprendizagem e as interações dos usuários com os mesmos, é possível fazer a execução de toda a etapa de filtragem.

A partir de então são utilizadas as informações de contexto na etapa de hibridização para priorizar as informações obtidas na etapa de filtragem. Considerando o mesmo usuário de identificador 190, os locais com os quais ele interagiu fazendo check-in são apresentados na Figura 8. Vê-se que o usuário fez check-in em um local de identificador “48aa7164f964a520a5511fe3” com a categoria “Park” e outro com identificador “4b18552ef964a52009d123e3” com a categoria “Hotel”, entre diversos outros.

User 190

Recomendações
Exercícios
Lugares
Usuários Similares

- 4b18552ef964a52009d123e3 - Hotel
- 4c76eb14947ca1cd15ce4537 - Food Truck
- 3fd66200f964a52038e41ee3 - Hobby Shop
- 3fd66200f964a520def11ee3 - Park
- 4a1afeb7f964a520b77a1fe3 - Bowling Alley
- 3fd66200f964a520cde61ee3 - Italian Restaurant
- 46dbf48df964a5208a4a1fe3 - Bar
- 4ab3e1eff964a520e46e20e3 - Clothing Store
- 4d9885ae647d8cfa23ccf03d - Flea Market
- 4c423c5bcc410f475783ac61 - Park
- 45f6af33f964a5202c441fe3 - Pizza Place
- 4da759dbfa8c4175d09fd01a - Food Truck
- 4ba12d0bf964a520169f37e3 - Sculpture Garden
- 4b7def17f964a520ceda2fe3 - Bar
- 4f908642e4b0cddb6a6d24af - Building
- 4b533795f964a520b59227e3 - Medical Center
- 4aeba012f964a520efc321e3 - Italian Restaurant
- 4bdb106663c5c9b651262668 - Scandinavian Restaurant
- 4858e403f964a520bf501fe3 - Furniture / Home Store
- 4b889d2ef964a5208a0432e3 - Bridge
- 4e79f9ce091ad14ff7119b42 - Bridge
- 48aa7164f964a520a5511fe3 - Park
- 40f1d480f964a5206a0a1fe3 - Park
- 4081c500f964a52081f21ee3 - Park
- 4581734ff964a520653f1fe3 - Seafood Restaurant
- 4c25fda55c5ca593f14145fe - Gym / Fitness Center
- 4cd006cdde0f6dccb8c36763 - Event Space
- 4f551c48e4b0ce972e8c5224 - Moroccan Restaurant
- 4af4d881f964a520d4f621e3 - Italian Restaurant
- 4b6b5abff964a520fb022ce3 - Historic Site

Figura 8 – Check-ins do usuário 190.

A partir dessa informação já é possível, através de uma FBC, priorizar as recomendações da etapa anterior com base nas categorias dos lugares frequentados e nos rótulos de lugares relacionados dos objetos de aprendizagem.

Da mesma forma, pode-se obter a similaridade entre usuários baseando-se na informação de contexto. Assim, o usuário com identificador 629 é similar ao usuário em questão (usuário de identificador 190) pois frequentou alguns dos mesmos lugares,

por exemplo. A Figura 9 apresenta à esquerda alguns dos lugares frequentados pelo usuário 629 e o lugar em comum entre os dois usuários está destacado.

User: 629

- 4a3020d2f964a52023991fe3 - Bar
 - 3fd66200f964a5205de41ee3 - French Restaurant
 - 4b08141af964a520610323e3 - Diner
 - 4af23a4af964a520c2e621e3 - Airport
 - 4f74a494e4b0da64dfe954dd - Clothing Store
 - 4a8e031cf964a520be1120e3 - Bar
 - 4b7def17f964a520ccea2fe3 - Bar
 - 4f8bad82e4b05ae88ae6dc6a - Neighborhood
 - 4cb235bfeb65b1f73ed97acd - Food & Drink Shop
 - 4e498e05aeb7de71b38c15ff - Bar
 - 49b79f54f964a5202c531fe3 - Plaza
 - 40e74880f964a520150a1fe3 - Burger Joint
 - 4c12b3d07f7f2d7f11ccdd68 - Bar
 - 4af83ea9f964a5209a0b22e3 - Seafood Restaurant
 - 4b9d6aedf964a52059ab36e3 - Food & Drink Shop
 - 4bfec39768c7a5935ea53f44 - Fast Food Restaurant
 - 4c2bcccd7d1a10f475a88f864 - Burger Joint
 - 4e5e96dbd4c08cf7f58fe276 - Bar
 - 3fd66200f964a52044e91ee3 - French Restaurant
 - 4a7a0b43f964a5204be81fe3 - Mall
 - 4d1e048416cfb60c7f864461 - Clothing Store
 - 4b4f5a31f964a520b20227e3 - Burger Joint
 - 4a935e84f964a520a61f20e3 - Deli / Bodega
 - 4e4dd9afbd4101d0d79cbd5c - Pizza Place
 - 4c3b7a364565e21e97ca566a - Bar
 - 49e79ffdf964a520e3641fe3 - Steakhouse
- Contato 5 - Day 18 - Book 2 - conditionals - nan
 - Contato 6 - Day 18 - Book 2 - conditionals - concert

Figura 9 – Check-ins do usuário 629 (à esquerda) e interações com objetos de aprendizagem (à direita).

Com essa informação é possível estabelecer os objetos de aprendizagem prioritários através de uma FC usuário-usuário, de maneira a recomendar objetos de aprendizagem que costumam interagir de usuários que frequentam os mesmos lugares.

Assim, com a combinação das duas abordagens, os objetos de aprendizagem são priorizados e contextualizados e, então, recomendados ao professor. E como saída, tem-se para o usuário 190, por exemplo, as recomendações apresentadas na Figura 10. Nela é possível ver OA que contém lugares relacionados e que estão nas categorias dos lugares nos quais o usuário fez check-in. Na mesma Figura 10, pode-se observar que uma das recomendações aparece na coluna da direita da Figura 9 como um exercício feito pelo usuário 629.

User 190

Recomendações

Exercícios

Lugares

Usuários Similares

- Contato 6 - Day 21 - Book 3 - to+verb, verb+ing - bike rental, rental office
- Contato 5 - Day 2 - Book 1 - question words, verb to be - park
- Contato 6 - Day 18 - Book 2 - conditionals - concert
- Contato 6 - Day 22 - Book 3 - had+past participle - airport
- Contato 1 - Day 6 - Book 1 - is, are, verb+ing - library

Figura 10 – Recomendações geradas para o usuário 190.

4.2 Definição das Métricas

Como dito anteriormente, o primeiro passo para a avaliação de um SR é a realização de experimentos offline, de forma a identificar o quão eficiente o algoritmo está sendo. Para isso, é necessário o acompanhamento de uma ou mais métricas. Nesse trabalho, as métricas definidas para medir o desempenho do *framework* são apresentadas a seguir.

Cobertura. A métrica de cobertura das recomendações diz respeito ao percentual de itens do total de itens disponíveis, nesse caso, objetos de aprendizado, que são recomendados pelo algoritmo. Em outras palavras, o SR é aplicado a todos os usuários e, após, é verificada a quantidade de itens que foram recomendados. Assim, quanto mais itens o SR conseguir recomendar, maior a cobertura que ele tem. Esse também pode ser um indicador de que o SR está conseguindo recomendar coisas diferentes para os usuários, ou recomendando apenas as mesmas coisas.

Similaridade entre recomendações. Esta métrica diz respeito à diversidade das recomendações que estão sendo dadas. Essa métrica pode indicar o quanto o sistema consegue inovar nas recomendações. Em outras palavras, quanto maior a similaridade entre os itens de uma recomendação, mais específico em uma determinada propriedade o algoritmo está sendo.

O quão bom ou ruim é o resultado final obtido com essa métrica, deve ser avaliado caso a caso, dependendo do objetivo do recomendador. Se a intenção é inovar nas recomendações, ou seja, mostrar coisas diferentes, quanto menor a similaridade entre os itens da lista, melhor. Entretanto, se o objetivo é ser consistente em mostrar itens alinhados a uma determinada preferência do usuário, pode ser que a similaridade ser maior pode ser melhor. Além disso, essa métrica, dependendo do caso, pode indicar uma superespecialização quando o valor é alto.

Personalização. A personalização é uma métrica que diz o quanto um SR consegue dar de experiência personalizada para um usuário, ou seja, o quanto as recomendações são específicas para um determinado usuário. Assim, quanto maior o índice de personalização, mais específicas são as as recomendações para um determinado usuário.

MAP@K e MAR@K. Um SR normalmente produz uma lista ordenada de recomendações para cada usuário. Assim, para medir o quão relevante são os itens dessa lista, são utilizadas as métricas média da precisão média até K (MAP@K, acrônimo do termo em inglês *Mean Average Precision at K*) e média do *recall* médio até K (MAR@K, acrônimo do termo em inglês *Mean Average Recall at K*).

A métrica MAP@K mede a proporção dos itens recomendados até a posição K que são relevantes. Já a métrica MAR@K mede a proporção de itens relevantes encontrados até a posição K. A precisão P pode se definida como na Equação 4.

$$P = \frac{recRel}{itensRec} \quad (4)$$

onde $recRel$ é o número de recomendações relevantes e $itensRec$ é o total de itens recomendados.

Assim, a precisão média (AP em MAP@K) é a precisão média do conjunto de recomendações para um usuário. Já MAP@K é a média de AP calculada para todos os usuários. O *recall* pode ser definido de acordo com a Equação 5.

$$R = \frac{recRel}{itensRel} \quad (5)$$

onde $recRel$ também é o número de recomendações relevantes e $itensRel$ é a quantidade de itens relevantes possíveis.

Da mesma maneira, para se calcular a média do *recall* médio (MAR@K) é calculada a média do valor obtido com o cálculo do *recall* médio (AR em MAR@K) de um conjunto de recomendações para todos os usuários.

Para exemplificar, para uma melhor compreensão, MAP@K diz que foram encontrados, por exemplo, 3 itens relevantes até a posição 5. Já MAR@K, diz que foram encontrados 3 itens relevantes dos 3 itens relevantes possíveis até a posição 5, por exemplo. Essa informação é coletada para todos os usuários e assim é feita a média. Mais detalhes e exemplos sobre essas métricas são fornecidos por MALAEB (2020).

4.3 Análise do *Dataset*

A análise do *dataset* é uma etapa importante para entender o comportamento que o *framework* pode tomar. Analisar e entender a quantidade de informações providas pelo *dataset* ajuda a compreender como que as recomendações podem ser influenciadas. Essa etapa se torna ainda mais importante por se tratar de um *dataset* sintético.

Sumarizando, o *dataset* é composto por 1202 usuários, 180 objetos de aprendizagem e 38333 lugares diferentes. Além disso, contém todas as informações de interações dos usuários com esses OA e lugares.

A primeira análise diz respeito a quantidade de objetos de aprendizagem encontrados e sua categorização. Foram encontrados ao todo, 180 objetos de aprendizagem os quais são descritos por categorias relativas ao tópico de estudo e ao lugar relacionado ao objeto de aprendizagem. Quanto à categorização desses objetos, eles estão relacionados ao todo com 58 categorias técnicas, ou seja, relacionadas ao conteúdo como, por exemplo, o tópico gramatical ao qual o OA está relacionado, e 51 rótulos

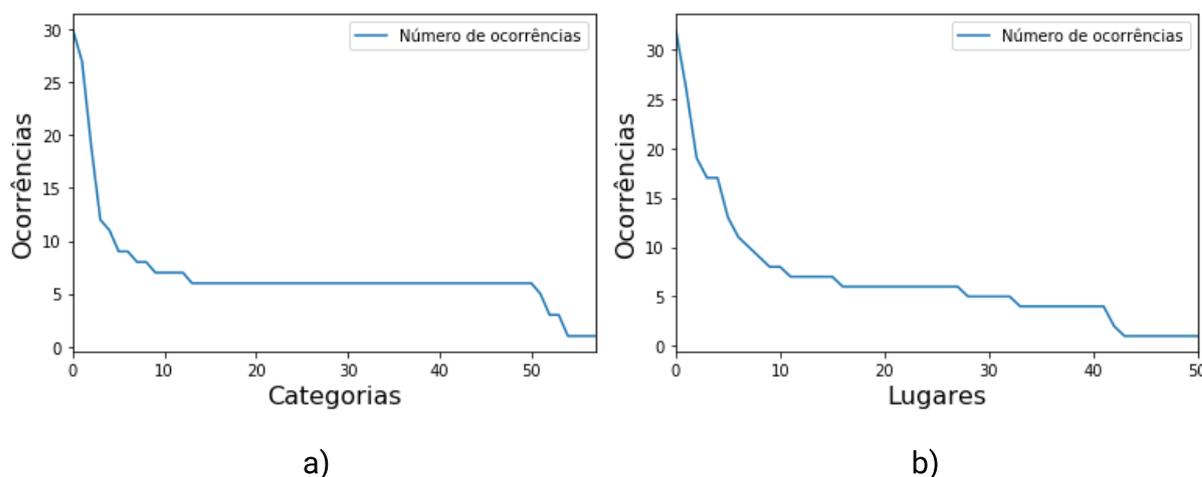


Figura 11 – Ocorrência das categorias nos objetos de aprendizado: a) Categorias técnicas. b) Rótulos dos lugares relacionados.

relacionados a lugares, ou seja, a qual tipo de lugar um determinado conteúdo está relacionado.

Como pode ser visto na Figura 11a existem algumas poucas categorias que ocorrem em vários objetos de aprendizagem. Isso pode indicar que existem vários exercícios bastante similares entre si com base na categorização. O efeito disso pode ser sentido na FBC, onde a gama de objetos de aprendizado que podem ser recomendados baseando-se em determinada categoria pode ser bastante ampla, pois, como dito existem muitos OA que são muito parecidos entre si com base em sua nas categorias relacionadas a cada um deles.

A mesma situação ocorre para a categorização dos objetos de aprendizagem com base em lugares relacionados, conforme pode ser visto na Figura 11b, que mostra a quantidade de objetos por rótulo relacionado ao lugar.

A segunda análise consiste na avaliação da relação entre objetos de aprendizado e as interações dos usuários com esses objetos. Conforme é apresentado na Figura 12, que apresenta quantidade de interações por usuário com os objetos de aprendizado, existe um efeito de cauda longa, ou seja, poucos usuários interagiram com muitos objetos, enquanto que muitos usuários interagiram com uma menor quantidade de objetos.

O usuário com maior número de interações, interagiu com 177 objetos do total de 180, enquanto que o menor número de interações é igual a no mínimo um objeto de aprendizagem. Ao todo, foram localizados 1171 usuários que interagiram com esses objetos de aprendizado do total de 1202 usuários presentes no *dataset*, ou seja, 31 usuários não possuíam nenhuma interação.

Em uma segunda etapa dessa última análise foi observado o comportamento pelo lado contrário, ou seja, procurou-se identificar quantas interações cada objeto de aprendizagem teve. Assim, conforme é ilustrado na Figura 13, notou-se um efeito

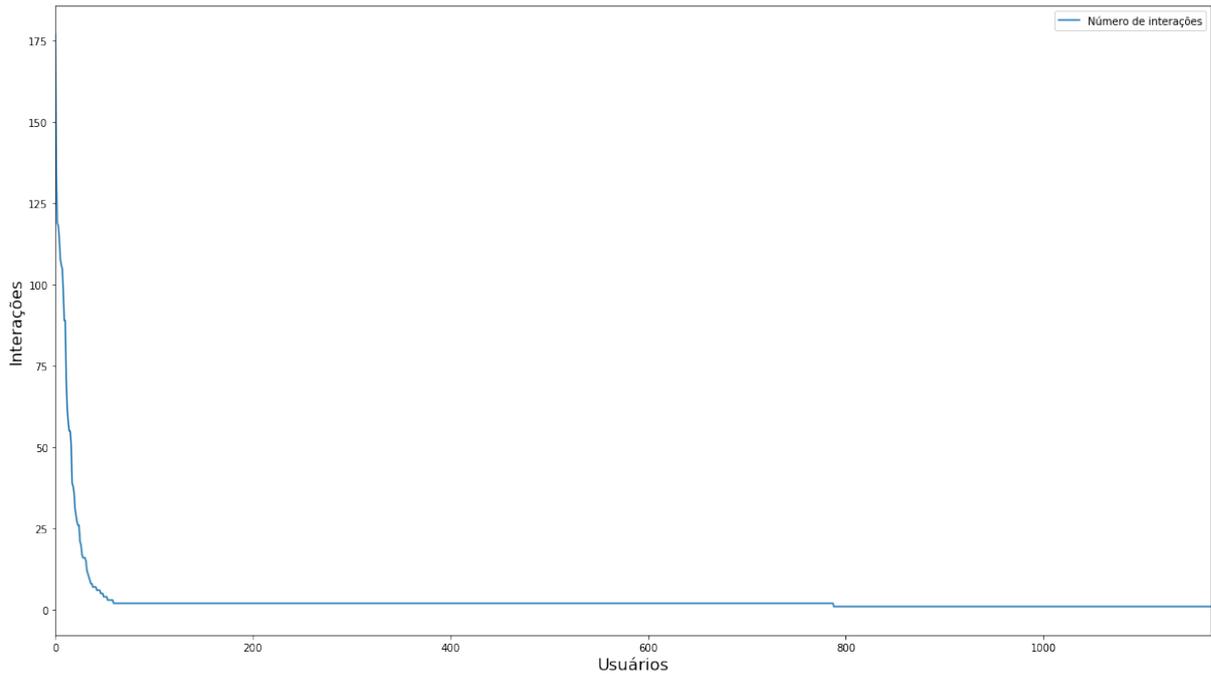


Figura 12 – Quantidade de interações com objetos de aprendizado por usuário.

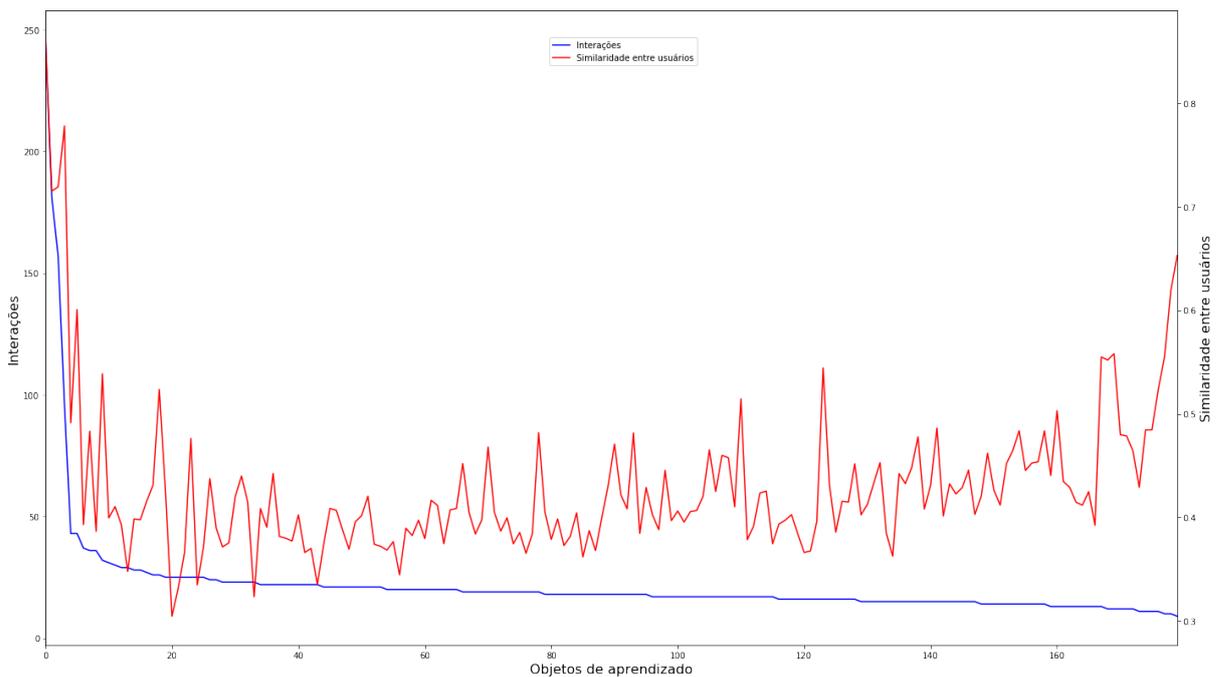


Figura 13 – Quantidade de usuários que interagiram com cada objeto de aprendizagem.

de cauda longa, sendo que o objeto de aprendizagem com o qual os usuários mais interagiram, teve 246 interações, ou seja, 246 usuários diferentes interagiram com esse objeto. Além disso, pode-se notar que cada objeto de aprendizagem teve no mínimo 9 usuários que interagiram com ele. Nenhum dos 180 objetos de aprendizado ficou sem interação.

Além disso, foi calculada a similaridade entre os usuários que interagiram com cada um dos objetos de aprendizagem com base no conjunto total de objetos que eles interagiram. O cálculo aplicado é semelhante ao cálculo aplicado na filtragem colaborativa usuário-usuário. Com esse cálculo, buscou-se observar se os usuários que interagiram com um determinado objeto de aprendizagem, costumam interagir com os mesmos itens e traçar uma relação.

Assim, pode-se perceber que objetos que tiveram a interação de vários e distintos usuários levam a uma maior similaridade entre os usuários. Isso indica que os usuários que interagiram com esses objetos de aprendizado, tem interações muito similares. E ao contrário, objetos que possuem menos interações revelaram que a similaridade entre esses usuários é menor, ou seja, há esparsidade nessas interações. Assim sendo, a alta similaridade mostrada no lado esquerdo da Figura 13 indica que os usuários que interagiram com esses objetos interagiram com poucos e quase os mesmos exercícios, uma vez que o restante da cauda indica esparsidade de informações.

Entretanto, é possível notar que ao final da cauda, onde se localizam os objetos com menor número de interações por usuários distintos, a similaridade entre os usuários volta a crescer. Isso pode ocorrer porque esses poucos usuários que interagiram com o objeto em questão interagiram com quase os mesmos outros objetos de aprendizado. Assim, esses mesmos 9 usuários podem ter interagido com quase todos os exercícios ou com quase nenhum outro. Ao que se indica, observando a Figura 13, por haver esparsidade de informações, esses usuários interagiram com os mesmos poucos exercícios.

Uma terceira análise consistiu na avaliação da informação de contexto dos usuários do *dataset* sintético deste trabalho. Dos 1202 usuários, 1083 possuem informações de check-in. Da mesma forma que foi feito na análise anterior, essa análise foi dividida em duas etapas. O usuário que mais fez check-ins realizou check-in em 714 diferentes lugares e o que menos realizou check-ins fez check-in em apenas 9 lugares.

Na primeira etapa dessa análise, cujo resultado é apresentado na Figura 14, foi avaliada a quantidade de check-ins em diferentes lugares realizadas por cada usuário e a média de em que ele repetiu o mesmo lugar.

Como é possível observar na Figura 14, existe também um efeito de cauda longa, onde poucos usuários frequentam distintos lugares e muitos usuários frequentam uma quantidade menor de lugares. É interessante observar que aqueles usuários que frequentam um maior número de lugares distintos, costumam frequentar esses lugares apenas uma ou duas vezes, em média. Enquanto isso, usuários que frequentam uma quantidade menor de lugares tendem a repetir com maior frequência sua visita.

Na segunda etapa dessa terceira avaliação, foi feito o processo contrário à etapa anterior. Foi analisada a quantidade de usuários que frequentaram determinado lugar.

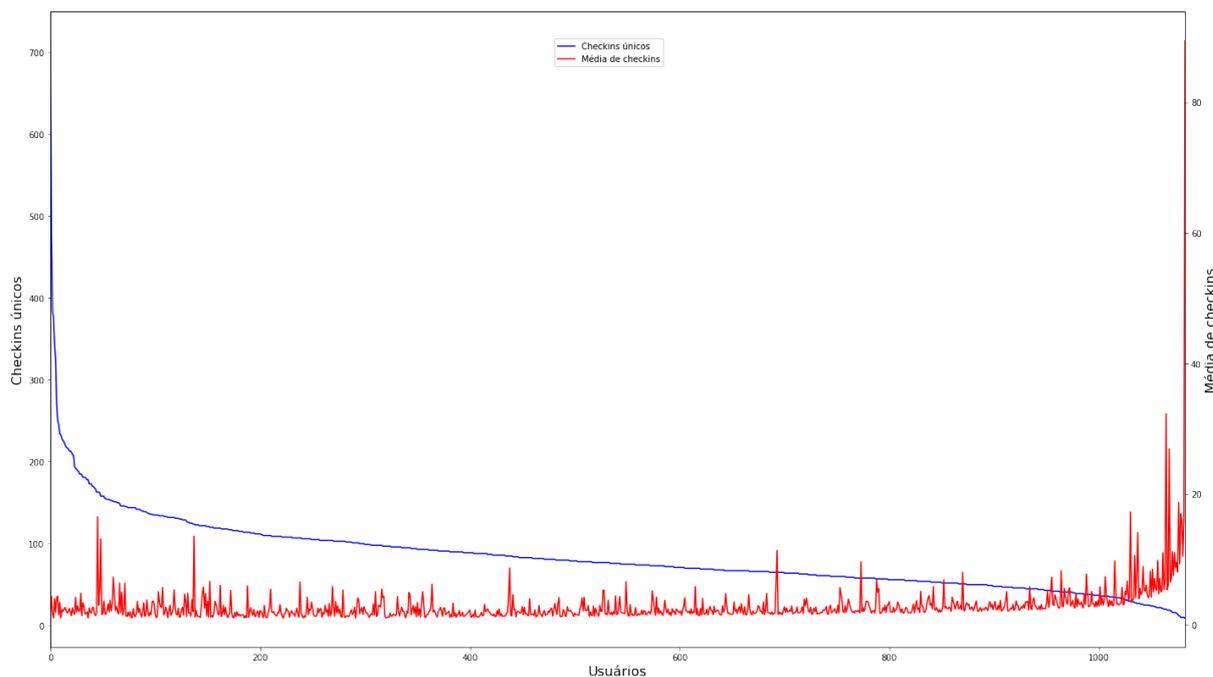


Figura 14 – Quantidade de check-ins únicos em diferentes lugares por usuário é média de check-ins por local.

Os resultados obtidos são apresentados na Figura 15. Ao todo, são 38333 lugares que tiveram check-ins realizados por 1083 usuários. O lugar mais frequentado, teve check-in de 274 usuários distintos enquanto que o lugar menos frequentado teve check-in de apenas um usuário.

Na Figura 15 também é possível notar um efeito de cauda longa, ou seja, muitos lugares são frequentados por poucos diferentes usuários, tornando a informação esparsa, logo, difícil de criar relações, enquanto que poucos lugares são frequentados por muitos usuários, o que pode elevar a correlação entre usuários.

Por fim, a quarta e última análise feita diz respeito a categorização dos lugares. Ou seja as propriedades da informação de contexto dos alunos. Com isso, foi possível observar que existem 251 rótulos distintos de lugares. É importante observar que nem todas os mesmos rótulos aqui presentes estão presentes nos objetos de aprendizagem, onde, conforme mencionado, foram encontradas apenas 51 rótulos diferentes.

A quantidade de lugares em cada rótulo está distribuído conforme apresentado na Figura 16, onde também pode ser visto que existe uma grande quantidade de lugares que se concentram em um determinado rótulo, e uma vasta gama de rótulos que estão relacionados a poucos lugares, dando um efeito de cauda longa.

Desses 51 rótulos, alguns deles não se encontram no *dataset* de check-ins. Sendo assim, menos de 20% do total de rótulos dos lugares estão relacionadas aos objetos de aprendizagem. Essa disparidade pode limitar o algoritmo na exploração de informação de contexto como relação à realização da recomendação associada aos lugares que o aluno costuma frequentar, pois os rótulos de um tipo de informação não

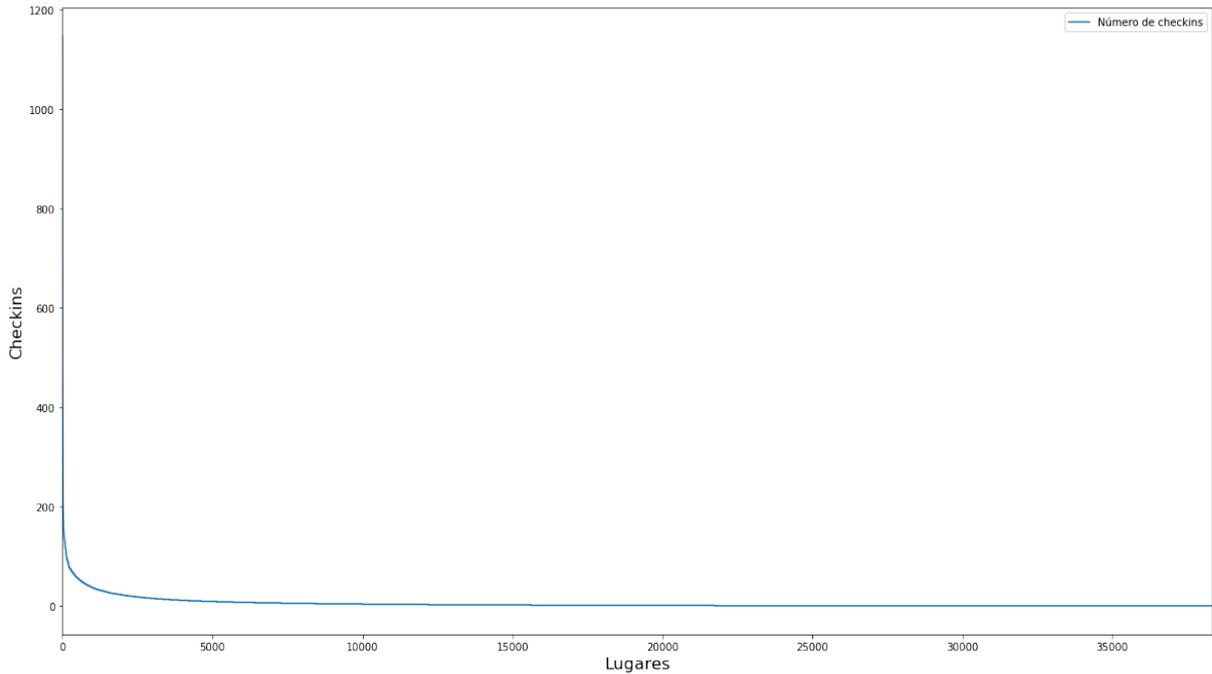


Figura 15 – Quantidade de check-ins únicos por lugar.

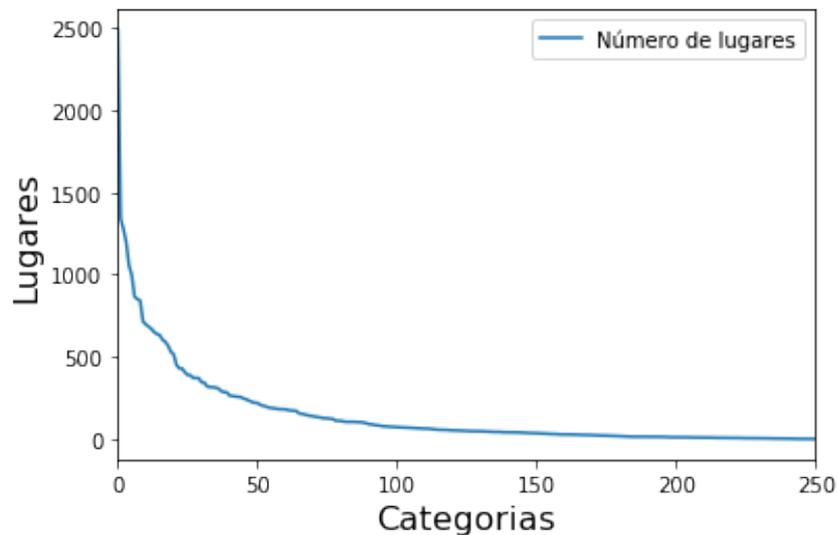


Figura 16 – Quantidade de lugares por categoria.

se encontram no outro.

O efeito de cauda longa foi mencionado várias vezes aqui para fazer referência a itens que são bastante populares e outros que têm informações bastante esparsas. Assim, ao considerarmos o efeito de calda longa, na esquerda se tem os itens que são mais populares. Normalmente esses itens são os itens mais recomendados por se ter um maior histórico, entretanto pode causar superespecialização. Por isso, introduzir diversidade se torna importante. E essa diversidade pode ser encontrada na cauda, à direita nos gráficos, onde se tem itens pouco conhecidos.

Por outro lado, por ter muita informação na parte da cauda, onde as informações

são bastante esparsas, é necessário tomar cuidado para que o recomendador não recomende informações erradas. Por isso, é importante que o recomendador saiba lidar com o problema de esparsidade.

4.4 Análise das Recomendações

Para se comparar o desempenho do *framework* como um todo, foram analisados, além do resultado final do *framework*, o resultado de cada uma das etapas do algoritmo, ou seja, das recomendações geradas pelas filtragens baseadas em conteúdo e pela filtragem colaborativa, além de comparar as recomendações pelos diferentes modos de hibridização: aleatório, mesclado e baseado no contexto.

Dessa forma pode ser feita uma comparação completa das variações do *framework* conforme indicado anteriormente na Seção 2.3.5.1 que fala a respeito da realização de experimentos offline.

Para a avaliação das recomendações de todas as variações mencionadas anteriormente, foram utilizadas as métricas apresentadas na Seção 4.2. Para tal avaliação, os resultados obtidos são apresentados na Tabela 3.

Tabela 3 – Resultados das avaliações do *framework*.

Algoritmo	Cobertura	Sim. recomendações	Personalização	MAP@K	MAR@K
FBC	100%	88,5%	88,1%	41%	41%
FBC-tópico	10%	98,86%	13,14%	2,2%	2,2%
FC	91,67%	25%	89,18%	59,81%	59,81%
Aleatório	99,44%	32,67%	82%	15,83%	15,83%
Mesclado	96,67%	39,22%	69,36%	60,94%	60,94%
Contexto	98,33%	53,66%	65,63%	25,52%	25,52%

Para a realização das análises foi utilizada a técnica conhecida como *Leave the Last Out* (em tradução literal, deixe o último de fora). Essa técnica, conforme descrito em JEUNEN (2019), é uma variação da validação *Leave One Out*, mais popular. Entretanto, deixar o último item de fora, permite fazer uma avaliação temporal das recomendações, pois a sequência de itens que um usuário interagiu pode ter levado ele a interagir com o item que está sendo recomendado.

Dessa forma, foi possível comparar o resultado final com o resultado esperado, o que era necessário principalmente para as métricas MAP@K e MAR@K. Além disso, o número de recomendações para cada uma das etapas do algoritmo e também como saída final do recomendador, isto é, após a hibridização, foi de 5 recomendações (parâmetro passado como entrada).

É possível observar analisando os resultados obtidos (apresentados na Tabela 3) que a variação que apresentou melhor desempenho em termos de cobertura foi a

FBC. Entretanto, os outros métodos, com exceção da FBC relacionada ao tópico de interesse, também obtiveram uma alta taxa de cobertura do *dataset*.

Isso se deve ao fato do *dataset* ter uma forte relação entre os objetos de aprendizagem, uma vez que eles normalmente são vistos em sequência e em grupos com características muito similares, além de ser uma quantidade pequena de objetos de aprendizagem. Parte disso também se deve a uma grande variação de interações dos usuários com os objetos de aprendizagem.

Por outro lado, como era de se esperar, a porcentagem de cobertura da FBC relacionada ao tópico de interesse foi baixa. Isso se deve pelo fato dessa etapa recomendar somente exercícios relacionados a determinado tópico. Da mesma maneira, por recomendar somente exercícios relacionados ao tópico informado, a similaridade entre as recomendações se torna alta e a taxa de personalização baixa, ou seja, recomenda quase sempre os mesmos conteúdos.

Entretanto, como alguns usuários não possuíam interações no cenário de testes, essa etapa foi importante para gerar as recomendações, solucionando o problema de partida a frio para alguns casos.

Um ponto importante a se observar é que a etapa de FBC relacionada ao tópico é influenciado e influencia diretamente no resultado das etapas de hibridização, para diferentes tópicos informados. Nesse caso, foi informado um tópico de interesse e pode ser que o estudante já tenha tido contato com todos os objetos de aprendizagem disponíveis sobre esse tópico, produzindo assim nenhuma recomendação a partir dessa etapa.

A FC, como era de se esperar a introdução de certa novidade entre as recomendações, teve uma similaridade entre as recomendações reduzidas, o que possibilita, por exemplo, encontrar outros padrões para se ter contato com os conteúdos. Entretanto, foi a etapa que apresentou maior taxa de personalização e a segunda maior em precisão nas recomendações.

Ao se analisar somente as recomendações finais, ou seja, após a execução dos métodos de hibridização, pode-se notar que o método mesclado foi o que apresentou melhor precisão nas recomendações. Enquanto isso, o método baseado no contexto do aluno, teve uma maior similaridade entre as recomendações. Isso acontece pela alta similaridade entre as categorizações dos conteúdos. O método aleatório, por outro lado, foi o que conseguiu maior cobertura e personalização, justamente pelo fato, de fazer escolhas aleatórias.

Dessa forma, é possível identificar que parece existir um *tradeoff*, entre a precisão da recomendação e trazer a informação contextualizada para o aluno. Entretanto, é válido lembrar que o estudo offline não necessariamente reflete a realidade. Dessa forma, seria necessário realizar testes reais para saber se vale ou não a pena essa troca e ter algum parâmetro para dizer até onde essa troca de precisão por contextu-

alização pode ir.

Além disso, é importante ressaltar que diferentes informações de contexto podem trazer diferentes comportamentos para o método de hibridização. De maneira geral, os resultados obtidos com a utilização do contexto do aluno mostram-se bastante promissores, uma vez que a cobertura de recomendações foi alta – aproximadamente 98%, a similaridade entre os conteúdos foi equilibrada – em torno de 53%, e a personalização ficou num nível que pode ser considerado alto – cerca de 65%.

Os resultados de MAP@K e MAR@K foram iguais, pois apenas um objeto de aprendizagem foi considerado relevante por usuário (devido a aplicação do *Leave The Last Out*), então não foi executado um “corte” na posição K, o que poderia diferenciar os valores. Em outras palavras, como a quantidade de itens relevantes na lista de recomendações é igual a quantidade de itens relevantes possíveis (nesse caso, 1), os valores obtidos para precisão e *recall* são iguais.

5 CONCLUSÃO

Os sistemas de recomendação vêm sendo aplicados nas mais diversas áreas. Uma dessas áreas é a área da educação. A área da educação pode ser dividida basicamente em três modalidades de ensino: ensino formal, ensino não-formal e ensino informal. Dado este contexto, de aumento na quantidade de cursos e também na quantidade de participantes em cursos *online* com base de ensino não formal, este trabalho tem como objetivo propor um *framework* de sistemas de recomendação aplicados no ensino/aprendizado não formal, utilizando-se para isso, da informação de contexto do aluno.

Como pode ser visto ao longo do trabalho, o *framework* desenvolvido aplicou uma ampla quantidade de técnicas de sistemas de recomendação para a realização das recomendações. Para isso, foram desenvolvidas três etapas de filtragem, de maneira a lidar com os problemas comuns e inerentes a cada uma das abordagens como, por exemplo, *cold start*, esparsidade e super especialização.

Em resumo as técnicas abordadas foram a filtragem baseada em conteúdo, a qual foi abordada de duas maneiras, a filtragem colaborativa através da abordagem item-item, além de implementação de três métodos de hibridização: aleatório, mesclado e cascata. Esse último utilizou-se de informações de contexto para fazer a filtragem. Para isso, foram utilizadas a filtragem baseada em conteúdo e uma filtragem colaborativa usuário-usuário, as quais foram combinadas linearmente para gerar as recomendações.

Para avaliar a qualidade do *framework* desenvolvido, foi criado um *dataset* sintético para emular situações de um cenário de uso. A avaliação foi feita através de experimentos offline. Como resultado, observou-se que o *framework* apresentou uma boa cobertura de recomendações para esse *dataset* em diferentes abordagens, possibilitando uma maior flexibilidade na utilização do *framework*, caso esse seja o objetivo.

Relacionado a exploração do contexto do aluno, a combinação geral dos resultados mostrou-se promissora, já que teve uma cobertura aproximada de 98%, a similaridade entre as recomendações ficou equilibrada e a personalização das recomendações ficou em torno de 65%. Entretanto, notou-se que existe uma espécie de troca, na ava-

liação offline, entre a precisão da recomendação e a contextualização da informação ao ambiente do aluno.

Conforme observado, devido a limitações do *dataset*, é necessário um maior número de testes. Num primeiro momento, podem ser testadas a inserção de novos objetos de aprendizado e/ou mais características a esses para haver uma maior diferenciação entre os objetos. Entretanto, pode ser interessante testar o *framework* com outro estudo de caso, para a validação com outras formas de interação com os objetos de aprendizagem.

Além disso, aumentando a quantidade de informações a respeito dos objetos de aprendizado, pode-se utilizar do padrão de metadados LOM, de forma a melhor representar os objetos com os quais o recomendador lida e, com isso, potencializar a capacidade de gerar melhores recomendações.

A partir do desenvolvimento deste trabalho, pretende-se evoluir o desenvolvimento implementando novos métodos de hibridização, aumentando assim o leque de possibilidades do algoritmo. Além disso, pretende-se adicionar suporte a múltiplas informações de contexto.

REFERÊNCIAS

- ADOMAVICIUS, G.; TUZHILIN, A. Toward the next generation of recommender systems: a survey of the state-of-the-art and possible extensions. **IEEE Transactions on Knowledge and Data Engineering**, Piscataway, Nova Jersey, EUA, v.17, n.6, p.734–749, 2005.
- ANSARI, M. H.; MORADI, M.; NIKRAH, O.; KAMBAKHS, K. M. CodERS: A hybrid recommender system for an E-learning system. In: INTERNATIONAL CONFERENCE OF SIGNAL PROCESSING AND INTELLIGENT SYSTEMS (ICSPIS), 2., 2016, Tehran, Iran. **Proceedings...** IEEE, 2016. p.1–5.
- AVILA, P. M. de; GATTO, E. C.; ZORZO, S. D. Recommender: Helping viewers in their choice for educational programs in digital TV context. In: FRONTIERS IN EDUCATION CONFERENCE (FIE), 2010, Washington, DC, USA. **Proceedings...** IEEE, 2010. p.S1E–1–S1E–6.
- BANNO, S. I.; YANG, Y. Improving Educational Assessment in Mobile Environment. In: SECOND INTERNATIONAL CONFERENCE ON COMPUTATIONAL INTELLIGENCE COMMUNICATION TECHNOLOGY (CICT), 2016, Ghaziabad, India. **Proceedings...** IEEE, 2016. p.591–597.
- BHATTACHARYA, M.; GUPTA, D.; BISWAS, S.; BANSAL, G. Designing Recommender System for Corporate Education WiP+32. In: SMARTWORLD, UBIQUITOUS INTELLIGENCE COMPUTING, ADVANCED TRUSTED COMPUTING, SCALABLE COMPUTING COMMUNICATIONS, CLOUD BIG DATA COMPUTING, INTERNET OF PEOPLE AND SMART CITY INNOVATION (SMARTWORLD/SCALCOM/UIC/ATC/CBDCOM/IOP/SCI), 2018, Guangzhou, China. **Proceedings...** IEEE, 2018. p.72–76.
- BORBA, C. S. de; GASPARINI, I. Quais as Melhores Maneiras de Apresentar as Recomendações para os Usuários? Um Mapeamento Sistemático da Literatura. **iSys - Revista Brasileira de Sistemas de Informação**, Rio de Janeiro, Brasil, v.12, n.4, p.36–63, 2019.

BURKE, R. Hybrid Recommender Systems: Survey and Experiments. **User Modeling and User-Adapted Interaction**, Netherlands, v.12, p.331–370, 11 2002.

CAI, D.; ZHANG, Y.; DAI, B. Learning Path Recommendation Based on Knowledge Tracing Model and Reinforcement Learning. In: INTERNATIONAL CONFERENCE ON COMPUTER AND COMMUNICATIONS (ICCC), 5., 2019, Chengdu, China. **Proceedings...** IEEE, 2019. p.1881–1885.

CAO, L.; MA, B.; ZHOU, Y.; CHEN, B. Design and Implementation of Writing Recommendation System Based on Hybrid Recommendation. **IEEE Access**, Piscataway, Nova Jersey, EUA, v.6, p.72506–72513, 2018.

CHAVARRIAGA, O.; FLORIAN-GAVIRIA, B.; P., O. S. Recommender system based on student competencies assessment results. In: COMPUTING COLOMBIAN CONFERENCE (9CCC), 9., 2014, Pereira, Colombia. **Proceedings...** IEEE, 2014. p.103–108.

CHENG, B.; ZHANG, Y.; SHI, D. Ontology-Based Personalized Learning Path Recommendation for Course Learning. In: INTERNATIONAL CONFERENCE ON INFORMATION TECHNOLOGY IN MEDICINE AND EDUCATION (ITME), 9., 2018, Hangzhou, China. **Proceedings...** IEEE, 2018. p.531–535.

COLLEY, H.; HODKINSON, P.; MALCOLM, J. **Non-formal learning**: mapping the conceptual terrain, a consultation report. Leeds: University of Leeds, 2002.

DANG, Q.-V. Implementing an Individualized Recommendation System Using Latent Semantic Analysis. In: INTERNATIONAL CONFERENCE ON INFORMATION AND EDUCATION TECHNOLOGY, 6., 2018, New York, NY, USA. **Proceedings...** ACM, 2018. p.239–243. (ICIET '18).

DURÁN, E. B.; ÁLVAREZ, M. M. Method for generating expert recommendations to advise students on ubiquitous learning experiences. In: INTERNATIONAL CONFERENCE OF THE CHILEAN COMPUTER SCIENCE SOCIETY (SCCC), 36., 2017, Arica, Chile. **Proceedings...** IEEE, 2017. p.1–8.

EPSTEIN, D.; COSTA PINHO, I. da; ACOSTA, O. C.; REATEGUI, E. Inquiry-based learning environment using intelligent tutoring system. In: FRONTIERS IN EDUCATION CONFERENCE (FIE), 2013, Oklahoma City, USA. **Proceedings...** IEEE, 2013. p.1072–1074.

FLEISCHMANN, A. M. P. **Sensibilidade à situação em sistemas educacionais na web**. 2012. Tese (Doutorado em Ciência da Computação) — PPGC, UFRGS.

FU, D.; LIU, Q.; ZHANG, S.; WANG, J. The Undergraduate-Oriented Framework of MOOCs Recommender System. In: INTERNATIONAL SYMPOSIUM ON EDUCATIONAL TECHNOLOGY (ISET), 2015, Wuhan, China. **Proceedings...** IEEE, 2015. p.115–119.

GEDDAWY, Y. E.; MIKIC-FONTE, F.; LLAMAS-NISTAL, M.; CAEIRO-RODRÍGUEZ, M. Adaptive Multi-Agent Assisting Framework for a Personal Teaching Environment. In: IEEE FRONTIERS IN EDUCATION CONFERENCE (FIE), 2019, Covington, KY, USA. **Proceedings...** IEEE, 2019. p.1–4.

GOGO, K. O.; NDERU, L.; MWANGI, R. W. Fuzzy Logic Based Context Aware Recommender for Smart E-learning Content Delivery. In: INTERNATIONAL CONFERENCE ON SOFT COMPUTING MACHINE INTELLIGENCE (ISCMI), 5., 2018, Nairobi, Kenya. **Proceedings...** IEEE, 2018. p.114–118.

GOLDBERG, D.; NICHOLS, D.; OKI, B. M.; TERRY, D. Using Collaborative Filtering to Weave an Information Tapestry. **Commun. ACM**, New York, NY, USA, v.35, n.12, p.61–70, Dec. 1992.

GOTARDO, R. A. et al. Approach to Cold-Start Problem in Recommender Systems in the Context of Web-Based Education. In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND APPLICATIONS, 12., 2013. **Proceedings...** IEEE, 2013. v.2, p.543–548.

GUNAWARDANA, A.; SHANI, G. Evaluating Recommender Systems. In: RICCI, F.; ROKACH, L.; SHAPIRA, B. (Ed.). **Recommender Systems Handbook**. Boston, MA: Springer US, 2015. p.265–308.

HASSAN, M.; HAMADA, M. Smart media-based context-aware recommender systems for learning: A conceptual framework. In: INTERNATIONAL CONFERENCE ON INFORMATION TECHNOLOGY BASED HIGHER EDUCATION AND TRAINING (ITHET), 16., 2017, Ohrid, Macedonia. **Proceedings...** IEEE, 2017. p.1–4.

HOIC-BOZIC, N.; DLAB, M. H.; MORNAR, V. Recommender System and Web 2.0 Tools to Enhance a Blended Learning Model. **IEEE Transactions on Education**, Piscataway, Nova Jersey, EUA, v.59, n.1, p.39–44, 2016.

IEEE. IEEE Standard for Learning Object Metadata. **IEEE Std 1484.12.1-2002**, Piscataway, Nova Jersey, EUA, p.1–40, 2002.

JAIN, H.; ANIKA. Applying Data Mining Techniques for Generating MOOCs Recommendations on the Basis of Learners Online Activity. In: INTERNATIONAL CONFERENCE ON MOOCS, INNOVATION AND TECHNOLOGY IN EDUCATION (MITE), 6., 2018, Hyderabad, India. **Proceedings...** IEEE, 2018. p.6–13.

JEUNEN, O. Revisiting Offline Evaluation for Implicit-Feedback Recommender Systems. In: ACM CONFERENCE ON RECOMMENDER SYSTEMS, 13., 2019, New York, NY, USA. **Proceedings...** Association for Computing Machinery, 2019. p.596–600. (RecSys '19).

KARGA, S.; SATRATZEMI, M. Mentor: A Hybrid Recommender System in Order to Support Teachers in Learning Design Authoring Process. In: INTERNATIONAL CONFERENCE ON ADVANCED LEARNING TECHNOLOGIES, 14., 2014, Athens, Greece. **Proceedings...** IEEE, 2014. p.522–523.

KITCHENHAM, B. et al. Systematic literature reviews in software engineering-A systematic literature review. **Information and Software Technology**, Netherlands, v.51, p.7–15, 01 2009.

KUMAR CHATURVEDI, A.; PELEJA, F.; FREIRE, A. **Recommender System for News Articles using Supervised Learning**. 2017. Dissertação (Mestrado em Ciência da Computação) — Universitat Pompeu Fabra, Barcelona.

LI, H.; SHI, J.; ZHANG, S.; YUN, H. Implementation of intelligent recommendation system for learning resources. In: INTERNATIONAL CONFERENCE ON COMPUTER SCIENCE AND EDUCATION (ICCSE), 12., 2017, Houston, USA. **Proceedings...** IEEE, 2017. p.139–144.

LI, H.; SUN, Y. English Education Text Recommendation Technology Based on Word Embedding. In: INTERNATIONAL CONFERENCE ON BIG DATA AND ARTIFICIAL INTELLIGENCE (BDAI), 2018, Beijing, China. **Proceedings...** IEEE, 2018. p.82–86.

LI, Y.; LI, H. MOOC-FRS: A new fusion recommender system for MOOCs. In: ADVANCED INFORMATION TECHNOLOGY, ELECTRONIC AND AUTOMATION CONTROL CONFERENCE (IAEAC), 2., 2017, Chongqing, China. **Proceedings...** IEEE, 2017. p.1481–1488.

LI, Y.; MEI, L.; WANG, J. A personalized recommendation system in E-Learning environment based on semantic analysis. In: INTERNATIONAL CONFERENCE ON NEW TRENDS IN INFORMATION SCIENCE, SERVICE SCIENCE AND DATA MINING (IS-SDM2012), 6., 2012. **Proceedings...** IEEE, 2012. p.802–807.

LIANG, Y.; CHEN, H. The research of video resource personalized recommendation system based on education website. In: INTERNATIONAL CONFERENCE ON COMPUTER SCIENCE EDUCATION, 9., 2014, Vancouver, Canada. **Proceedings...** IEEE, 2014. p.898–902.

LIN, P.; CHEN, S. Design and Evaluation of a Deep Learning Recommendation Based Augmented Reality System for Teaching Programming and Computational Thinking. **IEEE Access**, Piscataway, Nova Jersey, EUA, v.8, p.45689–45699, 2020.

LOUREIRO, S. A. **Revisão Sistemática da Literatura**. <http://vision.ime.usp.br/~acmt/revisao-sistemica-literatura.pdf>.

MALAEB, M. **Recall and Precision at k for Recommender Systems**. https://medium.com/@m_n_malaeb/recall-and-precision-at-k-for-recommender-systems-618483226c54.

MONDAL, B.; PATRA, O.; MISHRA, S.; PATRA, P. A course recommendation system based on grades. In: INTERNATIONAL CONFERENCE ON COMPUTER SCIENCE, ENGINEERING AND APPLICATIONS (ICCSEA), 2020, Gunupur, India. **Proceedings...** IEEE, 2020. p.1–5.

MONTUSCHI, P.; LAMBERTI, F.; GATTESCHI, V.; DEMARTINI, C. A Semantic Recommender System for Adaptive Learning. **IT Professional**, Piscataway, Nova Jersey, EUA, v.17, n.5, p.50–58, 2015.

MOOC-STATS. **By The Numbers: MOOCs in 2018**. <https://www.class-central.com/report/mooc-stats-2018/>.

MUHAMMAD, A. et al. Learning path adaptation in online learning systems. In: INTERNATIONAL CONFERENCE ON COMPUTER SUPPORTED COOPERATIVE WORK IN DESIGN (CSCWD), 20., 2016, USA. **Proceedings...** IEEE, 2016. p.421–426.

NADEEM, M.; STANSBURY, D.; MOONEY, S. Neural Educational Recommendation Engine (NERE). In: INTERNATIONAL CONFERENCE ON DATA MINING WORKSHOPS (ICDMW), 2018, Singapore. **Proceedings...** IEEE, 2018. p.343–348.

NETO, F. M. M.; SALES, A. F. A. A Recommendation System for Ubiquitous Learning in the Context of Formal and Informal Education. **IEEE Latin America Transactions**, Piscataway, Nova Jersey, EUA, v.13, n.4, p.1061–1067, 2015.

NOREMBERG, M. W.; AGUIAR, M. S. d.; PRIMO, T. T. **Sobre o uso de sistemas de recomendação no ensino não-formal**. <https://drive.google.com/file/d/0B5b0YQQfRS1ya2xUWTNncHNmVHAtdSDVrNTJ2LXhaSOV0Z19z/>.

OUALI, Y.; OUMAIRA, I. Reengineering ILE: towards a model for adapting the learning path. In: INTERNATIONAL CONFERENCE ON OPTIMIZATION AND APPLICATIONS (ICOA), 6., 2020, Beni Mellal, Morocco. **Proceedings...** IEEE, 2020. p.1–6.

PARYUDI, I.; C.N, S. R. Proposed intelligent e-learning system using semantic web. In: INTERNATIONAL CONFERENCE ON ADVANCED COMPUTER SCIENCE AND INFORMATION SYSTEMS, 2011, Jakarta, Indonesia. **Proceedings...** IEEE, 2011. p.133–136.

POTTS, B. A. et al. Reciprocal Peer Recommendation for Learning Purposes. In: INTERNATIONAL CONFERENCE ON LEARNING ANALYTICS AND KNOWLEDGE, 8., 2018, New York, NY, USA. **Proceedings...** ACM, 2018. p.226–235. (LAK '18).

PRIMO, T. T. **Método de representação de conhecimento baseado em Ontologias para apoiar Sistemas de Recomendação Educacionais**. 2013. Tese (Doutorado em Ciência da Computação) — PPGC, UFRGS.

PRISCO, A. et al. Using information technology for personalizing the computer science teaching. In: IEEE FRONTIERS IN EDUCATION CONFERENCE (FIE), 2017, Indianapolis, USA. **Proceedings...** IEEE, 2017. p.1–7.

PRISCO, A. et al. A Facebook chat bot as recommendation system for programming problems. In: FRONTIERS IN EDUCATION CONFERENCE (FIE), 2019, Covington, KY, USA. **Proceedings...** IEEE, 2019. p.1–5.

QIAO, Z.; GUO, J.; ZHAO, J. Research on personalized recommendation of distance education resources based on spark. In: INFORMATION TECHNOLOGY AND MECHATRONICS ENGINEERING CONFERENCE (ITOEC), 4., 2018, Chongqing, China. **Proceedings...** IEEE, 2018. p.338–342.

QOMARIYAH, N. N.; FAJAR, A. N. Recommender System for e-Learning based on Personal Learning Style. In: INTERNATIONAL SEMINAR ON RESEARCH OF INFORMATION TECHNOLOGY AND INTELLIGENT SYSTEMS (ISRITI), 2019, Yogyakarta, Indonesia. **Proceedings...** IEEE, 2019. p.563–567.

RAHMA, B. D.; KOUTHEAIR, K. M. Towards a framework for building automatic recommendations of answers in MOOCs' Discussion Forums. In: INTERNATIONAL CONFERENCE ON ICT ACCESSIBILITY (ICTA), 7., 2019, Hammamet, Tunisia. **Proceedings...** IEEE, 2019. p.1–6.

RICCI, F.; ROKACH, L.; SHAPIRA, B.; KANTOR, P. B. **Recommender Systems Handbook**. 1st.ed. Berlin, Heidelberg: Springer-Verlag, 2010.

SAITO, T.; WATANOBE, Y. Learning Path Recommender System based on Recurrent Neural Network. In: INTERNATIONAL CONFERENCE ON AWARENESS SCIENCE AND TECHNOLOGY (ICAST), 9., 2018, Fukuoka, Japan. **Proceedings...** IEEE, 2018. p.324–329.

SAMMOUR, G. et al. Semantic Web and ontologies for personalisation of learning in MOOCs. In: SEVENTH INTERNATIONAL CONFERENCE ON INTELLIGENT COMPUTING AND INFORMATION SYSTEMS (ICICIS), 2015, Cairo, Egypt. **Proceedings...** IEEE, 2015. p.183–186.

SCHMIDT, A.; BEIGL, M.; GELLERSEN, H.-W. There is more to context than location. **Computers & Graphics**, Netherlands, v.23, n.6, p.893 – 901, 1999.

SHI, R.; MAO, L.; HU, C.; LI, S. A Recommendation Method of Educational Resources Based on Knowledge Structure. In: INTERNATIONAL CONFERENCE ON COMPUTER AND COMMUNICATIONS (ICCC), 4., 2018, Chengdu, China. **Proceedings...** IEEE, 2018. p.2547–2552.

STRICKROTH, S.; PINKWART, N. High Quality Recommendations for Small Communities: The Case of a Regional Parent Network. In: SIXTH ACM CONFERENCE ON RECOMMENDER SYSTEMS, 2012, New York, NY, USA. **Proceedings...** ACM, 2012. p.107–114. (RecSys '12).

SUN, G. et al. (WIP) Evaluation of a Cloud-Based System for Delivering Adaptive Micro Open Education Resource to Fresh Learners. In: INTERNATIONAL CONFERENCE ON CLOUD COMPUTING (CLOUD), 11., 2018, San Francisco, CA, USA. **Proceedings...** IEEE, 2018. p.586–589.

TORRE, I.; TORSANI, S. A Recommender System as a Support and Training Tool. In: INTERNATIONAL CONFERENCE ON SIGNAL-IMAGE TECHNOLOGY INTERNET-BASED SYSTEMS (SITIS), 12., 2016, Naples, Italy. **Proceedings...** IEEE, 2016. p.773–780.

UNESCO. **Education 2030**: Incheon Declaration and Framework for Action for the implementation of Sustainable Development Goal 4.

WAI, L. Data science at UdeMy: Agile experimentation with algorithms. In: FUTURE TECHNOLOGIES CONFERENCE (FTC), 2016, San Francisco, CA, USA. **Proceedings...** IEEE, 2016. p.355–360.

YANG, D.; ZHANG, D.; ZHENG, V. W.; YU, Z. Modeling User Activity Preference by Leveraging User Spatial Temporal Characteristics in LBSNs. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, Piscataway, Nova Jersey, EUA, v.45, n.1, p.129–142, 2015.

ZHANG, H. et al. A hybrid recommendation approach for network teaching resources based on knowledge-tree. In: CHINESE CONTROL CONFERENCE, 33., 2014, Nanjing, China. **Proceedings...** IEEE, 2014. p.3450–3455.

ZHANG, M.; LIU, S.; WANG, Y. STR-SA: Session-based Thread Recommendation for Online Course Forum with Self-Attention. In: GLOBAL ENGINEERING EDUCATION CONFERENCE (EDUCON), 2020, Porto, Portugal. **Proceedings...** IEEE, 2020. p.374–381.

ZHAO, J.; BHATT, C.; COOPER, M.; SHAMMA, D. A. Flexible Learning with Semantic Visual Exploration and Sequence-Based Recommendation of MOOC Videos. In: CHI CONFERENCE ON HUMAN FACTORS IN COMPUTING SYSTEMS, 2018., 2018, New York, NY, USA. **Proceedings...** ACM, 2018. p.329:1–329:13. (CHI '18).

ZIQI, L. et al. A K-medoids algorithm based method to alleviate the data sparsity in collaborative filtering. In: CHINESE CONTROL CONFERENCE (CCC), 34., 2015, Hangzhou, China. **Proceedings...** IEEE, 2015. p.4974–4979.