

UNIVERSIDADE FEEVALE

DIEGO FELIPE REIDEL DA SILVA

PROPOSTA DE UM SISTEMA DE RECOMENDAÇÃO PARA O
HEALTH SIMULATOR

Novo Hamburgo

2017



DIEGO FELIPE REIDEL DA SILVA

PROPOSTA DE UM SISTEMA DE RECOMENDAÇÃO PARA O
HEALTH SIMULATOR

Trabalho de Conclusão de Curso
apresentado como requisito parcial
à obtenção do grau de Bacharel em
Ciência da Computação pela
Universidade Feevale

Orientador: Paulo Ricardo Muniz Barros

Coorientador: Marta Rosecler Bez

Novo Hamburgo

2017

AGRADECIMENTOS

Gostaria de agradecer a todos que estiveram ao meu lado durante a realização deste trabalho e especialmente...

... aos meus pais, por me mostrarem desde cedo a importância do trabalho e empenho.

... à minha família, especialmente à minha irmã, pelo apoio e compreensão sempre.

... à Carol, por suportar comigo os momentos de incerteza durante este e outros períodos.

... aos meus orientadores Paulo e Marta. Muito obrigado por seus conselhos e pela dedicação.

... a todos os professores, colegas e amigos destes 6 anos: muito obrigado por compartilharem comigo o seu conhecimento.

RESUMO

Simuladores são ferramentas eficazes para promover a integração entre a teoria e a prática no ensino superior na área da saúde. Estes sistemas disponibilizam um ambiente bastante próximo ao real e, assim, mostram-se como um recurso importante para o aprendizado do aluno, sem os riscos potenciais associados à prática clínica. Ainda, os simuladores do tipo paciente virtual permitem que o estudante repita a atividade e explore novas soluções para um mesmo caso de estudo e, dessa forma, reforce a precisão e a retenção do conhecimento adquirido. O Health Simulator é um simulador do tipo paciente virtual que se encontra em desenvolvimento na Universidade Feevale e que busca desenvolver o raciocínio clínico e diagnóstico do aluno da área da saúde. No Health Simulator, o professor pode criar diversos casos clínicos que serão resolvidos pelo aluno. Este trabalho objetiva desenvolver um sistema de recomendação de casos clínicos e materiais de estudo que favoreçam o aprendizado do aluno no Health Simulator, fazendo-se uso de estratégias de recomendação modernas que possam ser aplicadas à área da educação em saúde. A função de um sistema de recomendação é indicar ao usuário ativo o grupo de itens que possa ser de seu maior interesse dentro de um grupo maior de itens recomendáveis. Ferramentas desse tipo vem sendo utilizadas em sistemas de áreas diversas e é possível encontrar variadas técnicas para recomendação, cada qual com suas características distintas. O presente trabalho é uma pesquisa bibliográfica e experimental, de natureza aplicada e abordagem qualitativa. O experimento desenvolvido envolve a implementação das técnicas de recomendação do tipo filtro colaborativo e baseada em conteúdo, com outros três métodos híbridos tendo sido aplicados. A escolha destas técnicas se deu após o levantamento bibliográfico que apontou que estas são as mais utilizadas pela comunidade acadêmica. Para permitir a implantação das técnicas ao Health Simulator, diversas alterações ao simulador se mostraram necessárias. Posterior à implementação, o sistema foi avaliado qualitativamente com o uso de técnicas de acurácia da predição e da classificação. Os resultados mostraram valores satisfatórios para o método de filtro colaborativo enquanto apontaram que alterações ainda são necessárias ao algoritmo baseado em conteúdo utilizado. Espera-se que com o crescimento do uso do Health Simulator, novos casos clínicos sejam inseridos, tornando o simulador bastante abrangente. Por isso a importância de um sistema de recomendação que deve não somente mostrar bons casos de estudo a um usuário, mas também guiá-lo pelo simulador, proporcionando assim, maior oportunidade de aprendizado ao aluno.

Palavras-chave: Sistema de recomendação. Simuladores. Paciente virtual. Health Simulator.

ABSTRACT

Simulators are effective tools to promote integration between theory and practice in health care related college courses. This kind of system offers an environment that is close to the one faced by medical professionals in their daily activities, therefore are a valuable resource during the learning process. In addition, a simulator diminishes potential risks inherent to the clinical practice and allows students to repeat and explore different results to the same activity, increasing knowledge retention and precision. The Health Simulator is a virtual patient under development at Universidade Feevale that seeks to improve the student's diagnostic and clinical reasoning. Using the Health Simulator, a teacher may create multiple clinical cases to be solved by the students. This research aims to develop a recommender system to be used within the Health Simulator to point clinical cases and study materials that may help the student in the learning process. The goal of a recommendation system is to find among a large group of items those that better fit the user needs and preferences. Software like this has been adapted to different areas and many techniques to implement a recommendation engine have been developed. The present work is a bibliographic and experimental research, with applied nature and qualitative approach. The developed experiment involves the implementation of two recommendation techniques – collaborative filters and content based filters –, as well as three hybrid methods. The bibliographical research performed pointed that those are the most commonly used techniques, leading the authors to make that choice. To allow the algorithms to be used in the Health Simulator, many changes were necessary. Later, the system was qualitatively evaluated, using predict and classification accuracy metrics. Results show satisfactory values on the collaborative filters, despite the fact that improvements are necessary on the content based algorithm. Hopefully, as the systems grows, new clinical cases will be included, demanding a recommender system that not only finds good study materials, but also guides the student thought the process of solving a case.

Keywords: Recommender Systems. Simulators. Virtual Patient. Health Simulator.

LISTA DE FIGURAS

Figura 1.1 - Um caso clínico no SimDeCS	18
Figura 1.2 - Cadastro de casos clínicos no SIACC	20
Figura 1.3 - Estrutura do HS	21
Figura 1.4 - Exemplo de cenário para consultório Classe C	22
Figura 1.5 - Modelos de enfermeiras e médicos nas etnias branco, negro e amarelo ...	23
Figura 1.6 - BE com uma rede bayesiana para doação de sangue	24
Figura 1.7 - Cadastro de caso clínico na interface de administração	25
Figura 2.1 - Classificação dos sistemas de recomendação.....	29
Figura 2.2 - Uso de folksonomia para classificação de imagens no Instagram	31
Figura 2.3 - Avaliações do usuário em diversos sistemas da Internet	40
Figura 3.1 - Explicação para recomendação na Amazon.....	51
Figura 3.2 - Explicação para recomendação no Netflix.....	51
Figura 4.1 – Modelo ER original simplificado	60
Figura 4.2 - Modelo de usuário detalhado	61
Figura 4.3 - O modelo de usuário no HS	62
Figura 4.4 – Modelo ER resultante das alterações ao BD.....	62
Figura 4.5 - Cabeçalho e conteúdo para o arquivo de filmes.....	65
Figura 4.6 - Cabeçalho e conteúdo para o arquivo de avaliações	66
Figura 4.7 - Cabeçalho e conteúdo para o arquivo de <i>tags</i>	66
Figura 4.8 - Mapeamento entre dataset e BD.....	67
Figura 4.9 - Matrizes iniciais para a construção do perfil.....	68
Figura 4.10 - Perfil resultante para um usuário no HS.....	70
Figura 4.11 - Similaridade para usuários e itens	71
Figura 4.12 - Resultado das métricas de acurácia da predição	74

Figura 4.13 - Resultado das métricas de acurácia da classificação I	76
Figura 4.14 - Resultado das métricas de acurácia da classificação II	77

LISTA DE TABELAS

Tabela 1 - Matriz de confusão para avaliar um RS.....	42
---	----

LISTA DE QUADROS

Quadro 1.1 - Estratégias disponíveis no Diagrama de Influência.....	19
Quadro 3.1 - Tarefas de um SR de propósito geral.....	45
Quadro 3.2 - Tarefas adicionais em um SR voltado à educação.....	47
Quadro 3.3 - Motivos para prover explicações em um SR	50
Quadro 3.4 - Avaliação de diversos métodos de combinação	54
Quadro 4.1 - <i>Datasets</i> abertos para SR.....	63

LISTA DE ABREVIATURAS E SIGLAS

BD	Banco de Dados
BE	<i>Bayes Editor</i>
CBF	<i>Content-Based Filters</i>
CF	<i>Collaborative Filtering</i>
FNR	<i>False Negative Rate</i>
FPR	<i>False Positive Rate</i>
FROAC	<i>Federación de Repositorios de Objetos de Aprendizaje Colombia</i>
HS	Health Simulator
KBF	<i>Knowledge-Based Filters</i>
MAE	<i>Mean Absolute Error</i>
MSE	<i>Mean Squared Error</i>
PV	Paciente Virtual
RB	Rede Bayesiana
REST	<i>Representational State Transfer</i>
RMSE	<i>Root Mean Squared Error</i>
SGBD	Sistema Gerenciador de Banco de Dados
SIACC	Sistema Interdisciplinar de Análise de Casos Clínicos
SimDeCS	Simulador Inteligente para a Tomada de Decisão em Casos de Saúde
SR	Sistema de Recomendação
SUS	Sistema Único de Saúde
TF-IDF	<i>Term Frequency – Inverse Document Frequency</i>
TNA	<i>True Negative Accuracy</i>
TNR	<i>True Negative Rate</i>
TPA	<i>True Positive Accuracy</i>
TPR	<i>True Positive Rate</i>
OA	Objeto de Aprendizagem

SUMÁRIO

INTRODUÇÃO.....	13
1 SIMULADORES NO ENSINO NA ÁREA DA SAÚDE.....	16
1.1 Simulador Inteligente para a Tomada de Decisão em Casos de Saúde	17
1.2 Sistema Interdisciplinar de Análise de Casos Clínicos.....	19
1.3 Health Simulator	20
1.3.1 O <i>front-end</i> do Health Simulator	22
1.3.2 O back-end do Health Simulator.....	23
2 UMA INTRODUÇÃO AO ESTUDO DE SISTEMAS DE RECOMENDAÇÃO.....	27
2.1 Técnicas de recomendação	29
2.1.1 Sistemas de recomendação baseados em conteúdo.....	30
2.1.2 Folksonomia.....	31
2.1.3 Sistemas de recomendação colaborativos	32
2.1.4 Sistemas de recomendação demográficos.....	33
2.1.5 Sistemas de recomendação baseados em conhecimento.....	34
2.1.6 Sistemas de recomendação baseados na utilidade	34
2.1.7 Sistemas de recomendação híbridos	34
2.2 Desafios no estudo de Sistemas de Recomendação.....	36
2.3 Coleta de dados	38
2.4 Métricas para avaliação do SR.....	40
2.4.1 Métricas de acurácia da predição	40
2.4.2 Métricas de acurácia da classificação	41
2.4.3 Métricas de acurácia da ordenação	44
3 SR EM PLATAFORMAS VOLTADAS À EDUCAÇÃO.....	45
3.1 A importância da transparência	49
3.2 Trabalhos relacionados – SR no auxílio à educação.....	52
3.2.1 Incorporando a avaliação de bons alunos em CBF	52
3.2.2 Recomendação de objetos de aprendizagem.....	54
3.2.3 SAPO Campus: um SR para uma plataforma colaborativa	56
3.2.4 Filtros colaborativos para recomendação de objetos de aprendizagem	57
4 O DESENVOLVIMENTO DO SISTEMA DE RECOMENDAÇÃO	59
4.1 A respeito do armazenamento dos dados.....	59
4.1.1 O modelo do usuário	60

4.2 A respeito dos dados escolhidos para o desenvolvimento do SR.....	63
4.2.1 Detalhando a base de dados escolhida	64
4.2.2 A inserção dos dados no HS	67
4.3 A construção do perfil do usuário.....	67
4.4 A construção do perfil para itens	70
4.5 A seleção do grupo de vizinhos	70
4.6 As técnicas de recomendação desenvolvidas.....	71
4.6.1 Filtro colaborativo baseado no usuário	72
4.6.2 Recomendação baseada em conteúdo	72
4.6.3 Método híbrido adaptativo	72
4.6.4 Método híbrido misto.....	73
4.6.5 Método híbrido da intersecção dos conjuntos.....	73
4.7 Resultados obtidos	73
CONCLUSÃO	78
REFERÊNCIAS BIBLIOGRÁFICAS.....	81

INTRODUÇÃO

Durante o curso, ou mesmo nos primeiros anos atuando com a prática clínica, estudantes da área da saúde podem ter dificuldades de associar os conhecimentos teóricos à prática, mesmo que os estudos em sala de aula envolvam uma grande carga de atividades (HIGGS et al., 2008; SITTNER, 2009). Os simuladores, como os desenvolvidos por Holzinger et al. (2009) e Barros et al. (2012), compõem ferramentas efetivas para minimizar tais problemas, uma vez que se apresentam como uma maneira segura para que estudantes pratiquem os temas abordados durante o curso (SMITH, 2009). Essas ferramentas permitem um ambiente de prática similar ao real, sem apresentar riscos ao estudante ou paciente, promovendo, assim, a integração entre a teoria e a prática (ZIV; BEN-DAVID; ZIV, 2005).

O Health Simulator é um simulador do tipo Paciente Virtual, construído na Universidade Feevale, na forma de um jogo sério. Seu objetivo é “desenvolver o raciocínio clínico e o diagnóstico do aluno da área da saúde” (BEZ et al., 2015, p. 60). No simulador, a modelagem do conhecimento é elaborada a partir de um modelo probabilístico na forma de uma rede bayesiana (BEZ, 2012), que deve ser construída por um especialista com o auxílio de uma diretriz clínica. Com base nisto, o docente é capaz de elaborar diversos casos clínicos para que sejam utilizados pelos alunos como ferramenta de estudo e aprendizagem (HELWANGER; ROLIM; BARROS, 2015).

O objetivo deste trabalho foi desenvolver um sistema de recomendação (SR) de casos clínicos e materiais de estudo que favoreçam o aprendizado do aluno no Health Simulator, fazendo-se uso de estratégias de recomendação modernas que possam ser aplicadas à área da educação em saúde. A função de um SR é indicar ao usuário ativo o grupo de objetos que possa ser de seu maior interesse dentro de um grupo maior de itens recomendáveis. Tal indicação pode se dar na forma de uma recomendação simples ou como a predição do valor da utilidade de um item (FAZIO, 2013). No simulador em desenvolvimento, cada caso clínico ou material adicional de estudo é considerado um item recomendável.

Quando há sobrecarga de informação ou materiais em um sistema, um usuário pode acabar sendo prejudicado ao procurar por aquilo que lhe é de maior utilidade, perdendo tempo com a busca ou deixando de encontrar os objetos de maior relevância devido à ordem em que estes lhe são dispostos. Um SR busca minimizar esses problemas, aprendendo as preferências do usuário e lhe apresentando imediatamente aquilo que se mostra mais importante (LOPES,

2012). O SR proposto tem como principal objetivo auxiliar o aluno no seu processo de aprendizado, fornecendo ao aluno aqueles casos clínicos que sejam de seu maior interesse e ajudá-lo, dessa forma, na construção de seu conhecimento.

No primeiro capítulo deste trabalho, o tema dos simuladores aplicados à saúde foi abordado, com uma apresentação de dois simuladores já desenvolvidos e aplicados e o Health Simulator, que se encontra em desenvolvimento na Universidade Feevale. Este estudo mostrou-se importante para levantar conhecimento a respeito da área em que o sistema proposto será inserido, uma vez que é necessário que ele seja adequado ao ambiente do simulador. Neste capítulo, o estudo de Botezatu, Hult e Fors (2010) aponta que alunos que fazem uso de um simulador do tipo paciente virtual acreditam que o conteúdo disponível e as avaliações realizadas pela ferramenta devem condizer com a prática clínica que exercerão no futuro.

No capítulo seguinte, os sistemas de recomendação foram introduzidos. Nessa etapa, abordam-se assuntos como as diferentes técnicas utilizadas pela comunidade acadêmica, os desafios da área, os métodos para a coleta dos dados e as métricas utilizadas para avaliar a qualidade das recomendações prestadas. O conhecimento levantado no Capítulo 2 serviu como base para a construção e avaliação dos sistemas de recomendação construídos.

Já no terceiro capítulo, enfocaram-se os sistemas de recomendação aplicados à educação, apresentando-se as principais diferenças entre os algoritmos utilizados nessa área e os de propósito geral. Em adição, algumas plataformas de educação que utilizam recomendação foram apresentadas, buscando levantar conhecimento sobre as técnicas empregadas. Manouselis et al. (2010) mostrou que os objetivos de um SR para educação podem diferir das soluções utilizadas nas demais áreas, uma vez que os sistemas de educação podem fazer uso de recursos que não se fazem necessários em outras aplicações.

Por fim, o último capítulo apresenta o desenvolvimento realizado. São apresentados os algoritmos de filtro colaborativo e baseado em conteúdo, bem como as técnicas híbridas mista, adaptativa e da intersecção dos conjuntos. Além disso, as alterações necessárias ao Health Simulator são também descritas. Para todas as técnicas propostas, as métricas de avaliação apresentadas no Capítulo 2 foram calculadas.

Salienta-se que como o Health Simulator é ainda uma plataforma em desenvolvimento, não foi possível contar com dados reais de usuários do sistema. Para permitir o desenvolvimento deste trabalho, uma base de dados aberta foi utilizada (os detalhes são apresentados também no

Capítulo 4). Desta forma, ressalta-se que é necessário continuar o desenvolvimento dos sistemas de recomendação uma vez que tais dados estejam disponíveis.

1 SIMULADORES NO ENSINO NA ÁREA DA SAÚDE

Estudantes de nível superior da área da saúde, durante o curso ou ainda nos primeiros anos de prática clínica, podem ter dificuldades de associar os conhecimentos teóricos à prática, mesmo quando há uma grande carga de estudos em sala de aula (HIGGS et al., 2008; SITTNER, 2009). Tsuji e Silva (2010) afirmam que há a necessidade da prática de atividades de dificuldade crescente desde o início do curso, visando a qualidade da educação. Neste contexto, para a educação em saúde, o estudo de casos clínicos é uma importante ferramenta para desenvolver as competências e o pensamento crítico dos estudantes. Entretanto, Rocha (2013) aponta dificuldades para o uso de pacientes reais nesse método de aprendizagem, como a possibilidade de um paciente se sentir desconfortável ao ser avaliado por alunos sem experiência ou a chance de que o grande número de alunos em uma turma torne a prática pouco proveitosa.

Os simuladores, como os desenvolvidos por Holzinger et al. (2009) e Barros et al. (2012), têm se mostrado como uma ferramenta efetiva para minimizar tais problemas, uma vez que se apresentam como uma maneira segura para estudantes articularem os estudos da sala de aula com a realidade da área da saúde (SMITH, 2009). Para Banks et al. (2009, p. 3), a simulação pode ser definida como a reprodução da operação de um processo ou sistema do mundo-real, que pode ser realizada por um computador ou manualmente. Em qualquer dos casos, a simulação requer a criação e observação de um histórico artificial do sistema, buscando realizar inferências a respeito das características da operação do sistema real. Recursos educacionais como este vem sendo aplicados em diversas áreas, como física (MACEDO; DICKMAN; ANDRADE, 2012; SOUZA FILHO, 2010), farmácia (PARK; SUMMONS, 2013), enfermagem (MARTINS et al., 2014) e química (LIMA; VARELO; NASCIMENTO, 2012) em todos os níveis de ensino.

Um simulador do tipo paciente virtual (PV) pode ser definido como um *software* interativo que simula cenários clínicos reais, onde o estudante realiza o papel de profissional da saúde ao realizar atividades como a obtenção do histórico médico de um paciente, a solicitação de exames e a tomada de decisões diagnósticas e terapêuticas (IMISON; HUGHES, 2008; ROCHA, 2013). Além de promover a integração entre a teoria e a prática, essas ferramentas têm a vantagem de permitir um ambiente de prática similar ao real, sem apresentar qualquer risco ao estudante ou paciente ou mesmo à instituição de ensino em saúde (ZIV; BEN-DAVID; ZIV, 2005). Estudos mostram ainda que tais recursos educacionais incentivam os alunos a buscar por novas maneiras de solucionar um caso de estudo; diminuem a interferência de

elementos externos ao problema em estudo; permitem que os alunos repitam a atividade sem que erros causem riscos à saúde de um paciente; reforçam a precisão e a retenção do conhecimento (BOTEZATU; HULT; FORS, 2010).

Os próximos tópicos abordam simuladores do tipo PV, com o objeto de identificar as principais funcionalidades desses sistemas. Em 1.1 é apresentado o Simulador Inteligente para a Tomada de Decisão em Casos de Saúde (SimDeCS) enquanto em 1.2 explana-se a respeito do Sistema Interdisciplinar de Análise de Casos Clínicos (SIACC). Por fim, no tópico 1.3 o Health Simulator (HS) é introduzido. Como o objeto deste trabalho é desenvolver um sistema de recomendação¹ de casos clínicos e materiais de estudo que favoreçam o aprendizado do aluno no HS, é natural que este tópico contenha detalhes a respeito da arquitetura da solução, bem como os requisitos que ela busca atender.

1.1 Simulador Inteligente para a Tomada de Decisão em Casos de Saúde

O simulador de PV SimDeCS foi desenvolvido na forma de um jogo sério e utiliza três formalismos de inteligência artificial (redes bayesianas, diagrama de influência e sistemas multiagentes) e um oriundo da pedagogia (estratégia pedagógica), a fim de proporcionar uma experiência que leve ao aprendizado por parte do aluno. Profissionais das áreas de informática, educação e saúde participaram da criação do sistema, que foi posteriormente avaliado no COBEM 2012². O aluno, no SimDeCS, pode realizar a avaliação de diversos casos clínicos e, com o apoio do simulador, aperfeiçoar as habilidades e competências necessárias para a prática do diagnóstico (BARROS et al., 2012; BEZ et al., 2014). A Figura 1.1 mostra como um caso clínico é apresentado ao aluno no SimDeCS.

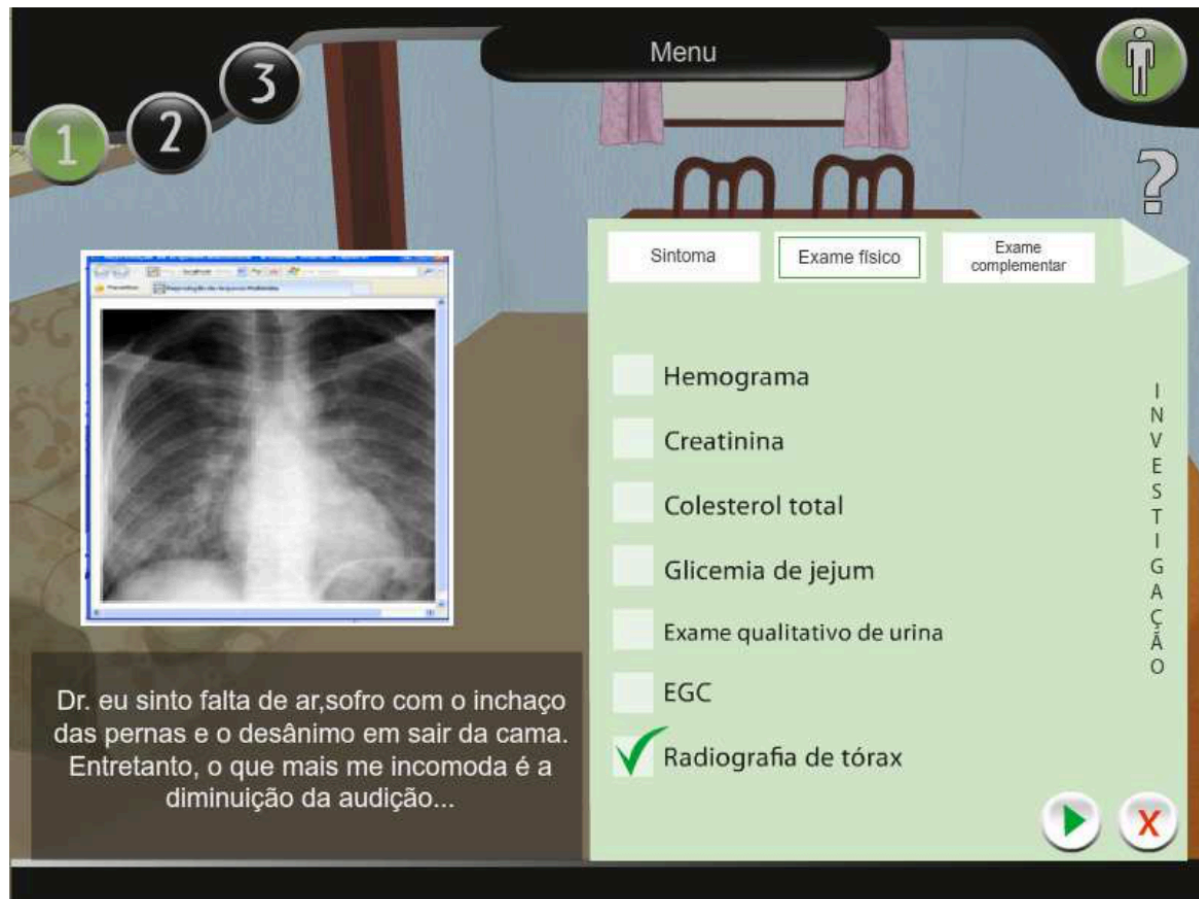
No simulador, uma representação do conhecimento, na forma de uma rede bayesiana (RB), é construída por um especialista, tornando-se disponível para o acesso dos docentes, que podem, então, criar casos clínicos e disponibilizá-los aos alunos. Para a criação de um caso, o professor deve informar dados a respeito das etapas de investigação, diagnóstico e conduta, que são armazenados em um banco dados, juntamente com outras informações a respeito do caso clínico. Sinais e sintomas, históricos e os exames físicos e complementares são armazenados como nodos da rede bayesiana. Para a realização da investigação, o professor deve cadastrar perguntas, que quando utilizadas pelo aluno, farão com que o sistema acesse a rede bayesiana

¹ O tema de sistemas de recomendação é abordado no Capítulo 2

² Congresso Brasileiro de Educação Médica: <http://cobem.com.br/>

e verifique a probabilidade da ocorrência daquele nodo em um determinado momento (BARROS et al., 2012; BEZ; VICARI; FLORES, 2012; BEZ et al., 2014).

Figura 1.1 - Um caso clínico no SimDeCS



Fonte: Barros et al. (2012, p.8)

O aluno é acompanhado, durante a execução do caso clínico, por um agente chamado de Aprendiz, que informa um segundo agente, chamado de Mediador, a respeito das decisões tomadas pelo estudante. Essas informações são propagadas em um diagrama de influências, que retorna uma estratégia pedagógica indicada ao aluno (BEZ et al., 2012). Confiança e credibilidade são dois aspectos do comportamento do aluno avaliados e utilizados para a decisão da estratégia pedagógica a ser utilizada. O primeiro aspecto é informado pelo aluno em quatro momentos durante a execução de um caso. Já a credibilidade é informada pelo Aprendiz, que utiliza variáveis coletadas durante a execução da simulação para calculá-la (BARROS et al., 2012; BEZ; VICARI; FLORES, 2012; BEZ et al., 2014). Com base nessas informações, a estratégia é definida de acordo com o diagrama de influências representado no Quadro 1.1.

Quadro 1.1 - Estratégias disponíveis no Diagrama de Influência

		CREDIBILIDADE		
		ALTA	MÉDIA	BAIXA
CONFIANÇA	ALTA	Ampliação	Contestação	Contestação
	MÉDIA	Comprovação	Contestação	Orientação
	BAIXA	Apoio	Apoio	Orientação

Fonte: adaptado de Bez et al. (2012)

1.2 Sistema Interdisciplinar de Análise de Casos Clínicos

O SIACC é um simulador de PV que trabalha com arquivos textuais, imagens, vídeos, sons, animações e diversos outros tipos de mídias. Duas fases contemplam o processo de criação no simulador – cadastro de informações e montagem do caso – sendo a primeira dividida em outras 7 etapas, apresentadas na sequência (SEBASTIANI et al., 2014):

- Anamnese, onde os dados do paciente são informados, incluindo queixas e histórico médico;
- A avaliação física realizada é informada, sendo possível incluir arquivos de diversos formatos;
- Hipóteses diagnósticas são cadastradas, indicando as linhas de investigação que o aluno poderá seguir;
- Exames complementares, onde é possível informar qualquer exame complementar realizado;
- Um diagnóstico é apontado;
- Tratamentos são indicados;
- Desfechos, onde o término para o caso é descrito.

Questões previamente cadastradas podem ser incluídas em um caso clínico, podendo elas ser de múltipla escolha ou de escolha simples. Na montagem do caso, o docente escolhe a maneira como as informações cadastradas serão apresentadas e, então, o sistema flexibiliza a

apresentação, buscando uma melhor experiência para o aluno. Em adição, o sistema ainda possibilita a criação de múltiplos caminhos a serem seguidos em um caso, através da inserção de desvios condicionais. O objetivo é permitir ao professor uma maneira de criar casos clínicos que indiquem ao aluno que ele está tomando o caminho errado, dando tempo hábil para que ele corrija os erros e ainda resolva o caso clínico com sucesso (SEBASTIANI et al., 2014). A Figura 1.2 apresenta a tela de cadastro de casos clínicos no SIACC.

Figura 1.2 - Cadastro de casos clínicos no SIACC



Fonte: Sebastiani et al. (2014, p. 669)

O sistema foi avaliado por 20 alunos da disciplina de Nefrologia, do curso de Medicina, que apontaram um índice de aceitação de 4,289 (em uma escala de 1 – 5). 95% dos participantes afirmaram que o exercício motiva e permite a concentração, enquanto 38% afirmaram sentirem-se obrigados a avançar no caso, sem compreender completamente o conteúdo (SEBASTIANI et al., 2014).

1.3 Health Simulator

O HS é um simulador do tipo PV construído na Universidade Feevale, no Brasil, na forma de um jogo sério. Seu objetivo é “desenvolver o raciocínio clínico e o diagnóstico do aluno da área da saúde” (BEZ et al., 2015, p. 60) – beneficiando-se de todas as vantagens de

um simulador – e foi projetado para ser utilizado como um recurso adicional à aprendizagem dos alunos. O seu ambiente oferece situações corriqueiras da área da saúde, removendo, porém, os riscos usuais dessas atividades. Portanto, o HS proporciona maior segurança para que o aluno aplique seus conhecimentos e, assim, venha a aprender o raciocínio clínico. Dessa forma, o aluno terá maior confiança e precisão quando defrontado com uma situação real (MELLO; STAHNKE; BEZ, 2015).

A equipe de desenvolvimento do simulador é interdisciplinar, contando com profissionais da medicina, informática, design e jogos digitais (LIMA et al., 2015). Devido às diversas tecnologias utilizadas para a construção do simulador, foi preciso dividir sua arquitetura em duas áreas. A primeira realiza a interface com o aluno e é apresentada na forma de um jogo sério, para qual se deu o nome de *front-end*. Já o *back-end*, utilizado como um repositório das informações necessárias para execução do jogo, é dividido em outras 3 sessões, apresentadas em 1.3.2 (HELWANGER; ROLIM; BARROS, 2015). A estrutura do HS é apresentada na Figura 1.3 e cada um dos itens é explicado na sequência.

Figura 1.3 - Estrutura do HS



Fonte: elaborado pelos autores

1.3.1 O *front-end* do Health Simulator

O *front-end* do HS é o ambiente do aluno, que foi construído de acordo com a filosofia e os princípios ágeis do desenvolvimento de software e conta com diversos componentes de arte. O formato utilizado é o de um jogo sério, com cenários e personagens que remetem ao cotidiano da área da saúde. Assim, os modelos tridimensionais desenvolvidos para o *front-end* incluem objetos que representam os ambientes e profissionais da saúde, criados na *engine* Unity (HECKEL et al., 2015; LIMA et al., 2015; MELLO; STAHNKE; BEZ, 2015).

Os cenários incluem consultórios e hospitais de classe A, B ou C, residências e um hospital do Sistema Único de Saúde (SUS). O processo de desenvolvimento iniciou-se com a criação de objetos necessários para a montagem de um cenário hospitalar (macas, mesas de atendimento, cadeiras, equipamentos, etc.). Esses objetos são então reutilizados em diversas texturas diferentes, formando cenários distintos, sem que seja necessário desenvolver todos os itens novamente. A Figura 1.4 mostra um dos cenários já desenvolvidos no *front-end* do HS.

Figura 1.4 - Exemplo de cenário para consultório Classe C



Fonte: Mello, Stahnke e Bez (2015, p. 5)

Quanto aos personagens, quatro tipos, de ambos os gêneros e nas etnias parda, branca, negra, índia e amarela, foram desenvolvidos: médicos, pacientes, enfermeiros e dentistas. Os personagens ainda variam em idade (bebês, crianças, adolescentes – só para pacientes – adultos e idosos) e biotipo (magro, normal ou obeso). Dessa forma, a categoria de paciente conta,

individualmente, com aproximadamente 260 modelos (HECKEL et al., 2015; MELLO; STAHNKE; BEZ, 2015). A Figura 1.5 apresenta alguns dos modelos de personagens já desenvolvidos no simulador.

Figura 1.5 - Modelos de enfermeiras e médicos nas etnias branco, negro e amarelo



Fonte: Mello, Stahnke e Bez (2015, p.5)

1.3.2 O *back-end* do Health Simulator

O *back-end* é responsável por questões estruturais, como a coleta e manutenção dos dados necessários para o funcionamento do jogo. Essa estrutura foi dividida em três módulos (modelagem do conhecimento, interface de administração e serviço de comunicação), cada um com suas responsabilidades. Esses módulos são apresentados na sequência.

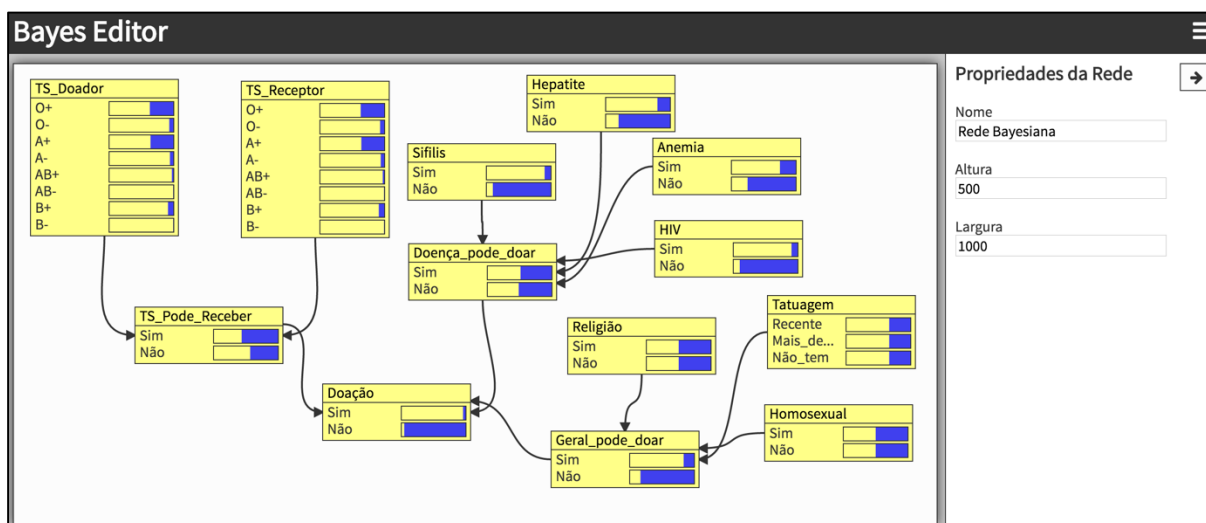
1.3.2.1 Modelagem do conhecimento

No HS, o papel de realizar a modelagem do conhecimento necessário para o correto funcionamento do jogo sério é de um especialista da saúde. Para tal, o profissional pode fazer uso das diretrizes clínicas, “uma forma sistemática de orientação e delimitação do conteúdo, a ser desenvolvida a partir de evidências” (HELWANGER; ROLIM; BARROS, 2015, p. 4). O diagnóstico médico é um processo que envolve incertezas, no qual um profissional – o médico – analisa sinais e sintomas que indicam uma determinada probabilidade de um indivíduo portar uma doença. Geralmente os sintomas não apontam uma única causa, mas sim, a chance de ocorrência de uma enfermidade. Para situações como essa, é necessário fazer uso de uma técnica que aponte o grau de confiança em cada um dos possíveis resultados (MARQUES; DUTRA, 2002; NILSSON, 1998; RUSSELL; NORVIG, 1995). Uma das maneiras de

representar uma diretriz clínica – e o processo de diagnóstico – é através da utilização de uma RB, o que é adotado na implementação do simulador (BEZ, 2012).

Uma RB é construída na forma de um grafo acíclico dirigido, onde cada variável é representada por um nodo e as relações de independência condicional são representadas pela topologia do grafo. Já as arestas representam as relações de causa e efeito entre as variáveis. Há ainda a presença de uma tabela com a distribuição das probabilidades condicionais para cada variável, levando-se em conta apenas a influência dos pais diretos de cada nodo (MARQUES; DUTRA, 2002; PINHEIRO et al., 2015; RUSSELL; NORVIG, 1995). O HS conta com seu editor próprio para a criação das redes bayesianas, o Bayes Editor (BE). Embora existam outros *softwares* disponíveis para a criação e edição de RB, há relatos de que esses podem ser demasiado complexos, trazendo dificuldades para a utilização no ensino em saúde (MARONI, 2013). Dessa forma, o BE tem como objetivo “criar um editor de redes bayesianas com foco em usabilidade que possa ser empregado em diferentes aplicações de diferentes domínios”. A Figura 1.6 mostra uma RB para um procedimento de doação de sangue, criada por alunos do grupo de pesquisa Computação Aplicada, da Universidade Feevale.

Figura 1.6 - BE com uma rede bayesiana para doação de sangue



Fonte: elaborado pelos autores

1.3.2.2 Interface de administração

A interface de administração é uma ferramenta web utilizada para a elaboração de casos clínicos por parte do professor, fazendo uso da diretriz clínica. Todas as telas foram pensadas levando em conta uma interface simples, para facilitar a utilização do sistema (HELWANGER;

ROLIM; BARROS, 2015). Nesta interface, o docente pode localizar os sinais e sintomas apresentados na RB, acessar e editar históricos médicos do paciente ou listar exames físicos e complementares. Ainda, conforme seleção dessas variáveis, o sistema deve considerar as probabilidades apontadas na RB para informar o resultado de um caso clínico, apontando diagnósticos e condutas (LIMA et al., 2015). A Figura 1.7 mostra a tela utilizada para cadastro de casos clínicos no HS.

Figura 1.7 - Cadastro de caso clínico na interface de administração

Escolha um dos casos abaixo para editar, ou crie um novo caso, a partir do botão Novo ao lado.

Filtros de Pesquisa

Para Profissionais Universidade Associada Disciplina Associada

Nome	Diagnósticos	Condutas
<input type="text"/>	Sinusite 95.0 %	Analgesia 98.0 %
Tipo de Caso <input type="text"/>	cefaléia 80.0 %	Antimicrobianos 95.0 %
Para Profissionais <input type="text"/>	Enxaqueca 50.0 %	Especialista 45.0 %
Universidade Associada <input type="text"/>	Cefaléia em Salvas 40.0 %	Investigar Imagem 01.0 %
Disciplina Associada <input type="text"/>		Profilaxia 01.0 %
Classe Social <input type="text"/>		
Cenário Associado <input type="text"/>		
Personagens Associado <input type="text"/>		
Descrição <input type="text"/>		

Fonte: elaborada pelos autores

1.3.2.3 Serviço Web de comunicação

Uma vez que o docente elabora os casos clínicos utilizando a interface de administração, eles são armazenados no banco de dados e são acessíveis para o jogo através do serviço web de comunicação. Essa funcionalidade do sistema foi construída utilizando uma arquitetura REST (*Representational State Transfer*), que por sua vez é baseada no protocolo HTTP, permitindo maior compatibilidade entre softwares de diferentes plataformas (HELWANGER; ROLIM; BARROS, 2015).

O sistema conta com cinco recursos RESTful: usuário, *avatar*, instituição, caso clínico e simulação. Para a interação com o *front-end*, esses recursos são serializados no formato JSON e transmitidos por meio de requisições HTTP. A comunicação entre as duas partes do sistema

deve ser iniciada pelo *front-end* e é realizada em turnos com um intervalo de tempo pré-determinado. A cada turno, uma nova interação acontece e um dos métodos definidos no *back-end* é chamado (HELWANGER; ROLIM; BARROS, 2015).

Objetivo deste trabalho é apresentar o desenvolvimento do módulo restante daqueles apresentados na Figura 1.3, referente ao sistema de recomendação que deve auxiliar pedagogicamente o aluno durante sua interação com o simulador. O algoritmo deve recomendar os próximos materiais e casos clínicos a serem consumidos pelo aluno, após uma análise de seu desempenho em casos anteriores, de forma que o usuário exercite suas fraquezas, reforce seu conhecimento ou adquira novos aprendizados. Detalhes a respeito da implementação do sistema de recomendação estão descritos no Capítulo 4. Capítulos 2 e 3 realizam uma revisão teórica da área de sistemas de recomendação, com o Capítulo 2 abordando tópicos como as diferentes técnicas utilizadas, os meios utilizados para coleta de dados e as métricas utilizadas para avaliação. Já o Capítulo 3 apresenta sistemas da área da educação que utilizam recomendação.

2 UMA INTRODUÇÃO AO ESTUDO DE SISTEMAS DE RECOMENDAÇÃO

Sistemas estão constantemente gerando dados, mesmo que muitas vezes não seja possível processar toda a informação criada. Como já apontado por Schick, Gordon e Haka (1990), quando a quantidade de dados criada é maior do que a capacidade de processamento de um sistema, tem-se o problema conhecido como sobrecarga de informações (*information overload*, na língua inglesa). Uma das consequências disso é a redução da qualidade e assertividade das decisões tomadas com base nos dados disponíveis.

De forma similar, Schwartz (2004) aponta que durante sua vida um indivíduo tem de realizar uma gama de decisões para as quais não tem capacidade de escolha, muitas vezes por falta de conhecimento. Para ele, algumas são decisões pequenas e sem impacto a longo prazo, como a marca ou tipo de bolacha a comprar, enquanto outras são escolhas importantes que podem levar a um descontentamento no futuro, como o curso a seguir na universidade. O autor acrescenta que embora a falta de opções seja, sem dúvida, um fator para infelicidade, o exagero do número de possibilidades também causa desconforto para muitos indivíduos. A este fenômeno deu-se o nome de paradoxo da escolha (*the paradox of choice*).

No trabalho que debate a sobrecarga de informações, a grande consequência é a redução na qualidade da decisão final (SCHICK; GORDON; HAKA, 1990). Já no livro que debate o paradoxo da escolha, o tempo necessário para analisar todas as opções é o grande empecilho (SCHWARTZ, 2004). Em sistemas de informação com grande número de usuários e quantidade ainda maior de dados – como a Internet – é comum deparar-se com estes problemas. Ao realizar uma pesquisa em uma máquina de buscas como o Google³, centenas de sites e artigos são oferecidos como resposta. Entretanto, muitas vezes essa grande quantidade de dados pode prejudicar o processo de escolha por parte do indivíduo, uma vez que ele tem de dedicar um tempo grande para o processamento de toda a informação. Durante esse processo, o indivíduo pode perceber que nem tudo está diretamente relacionado ao assunto que ele está pesquisando ou que parte das respostas simplesmente não são de seu agrado. Por isso, o usuário pode escolher deixar parte dos dados fora de sua análise, atendo-se às primeiras páginas da resposta (FAZIO, 2013). Ainda, muitas vezes, um indivíduo não tem conhecimento suficiente a respeito de um determinado assunto para realizar uma escolha adequada.

³ Google - <https://www.google.com.br>

Nestes casos, uma opção natural é basear-se em opiniões oriundas de outras pessoas para realizar uma escolha. Quando incerto sobre uma decisão, por vezes o indivíduo tende a ouvir aquilo que outras pessoas próximas a si dizem ser vantajoso. Por exemplo, quando buscando por um filme para assistir no fim de semana, é normal que o telespectador prefira o filme do qual se ouviu falar positivamente sobre outros dos quais pouco se ouviu falar. Ou seja, quando incerto, é comum que o usuário de baseie em recomendações de outros indivíduos para realizar uma tomada de decisão (FAZIO, 2013).

Buscando reproduzir esse efeito, os primeiros sistemas de recomendação (SR) surgiram por volta do ano de 1990, com o intuito de minimizar os problemas causados pela sobrecarga de informações, utilizando a avaliação provida da comunidade de usuários do sistema para realizar a indicação dos itens mais apropriados a um indivíduo. A essa técnica deu-se o nome de *collaborative filtering* (CF), ou filtros colaborativos em português (RICCI; ROKACH; SHAPIRA, 2010).

Na área de SR, costuma-se chamar o indivíduo que está utilizando o sistema, para o qual se deseja apresentar uma recomendação, como “usuário ativo”. Assim, quando utilizar-se o termo usuário ativo neste trabalho, entende-se que se trata da pessoa para qual a recomendação se destina. De forma similar, geralmente se utiliza o termo “item” para descrever o que se busca recomendar ao usuário. Um SR geralmente está direcionado para um determinado grupo de itens do mesmo tipo – CDs, livros, músicas, filmes, materiais didáticos, entre outros (RICCI; ROKACH; SHAPIRA, 2010).

Adomavicius e Tuzhilin (2005, p.1-2, tradução nossa) apresentaram uma maneira para descrever o problema da recomendação:

Deixe C ser o *set* de todos os usuários e S ser o *set* de todos os itens possíveis que podem ser recomendados, tal qual livros, filmes ou restaurantes. A quantidade S de itens pode ser bastante grande, variando entre centenas de milhares ou mesmo milhões de itens em algumas aplicações [...]. De forma similar, a quantidade de usuários pode ser bastante grande – milhões em alguns casos. Deixe que u seja uma função de utilidade que mede a utilidade do item s ao usuário c , de forma que $u: C \times S \rightarrow R$, onde R é um set totalmente ordenado [...]. Então, para cada usuário $c \in C$ queremos escolher os itens $s' \in S$ que maximizem a utilidade para o usuário. Mais formalmente:

$$\forall c \in C, \quad s'_c = \arg \max_{s \in S} u(c, s) \quad (1)$$

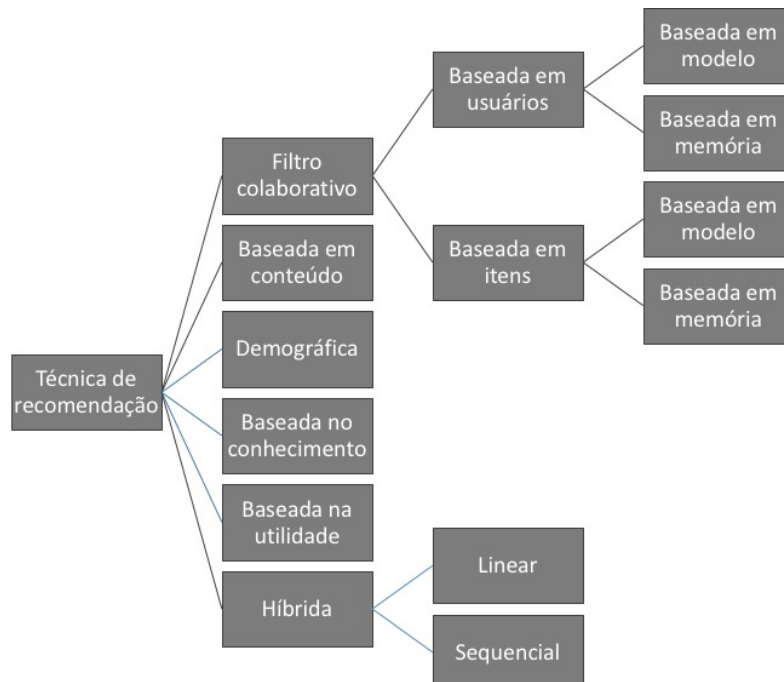
Um SR aprende as características e preferências do usuário ativo durante a interação e assim monta um modelo que represente este indivíduo. Com base neste modelo, o algoritmo busca pelos itens que melhor se enquadram nas características do usuário e os recomenda

(RICCI; MAHMOOD, 2009). Logo, sistemas de recomendação são geralmente personalizados e apresentam indicações diferentes para cada usuário que utiliza o sistema. Entretanto, por vezes se empregam SR não personalizados, como na sugestão dos *top-n* (CREMONESI; KOREN; TURRIN, 2010) itens mais vistos ou melhor avaliados do sistema. Entretanto, esse grupo de SR não é objeto de muitas pesquisas científicas (RICCI; ROKACH; SHAPIRA, 2010).

2.1 Técnicas de recomendação

Cada técnica de recomendação traz consigo características distintas, porém, grande parte dos estudos classificam os sistemas de recomendação em três categorias: *Content-Based Filters* (CBF), ou filtros baseados em conteúdo, *Collaborative Filtering* (CF), ou filtros colaborativos, e algoritmos híbridos, sendo o último o resultado do uso de diversas técnicas de recomendação em um mesmo sistema (FAZIO, 2013). Já Burke (2002), apresenta outras três categorias: técnicas demográficas, baseadas no conhecimento, ou *Knowledge-Based Filters* (KBF) e baseadas na utilidade. A Figura 2.1 mostra a divisão entre categorias:

Figura 2.1 - Classificação dos sistemas de recomendação



Fonte: elaborado pelos autores

Os próximos subcapítulos irão detalhar cada uma das técnicas apresentadas na Figura 1.4. No subcapítulo 2.1.1, trata-se a respeito da técnica de CBF, enquanto o subcapítulo 2.1.3 introduz os CF e o subcapítulo 2.1.4 versa sobre os sistemas demográficos. Em 2.1.5 apresenta-

se as técnicas baseadas em conhecimento, enquanto 2.1.6 aborda sistemas baseados em utilidade e, finalmente, 2.1.7 trata sobre os algoritmos híbridos.

2.1.1 Sistemas de recomendação baseados em conteúdo

Na abordagem de recomendação baseada em conteúdo busca-se identificar itens que possam ser de interesse do usuário tomando como base para a decisão outros itens que o usuário já tenha consumido e avaliado. Neste método cada item recomendável traz consigo atributos ou palavras-chave que descrevem o seu conteúdo. Toda vez que o usuário avalia um item, o modelo que descreve as predileções desse usuário é atualizado para cada um dos atributos daquele item. Para realizar uma recomendação, se busca por itens que possuam características às quais o perfil do usuário mostre boa aceitação (BOBADILLA, 2013).

Existem diversas maneiras para captar o conteúdo de um item e identificar suas características. Embora não seja comum em sistemas com grande número de usuários, essas características podem ser preenchidas até por humanos. Entretanto, uma das principais técnicas utilizadas é conhecida como *Term Frequency – Inverse Document Frequency* (TF-IDF). Essa técnica consiste em identificar termos (palavras) frequentes em um documento que não sejam frequentes no restante do grupo de itens. A equação 2 representa a frequência de um termo (TF) em um documento, onde f_{ti} é o número de ocorrências de um termo t em um documento i , sendo i um documento em um grupo composto por N documentos. Sendo assim, a frequência de um termo em um documento é igual ao número de ocorrências daquele termo no documento dividido pelo número de ocorrências máximo de um termo no mesmo documento (RAJARAMAN; ULLMAN, 2012).

$$TF_{ti} = \frac{f_{ti}}{\max_k f_{ki}} \quad (2)$$

Dessa forma, o termo com maior ocorrência terá $TF = 1$. Supondo que o termo t ocorra em n_t dos documentos de N , a porção IDF é definida pela equação expressa a seguir:

$$IDF_t = \log_2 \left(\frac{N}{n_t} \right) \quad (3)$$

O valor de TF-IDF para o termo t é definido por $TF_{ti} \times IDF_t$, sendo que os termos com maior resultado geralmente são os que melhor caracterizam o conteúdo do documento (RAJARAMAN; ULLMAN, 2012).

2.1.2 Folksonomia

Segundo Rocha e Moreno (2012, p. 2) a “Folksonomia surgiu em 2004 no ambiente *web* após a constatação de que vários usuários passaram a atribuir etiquetas (*tags*) a determinados recursos educacionais nas redes”. Também conhecida como classificação colaborativa, essa técnica apresenta maneira flexível para que usuários do sistema classifiquem os materiais disponíveis. Esse recurso, no contexto dos sistemas de recomendação, pode se mostrar bastante importante para a descrição de objetos não textuais, tais quais vídeos, filmes e imagens. Um dos exemplos mais conhecidos da utilização de folksonomia são as redes sociais: no Instagram⁴, por exemplo, o uso das *hashtags* emergiu nos últimos anos, auxiliando a classificação e busca das imagens públicas pelos usuários.

Figura 2.2 - Uso de folksonomia para classificação de imagens no Instagram



Fonte: THEFORCEAWAKENSAILY (2017)

⁴ Instagram – <https://www.instagram.com>

2.1.3 Sistemas de recomendação colaborativos

A técnica de CF surgiu por volta dos anos 1990 (GOLDBERG et al., 1992) tentando imitar o efeito que uma recomendação de familiares ou amigos para um produto trás sobre a escolha final do indivíduo. Os algoritmos deste tipo recomendam itens ao usuário com base nas avaliações feitas por um grupo de usuários com predileções similares ao usuário ativo. Nesta técnica, pouco ou mesmo nada é preciso saber a respeito de um item. O que se armazena é a avaliação de usuários para cada item (LOPES, 2012). Existem duas subcategorias que se destacam: recomendação baseada no usuário (*user based*) e baseada no item (*item based*).

Na abordagem do tipo *user based*, se cria um agrupamento de indivíduos, chamado de grupo dos vizinhos, com perfil similar ao do usuário ativo e assume-se que a avaliação a um item pelo usuário ativo será bastante similar às avaliações realizadas pelo seu grupo de vizinhos. Ou seja, se os indivíduos com preferências similares à do usuário ativo mostram gostar de um item, é possível induzir que o item irá agradar também ao usuário ativo (LOPES, 2012).

Já algoritmos baseados em itens traçam similaridades entre itens usando as avaliações de usuários. Desta forma, quando o sistema detecta o interesse do usuário por um item, ele pode recomendar outro similar. Se os usuários que avaliam o item i positivamente também avaliam positivamente o item j , é possível assumir que i e j são similares e, portanto, pode-se recomendar j a um usuário u que avalie i de forma positiva, ou vice-versa. Caso o contrário ocorra e um item k seja avaliado negativamente por usuários que bem avaliaram i , pode-se assumir que k não é similar a i e, portanto, não deve ser recomendado a u (LAMPROPOULOS; TSIHRINTZIS, 2015).

2.1.3.1 Funções de similaridade

Um elemento de grande importância para a filtragem colaborativa é a escolha dos indivíduos que farão parte do grupo de vizinhos do usuário em questão. Geralmente essa escolha de vizinhos é feita através de uma função de similaridade, como a correlação de Pearson ou a similaridade do cosseno.

A equação (4) mostra uma fórmula da correlação de Pearson, que indica a similaridade sim entre dois usuários u_a e u_b , onde um grupo de m usuários u_k , com $k = 1, 2, \dots, m$, $U_m = \{u_1, u_2, \dots, u_m\}$, realizaram uma avaliação $R(u_k, i_l)$ para um item i_l , onde $l = 1, 2, \dots, n$, $I_n = \{i_1, i_2, \dots, i_n\}$ é um grupo de itens (LAMPROPOULOS; TSIHRINTZIS, 2015; TESTA, 2013):

$$sim(u_a, u_b) = \frac{\sum_{l=1}^n (R(u_a, i_l) - \bar{R}(u_a)) * (R(u_b, i_l) - \bar{R}(u_b))}{\sqrt{\sum_{l=1}^n (R(u_a, i_l) - \bar{R}(u_a))^2 \sum_{l=1}^n (R(u_b, i_l) - \bar{R}(u_b))^2}} \quad (4)$$

É bastante comum, também, que seja necessário descobrir a similaridade entre dois itens de um mesmo banco de dados. Para tal, uma equação frequentemente utilizada é a distância do cosseno, representada a seguir. “Os documentos em uma coleção de texto são vistos como um conjunto de vetores de dimensão n . O grau de similaridade entre os documentos d_i e d_j é dado pelo cosseno do ângulo formado pelos vetores correspondentes”, onde $w_{t,i}$ é o valor de $TF_{t_i} \times IDF_t$ para o termo t do documento d_i (CATAE, 2012, p. 34)

$$\cos(d_i, d_j) = \frac{\sum w_{t,i} \times w_{t,j}}{\sqrt{\sum w_{t,i}^2} \times \sqrt{\sum w_{t,j}^2}} \quad (5)$$

2.1.4 Sistemas de recomendação demográficos

Outra técnica proposta pelos estudos científicos é a utilização de informações demográficas a respeito do usuário armazenadas no sistema para a construção da recomendação, partindo da premissa de que usuário com características demográficas parecidas terão preferências similares. Tais informações podem incluir a idade, gênero, local, escolaridade, entre outros. De forma similar ao realizado nas técnicas de CF, um grupo de usuários com perfil similar ativo é construído e utilizado como base para a recomendação. Os itens bem avaliados pelos vizinhos do usuário ativo serão recomendados (SAFOURY; SALAH, 2013).

Técnicas deste tipo não costumam ser utilizadas separadamente, embora alguns estudos tenham medido o impacto da adição de características demográficas às técnicas do tipo CF. O estudo de Safoury e Salah (2013), mostrou que a utilização de atributos demográficos juntamente com técnicas colaborativas não interfere notavelmente na precisão das recomendações. Já Beel et al. (2013) apontam que essas técnicas podem sim melhorar a qualidade da recomendação, sendo que a idade é o atributo com maior impacto.

2.1.5 Sistemas de recomendação baseados em conhecimento

Um sistema de recomendação baseado em conhecimento utiliza uma base de conhecimento para realizar a recomendação. No lugar de montar um modelo para o usuário, o sistema solicita as preferências do mesmo e com base nas respostas busca por itens que satisfaçam às necessidades apontadas. Aqui é preciso que o sistema tenha um conhecimento grande a respeito do tipo de item a ser recomendado, uma vez que ele precisa aprender quais características são mais importantes em um produto (PRASAD, 2007; TRAN, 2007; RODRÍGUEZ et al., 2016).

Burke (1999) aponta que a principal vantagem de um KBF é que ele não sofre com problemas de escalabilidade, uma vez que não é preciso guardar informações a respeito das avaliações de itens por usuários e também não é preciso construir um modelo único para cada usuário do sistema.

2.1.6 Sistemas de recomendação baseados na utilidade

Sistemas de recomendação baseados na utilidade constroem uma função de utilidade para cada usuário do sistema e utilizam essa função para avaliar os itens armazenados. Em outras palavras, cada atributo de um item é utilizado em uma função, com pesos diferentes de acordo com as predileções do usuário e o cálculo da utilidade é então realizado para cada item a ser avaliado. Aqueles com melhor resultado são então recomendados (HUANG, 2011).

Embora esse tipo de técnica não apresente problemas comuns da área de SR, como o *cold-start* (descrito em 2.2), construir uma função de utilidade que descreva com precisão as preferências do usuário é uma tarefa de alta complexidade que pode requerer diversas iterações diferentes do usuário com o sistema (FENG, 2015).

2.1.7 Sistemas de recomendação híbridos

As técnicas híbridas consistem em agrupar dois ou mais algoritmos distintos em uma mesma solução, com o intuito de maximizar a relevância da recomendação para o usuário. Segundo Rodríguez, Duque e Ovalle (2016), os sistemas híbridos podem se dividir em duas categorias: lineares e sequenciais. Os algoritmos lineares são aqueles nos quais uma lista de itens a ser comentada é criada com base na saída de cada uma das diferentes técnicas utilizadas, sem combiná-las. Ou seja, um algoritmo linear irá apresentar como saída cada um dos itens

selecionados por cada uma das técnicas utilizadas. Já os do tipo sequencial utilizam a saída de um algoritmo como entrada para o seguinte. Dessa forma, uma quantidade menor de itens é apresentada como recomendação, visando maior precisão.

Como mencionado anteriormente, para que um algoritmo seja considerado híbrido é preciso que ele faça uso de ao menos duas técnicas de recomendação diferentes. Sendo assim, é preciso encontrar uma maneira de combinar as recomendações dos múltiplos sistemas em uma listagem única. Burke (2002) aponta que as principais táticas para abordar esse problema são as listadas a seguir:

Método ponderado (*weighted*): nesta estratégia o valor da utilidade de um item é calculado utilizando todas as técnicas do sistema híbrido juntas. É então possível que se dê um valor de peso para cada técnica e o valor final da recomendação é calculado com base na combinação do valor predito por cada tática com o valor para o peso de cada uma. A principal vantagem, segundo Burke (2002), é que esse método faz uso do maior benefício possível de cada técnica. Porém, o autor aponta que nesse caso se espera que o valor predito por cada técnica não tenha grandes variações, o que pode não ser verdade em algumas realidades, como a falta de avaliações para um item para que se use um algoritmo colaborativo.

Método adaptativo (*switching*): neste caso, a técnica utilizada para recomendação muda para cada ambiente necessário. Quando uma técnica colaborativa não for capaz de recomendar itens relevantes ao usuário, uma abordagem baseada em conteúdo é utilizada no lugar, por exemplo. A grande vantagem é a capacidade de encontrar itens que poderiam passar despercebidos se utilizando apenas um método. Porém, uma desvantagem é que o algoritmo pode acabar utilizando apenas uma estratégia e deixar a outra não utilizada (BURKE, 2002).

Método misto (*mixed*): em situações onde há espaço para um grande número de itens recomendados, um método misto pode causar efeitos positivos na qualidade da indicação. Essa categoria recomenda itens de mais de uma técnica de recomendação. Em outras palavras, não se busca combinar as recomendações de cada técnica e apresentar um pequeno grupo de itens presente em todas as filtragens. O que se realiza é a recomendação ao mesmo tempo dos itens recomendados por todas as técnicas utilizadas. Entretanto, em casos onde uma técnica conflite com outra, é preciso escolher qual abordagem terá preferência (BURKE, 2002).

Método de combinação de características (*feature combination*): esta técnica utiliza sistemas colaborativos como uma nova característica a ser utilizada por um algoritmo baseado em conteúdo. Para itens com poucas características apresentadas, para os quais é difícil

identificar objetos semelhantes, os filtros colaborativos ajudam a apontar outros materiais. As características que aparecem frequentemente nos objetos apontados pelo método colaborativo podem então ser utilizadas para fortalecer o modelo do item que se busca avaliar (BURKE, 2002).

Método cascata (*cascade*): neste caso, a saída de um método de recomendação é utilizada para entrada do próximo método. Assim, a segunda abordagem trabalha de forma a refinar a recomendação da primeira, mas sem encontrar itens diferentes. As grandes vantagens são a qualidade da recomendação e o fato de o processamento necessário ser reduzido, se comparado à uma combinação ponderada (BURKE, 2002).

Método do aumento de características (*feature augmentation*): avaliações ou classificações aos itens são produzidas utilizando-se de alguma técnica, como o uso de agentes de inteligência artificial, reproduzindo o efeito de uma avaliação de um usuário real. Então, uma nova técnica de recomendação é utilizada, tomando essas avaliações em consideração.

Método de intersecção dos conjuntos: apresenta como recomendação apenas os itens indicados em cada uma das técnicas utilizadas (RODRÍGUEZ; DUQUE; OVALLE, 2016).

Meta-level: algoritmos do tipo *meta-level* utilizam uma técnica para criar um modelo das preferências do usuário. Esse modelo é então utilizado inteiramente por uma segunda técnica de recomendação, a fim de encontrar outros itens de interesse do usuário. A vantagem aqui é que o modelo facilita o processo de iteração da segunda estratégia, uma vez que essa pode utilizar uma representação do usuário no lugar de uma avaliação pura (BURKE, 2002).

2.2 Desafios no estudo de Sistemas de Recomendação

Durante a pesquisa na área de SR é comum encontrar diversas referências a problemas clássicos deste campo de pesquisa. Este tópico visa citar e introduzir alguns destes desafios, além de listar as principais técnicas afetadas por cada um deles. Um SR deve buscar uma maneira de contornar cada um desses problemas, a fim de alcançar uma maior qualidade.

Um dos principais desafios é o conhecido como *cold-start* (início frio). Basicamente, quando o usuário é novo no sistema e não avaliou um número considerável de itens é difícil prever a qual grupo ele fará parte, dificultando a recomendação. Esse problema atinge tanto usuários quanto itens, uma vez que quando recém inserido no sistema, o item não possui qualquer avaliação e, logo, pouco é possível saber sobre ele. O *cold-start* afeta principalmente

as técnicas colaborativas, uma vez que as predileções do usuário são conhecidas principalmente pela interação dele com o sistema, através de avaliações implícitas ou explícitas (TESTA, 2014).

Já o problema da ovelha negra (*gray sheep*) ocorre quando as preferências de um usuário não são similares a um grupo considerável de indivíduos. Nesses casos, é difícil alocar o usuário a um grupo específico de vizinhos e, logo, não é possível escolher os vizinhos que devem ser utilizados como base para a recomendação. Mais uma vez, esse problema afeta principalmente sistemas colaborativos (TESTA, 2014).

A principal dificuldade envolvendo a filtragem baseada em conteúdo chama-se **superespecialização**, que é a tendência de recomendar ao usuário apenas itens de um único assunto. Por exemplo, se um usuário costuma avaliar apenas filmes de comédia, o sistema de recomendação pode não lhe sugerir um filme de terror, mesmo que esse seja muito bem avaliado por outros usuários. Dessa forma, o usuário pode acabar sempre consumindo itens de um mesmo conteúdo.

Já a esparzida (*sparsity*) acontece quando o número de avaliações realizadas é muito pequeno se comparado à quantidade de itens no sistema. Sendo assim, cada item em particular terá, geralmente, poucas avaliações. Dessa forma, é muito provável que usuários com preferências similares não sejam relacionados simplesmente por não terem avaliado qualquer item em comum, tornando mais complicada a tarefa de agrupamento dos vizinhos (TESTA, 2014).

O problema dos **sinônimos** é mais frequente com sistemas baseados em conteúdo. Neste caso, é comum que sistemas apresentem itens bastante similares ou mesmo idênticos, porém com identificações (nome ou chave-primária) diferentes. Assim, o sistema de recomendação pode induzir que os itens idênticos são similares e devem ser recomendados. Dessa forma, um usuário pode receber uma recomendação de dois itens idênticos ao mesmo tempo, o que deveria ser evitado (FAZIO, 2013).

A **escalabilidade** também afeta os sistemas de recomendação. Quando o número de usuários e itens no sistema se torna grande, a demanda do sistema de recomendação aumenta. Alguns algoritmos têm maior dificuldade de apresentar recomendação quando o número de itens é grande, como no problema da esparsidade. Ainda, o desempenho do sistema pode diminuir, uma vez que é preciso um alto processamento para realizar a previsão do valor de utilidade de cada item (FAZIO, 2013).

2.3 Coleta de dados

Ricci, Rokach e Shapira (2010) apontam que para realizar recomendações é comum que sistemas guardem informações a respeito de três objetos: itens, usuários e transações. Alguns sistemas utilizam pouca informação, provendo indicações de itens tomando apenas as avaliações realizadas pelo usuário como base, por exemplo. Entretanto, outros sistemas utilizam grandes volumes de dados de diferentes fontes.

Os itens são os objetos a serem recomendados e é comum que sejam representados por uma série de atributos que descrevem seu conteúdo ou formato. Cada item tem um valor de utilidade diferente para cada usuário do sistema. Dessa forma, um filme que seja bem avaliado por um usuário pode não ser tão apreciado por outro (RICCI; ROKACH; SHAPIRA, 2010).

Já os usuários são os indivíduos para os quais se deseja oferecer uma recomendação. Cada usuário apresenta características e preferências próprias, que podem variar ao longo do tempo de forma que algo que hoje tem valor para um indivíduo, pode não ter o mesmo valor no futuro. É importante que o sistema de recomendação aprenda as predileções do usuário e seja capaz de adapta-las ao longo do tempo. É bastante comum que se crie um modelo para representar o usuário, porém, os dados utilizados para popular este modelo costuma variar de técnica para técnica. O modelo pode, por exemplo, incluir informações a respeito do usuário, como idade, gênero e localização, ou apenas um histórico dos itens que foram por ele consumidos. Independente do modelo escolhido, é importante salientar que ele é de extrema importância para a qualidade do sistema, uma vez que se busca uma customização do sistema que só é alcançada com um conhecimento profundo a respeito do usuário (RICCI, ROKACH, SHAPIRA, 2010).

Por fim, transações são utilizadas como forma de representar uma interação do usuário com o sistema, armazenando informações que possam ser úteis para a recomendação. Tal informação pode incluir, por exemplo, a busca realizada pelo usuário ou o valor da avaliação que ele providenciou a um item. Ricci, Rokach e Shapira (2010) afirmam que uma avaliação é provavelmente a transação mais comum em um sistema de recomendação. Essa avaliação pode se dar de forma implícita ou explícita.

Avaliações explícitas são aquelas nas quais o usuário é solicitado a dar a sua opinião a respeito de um item. Ao realizar essa avaliação, o usuário tem conhecimento de que a informação que ele dispõe a respeito de um objeto será armazenada. Existem diversos modelos

para esse tipo de avaliação, sendo que Ricci, Rokach e Shapira (2010) listam os principais como:

- avaliação numérica de 1 – 5, sendo 1 a pior avaliação e 5 a melhor avaliação possível;
- avaliação ordinal, tais como a escala de Likert (1932);
- avaliações binárias, nas quais o usuário informa apenas se o item é bom ou ruim;
- avaliações unárias, onde o usuário pode apenas dizer que gostou do item. Neste caso, a falta de avaliação para itens que o usuário já visualizou é considerada como uma avaliação negativa.

A Figura 2.3 mostra exemplos largamente utilizados da aplicação destes meios de avaliação em sistemas da Internet largamente utilizados. No exemplo A é possível ver a utilização da avaliação numérica representada na forma de estrelas no website de comércio eletrônico da Amazon⁵. Um método similar é utilizado pelo IMDB⁶ (E) para a avaliação de filmes e programas de televisão, com a diferença de que enquanto a Amazon utiliza uma escala que varia de 1 – 5, a escala no banco de dados voltado ao entretenimento varia de 1 – 10. Já o Netflix⁷, principal ferramenta de *streaming* de vídeos por assinatura da Internet, utiliza uma avaliação binária (B) onde o usuário pode mostrar sua aprovação ou reprovação para cada um dos itens. O meio utilizado pela Netflix é bastante similar ao empregado anteriormente pelo YouTube⁸ em todos os seus vídeos, apresentado no exemplo C. Por fim, o exemplo D é a avaliação unária utilizada no Facebook⁹, no qual o usuário utiliza o famoso “Curtir” para mostrar sua aprovação ao conteúdo publicado pelos outros membros da rede social.

Já avaliações implícitas acontecem sem que o usuário tome conhecimento. Esse tipo de coleta de dados pode incluir: informações sobre os itens comprados ou visualizados pelo indivíduo, informações sobre os tópicos pesquisados, tempo ativo em uma mesma página, entre outros (RICCI, ROKACH, SHAPIRA, 2010).

⁵ Amazon - <https://www.amazon.com>

⁶ IMDB - <http://www.imdb.com>

⁷ Netflix - <https://www.netflix.com>

⁸ YouTube - <https://www.youtube.com>

⁹ Facebook - <https://www.facebook.com>

Figura 2.3 - Avaliações do usuário em diversos sistemas da Internet



Fonte: elaborado pelos autores

2.4 Métricas para avaliação do SR

Este tópico busca apresentar uma série de métricas utilizadas para a avaliação de sistemas de recomendação. Enquanto existem diversas formas de medir quão próximas à realidade estão as recomendações e predições de um sistema, é impossível listar todas elas. Desta forma, aqui são apresentadas as principais, que foram encontradas na literatura deste trabalho.

2.4.1 Métricas de acurácia da predição

Esse tipo de métrica busca avaliar quão próximas às avaliações do usuário para um item estão as predições do sistema. Uma métrica bastante utilizada é o *Mean Absolute Error* (MAE). A equação (6) mostra o cálculo do valor de MAE, onde N é o número de itens avaliados, p_i é o valor previsto pelo SR e r_i é a avaliação realizada pelo usuário. Neste caso, quão mais perto de 0, mais preciso o sistema de recomendação (CAMPOS et al., 2010).

$$\text{MAE} = \frac{\sum_{i=1}^n |p_i - r_i|}{N} \quad (6)$$

Outra métrica utilizada é conhecida como *Mean Squared Error* (MSE), para qual o cálculo é apresentado na equação (7). Uma variante desse método, chamada *Root Mean Squared Error* (RMSE) é apresentada na equação (8). Quando comparados à métrica MAE, MSE e RMSE tem a diferença de penalizar mais severamente erros maiores, enquanto MAE

trata todos os erros com o mesmo peso (CHAI; DRAXLER, 2014; SCHRÖDER; THIELE; LEHNER, 2011). MSE tem como saída uma métrica quadrática e, portanto, em unidades diferentes dos valores utilizados no cálculo. Para retornar o valor da métrica à escala utilizada pelo SR, RMSE é utilizada (GUNAWARDANA; SHANI, 2009; SCHRÖDER; THIELE; LEHNER, 2011)

$$\text{MSE} = \frac{\sum_{i=1}^n (p_i - r_i)^2}{N} \quad (7)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (p_i - r_i)^2}{N}} \quad (8)$$

Por fim, a *Normalized Mean Absolute Error* (NMAE) normaliza os valores da saída de MAE aos utilizados pelo sistema de recomendação, fazendo com que a métrica possa ser utilizada para comparar SR que utilizarão escalas de avaliação diferentes (SCHRÖDER; THIELE; LEHNER, 2011). Para um sistema onde o valor máximo possível em uma avaliação é r_{max} e o valor mínimo é r_{min} , o valor de NMAE pode ser calculado conforme a equação (9):

$$\text{NMAE} = \frac{\text{MAE}}{r_{max} - r_{min}} \quad (9)$$

De acordo com Schröder, Thiele e Lehner (2011), os motivos para a utilização das métricas descritas anteriormente incluem a sua facilidade para o entendimento e a implementação. Entretanto, os autores apontam que essas métricas podem não ser as mais adequadas para avaliação de um SR, uma vez que o objetivo do usuário de um SR pode ser tão simples quanto receber uma lista de recomendações dos *top-N* objetos mais adequados ao seu perfil, não se importando, ele, com o valor das avaliações prestadas a cada um dos itens. Com isso, outras métricas avaliam a acurácia da lista de itens apresentada ao usuário. Algumas dessas métricas estão descritas em 2.4.2.

2.4.2 Métricas de acurácia da classificação

As métricas de acurácia da classificação indicam a quantidade de itens que são correta ou incorretamente recomendados pelo SR, ignorando as avaliações ou a ordem de apresentação dos itens. Apenas a classificação entre “recomendado” e “não recomendado” é avaliada

(SCHRÖDER; THIELE; LEHNER, 2011). Essas métricas são, portanto, calculadas com base no número de itens que são relevantes/irrelevantes e contidos/não contidos na recomendação. Dessa forma, os possíveis cenários são descritos em uma matriz de confusão, conforme apresentado na Tabela 1.

Tabela 1 - Matriz de confusão para avaliar um RS

	Relevante	Irrelevante	Total
Recomendado	tp	fp	$tp + fp$
Não recomendado	fn	tn	$fn + tn$
Total	$tp + fn$	$fp + tn$	

Fonte: Schröder, Thiele e Lehner (2011, p.4)

A primeira métrica e uma das mais utilizadas é a *Precision* (Precisão), também conhecida como *True Positive Accuracy* (TPA) ou *confidence*, que indica a razão do número de itens recomendados que são relevantes para o total de itens recomendados. Em outras palavras, a métrica aponta quantos dos itens recomendados deveria de fato ter sido recomendado. Já a métrica *Recall*, também chamada *True Positive Rate* (TPR) ou *sensibility*, mede a razão do número de itens recomendados que são relevantes para o total de itens relevantes. Ou seja, a medida aponta quanto dos itens que deveriam ser recomendados foram de fato apresentados pelo SR (POWERS, 2011; SCHRÖDER; THIELE; LEHNER, 2011).

$$TPA = \frac{tp}{tp + fp} \quad (10)$$

$$TPR = \frac{tp}{tp + fn} \quad (11)$$

De forma inversa, a medida de *Fallout*, ou *False Positive Rate* (FPR) aponta a razão do número de itens irrelevantes recomendados pelo total de itens irrelevantes, mostrando a probabilidade de um item que não deveria ser recomendado ser apresentado pelo SR. Já a probabilidade de um item que deveria ser recomendado não ser apresentado no SR é medida pela métrica conhecida como *miss rate*, ou *False Negative Rate* (FNR) (POWERS, 2011; SCHRÖDER; THIELE; LEHNER, 2011).

$$\text{FPR} = \frac{fp}{fp + tn} \quad (12)$$

$$\text{FNR} = \frac{fn}{tp + fn} \quad (13)$$

Inverse Precision, ou *True Negative Accuracy* (TNA), é calculado como a razão do número de itens corretamente não recomendados pelo número total de itens não recomendados, mostrando a probabilidade de que um item não recomendado seja de fato irrelevante. Por fim, *Inverse Recall*, ou *True Negative Rate* (TNR), calculado como a razão do número de itens corretamente não recomendados pelo total de itens irrelevantes (POWERS, 2011; SCHRÖDER; THIELE; LEHNER, 2011).

$$\text{TNA} = \frac{tn}{fn + tn} \quad (14)$$

$$\text{TNR} = \frac{tn}{fp + tn} \quad (15)$$

Já o *F1-score* ou *F1-measure*, combina *Precision* e *Recall* em uma métrica única. Powers (2011), entretanto, aponta que as três métricas mais utilizadas (*Precision*, *Recall* e *F1-measure*) são propensas à desequilíbrios de acordo com a quantidade de itens relevantes disponíveis. Tal desequilíbrio pode levar a enganos durante o desenvolvimento e a escolha da técnica de recomendação mais indicada para um sistema. Buscando resolver este problema, as técnicas de *markedness* e *informedness* foram introduzidas, utilizando TNA e TNR no seu cálculo (POWERS, 2011; SCHRÖDER; THIELE; LEHNER, 2011).

$$\text{F1} = \frac{2 \times \text{TPA} \times \text{TPR}}{\text{TPA} + \text{TPR}} \quad (16)$$

$$\text{markedness} = \text{TPA} + \text{TNA} - 1 \quad (17)$$

$$\text{informedness} = \text{TPR} + \text{TNR} - 1 \quad (18)$$

A métrica da correlação de Matthews, por sua vez, combina *markedness* e *informedness* em um valor único que varia de -1 a 1, e, segundo Schröder, Thiele e Lehner (2011), é uma boa ferramenta para apontar o tamanho de uma lista de *top-N* itens a serem recomendados.

$$\text{Matthews correlation} = \pm\sqrt{\text{markedness} \times \text{informedness}} \quad (19)$$

2.4.3 Métricas de acurácia da ordenação

Existem métricas para avaliar a acurácia da ordem de preferência proposta por um sistema de recomendação. Os *top-N* itens propostos por um sistema podem ser encarados como uma lista ordenada de itens. Dessa forma, é preciso verificar quão similar a ordem dos itens é em comparação à uma segunda lista, que representa os mesmos itens ordenados pelo usuário de acordo com a sua preferência. Schröder, Thiele e Lehner (2011) apontam que é possível utilizar o coeficiente de correlação *tau* (KENDALL, 1938) ou o coeficiente de correlação *rho* de Spearman para essa tarefa. Os autores apontam, entretanto, que a utilização dessas técnicas pode trazer dificuldades quando aplicadas à avaliação de um SR, pois a lista proposta pelo algoritmo pode conter itens com valor de utilidade idênticos (2 ou 3 itens com utilidade igual a 4), que serão ordenados de forma arbitrária pelo SR. Dessa forma, essa ordenação arbitrária poderia trazer o valor da métrica para baixo, mesmo que todos os itens sejam indicados ao usuário.

O Capítulo 3 aborda o tema dos SR utilizados em plataformas de educação, focando principalmente nas diferenças entre a utilização de técnicas de recomendação para suporte ao ensino e os algoritmos de propósito geral, como os utilizados para entretenimento ou comércio eletrônico. Aborda-se também a importância da transparência na recomendação e de explicar as recomendações apontadas, o que trás maior credibilidade ao SR. Por fim, algumas plataformas de ensino que fazem uso de técnicas de recomendação são apresentadas. Em algumas destas, as métricas de acurácia apresentadas anteriormente são utilizadas como forma de avaliação da qualidade das recomendações realizadas.

3 SR EM PLATAFORMAS VOLTADAS À EDUCAÇÃO

Herlocker et al. (2004) apresentam uma lista de objetivos e tarefas de um sistema de recomendação sobre o ponto de vista do usuário ativo e não do serviço ou empresa que o disponibiliza. A lista foi proposta após pesquisas e estudos nos sistemas de recomendação já conhecidos pelos autores e estes salientam que a lista contém as principais tarefas de um sistema de recomendação e não a totalidade dos possíveis objetivos. A meta dos autores é que a lista seja usada como referencial a respeito das tarefas de um SR a ser utilizada durante a construção do sistema, sem fixá-la a um domínio específico, como o comércio eletrônico ou o entretenimento. A listagem de tais tarefas está descrita no Quadro 3.1:

Quadro 3.1 - Tarefas de um SR de propósito geral

TAREFAS DE UM SISTEMA DE RECOMENDAÇÃO DE PROPÓSITO GERAL	
Anotações no contexto	O objetivo dos sistemas de recomendação originais (GOLDBERG et al., 1992) era ajudar o usuário a escolher quais mensagens ler em um sistema de comunicação com grande número de postagens. Dessa forma, era preciso que o sistema mantivesse conhecimento a respeito do contexto das mensagens, a fim de decidir para quais delas realizar uma indicação. As mensagens que o sistema avaliava como mais importantes eram destacadas das outras, para chamarem maior atenção do usuário.
Encontrar bons itens	Alguns sistemas atuam de forma mais direcionada, sugerindo itens específicos ao usuário ativo, associado à uma predição do valor de utilidade daquele item. A literatura aponta este como sendo o principal objetivo de um sistema de recomendação, utilizado em diversos cenários. Alguns sistemas preferem omitir a predição do valor de utilidade, atendo-se a apresentar uma lista dos itens que melhor suprem as necessidades do usuário.

TAREFAS DE UM SISTEMA DE RECOMENDAÇÃO DE PROPÓSITO GERAL	
Encontrar todos os bons itens	Enquanto alguns sistemas focam em encontrar um certo número de itens a recomendar, buscando eliminar grande parte dos objetos irrelevantes mesmo a custo de perder alguns bons itens, outros sistemas necessitam encontrar todo e cada um dos itens que se enquadrem nas necessidades do usuário, mesmo que a um custo demasiado alto para o sistema e para o indivíduo.
Recomendar uma sequência	Alguns sistemas focam em recomendar não apenas um item, mas uma sequência de itens a serem consumidos pelo usuário final. Como exemplo, pode-se citar uma <i>playlist</i> de músicas em uma ferramenta como o Spotify ¹⁰ , ou uma sequência de artigos a serem lidos a fim de aprender sobre um determinado assunto.
Recomendar um conjunto	Neste caso, no lugar de uma recomendação simples a um item em separado, o sistema visa encontrar itens que se relacionam e podem ser consumidos juntos. Um exemplo da literatura estudada é um pacote de viagem que poderia acompanhar, por exemplo, o destino, as diárias em um hotel e uma série de programas para o período da viagem.
Apenas navegando	Alguns usuários acessam sites ou ferramentas sem o objetivo de consumir algum conteúdo em específico, mas apenas por distração ou entretenimento. Em casos como esses, o sistema de recomendação não requer a mesma acurácia e deve focar em apresentar uma maneira agradável e personalizada para que o usuário utilize o sistema.
Encontrar recomendações confiáveis	Alguns usuários utilizam um sistema de recomendação apenas para testar quão boas são suas indicações, visitando objetos já consumidos e para os quais ele – o usuário – já tem uma opinião formada.
Expressar opinião	Certos usuários podem não se importar com as recomendações e mesmo assim utilizar o sistema a fim de contribuir com suas avaliações e pensamentos a respeito dos itens.

¹⁰ Spotify - <https://www.spotify.com/>

TAREFAS DE UM SISTEMA DE RECOMENDAÇÃO DE PROPÓSITO GERAL	
Melhorar o perfil	Relacionado à disponibilidade de o usuário criar e alimentar um perfil que descreva suas preferências e necessidades no sistema. É um requisito de grande importância, uma vez que sem conhecimento do usuário é muito difícil prestar uma recomendação com qualidade.
Ajudar aos outros	Uma parte dos usuários do sistema pode encontrar no sistema de recomendação uma forma de ajudar aos outros membros, através das avaliações e comentários em itens do sistema.
Influenciar aos outros	O sistema deve procurar uma maneira de evitar que os usuários realizem esta tarefa. Alguns indivíduos podem utilizar o sistema de recomendação para persuadir os outros a consumir determinados itens. O sistema deve evitar essa prática, uma vez que isso não é sinônimo de uma boa recomendação.

Fonte: adaptado de Herlocker et al. (2004, p. 9 – 11)

Em adição a esses tópicos, o estudo realizado por Manouselis et al. (2010) aponta que um sistema de recomendação da área da educação pode ainda explorar outros objetivos não descritos por Herlocker et al. (2004). O Quadro 3.2 descreve cada uma das novas tarefas propostas.

Quadro 3.2 - Tarefas adicionais em um SR voltado à educação

TAREFAS ADICIONAIS EM UM SISTEMA DE RECOMENDAÇÃO DE PROPÓSITO EDUCACIONAL	
Encontrar itens recentes	Prover recomendação de objetos recém adicionados ao sistema, incluindo itens de conteúdo controverso, que possam ser de interesse do usuário ativo com base na sua área de estudo. Para tal, é necessário que se explorem técnicas de recomendação que utilizem outras fontes de informação que não apenas a similaridade entre os itens.

TAREFAS ADICIONAIS EM UM SISTEMA DE RECOMENDAÇÃO DE PROPÓSITO EDUCACIONAL	
Encontrar parceiros	A recomendação de outros indivíduos com preferências similares ao usuário ativo pode ser importante em um sistema voltado à educação, uma vez que o aluno pode utilizar essa recomendação para conhecer especialistas da área. Tal recomendação pode incluir professores, especialistas ou mesmo outros alunos.
Encontrar bons caminhos de estudo	O sistema pode ainda explorar a recomendação de bons caminhos de estudo. Diferente da recomendação de uma sequência, essa tarefa pode recomendar uma série de itens e então propor caminhos alternativos através destes itens para que o usuário alcance um determinado objetivo pedagógico. Para tal, é preciso que se busque por uma técnica capaz de prover uma série de materiais similares, mas organizados de formas diferentes.

Fonte: adaptado de Manouselis et al. (2010, p. 390)

Já Fraihat e Shambour (2015) apontam outros tópicos que são peculiaridades da área da educação, com as quais um SR deve se preocupar:

- O objetivo do sistema deve ser encontrar materiais e atividades que melhor ajudem o usuário ativo a alcançar seus objetivos de aprendizagem e desenvolver as suas competências em um curto período de tempo (FRAIHAT; SHAMBOUR, 2015);
- O sistema pode realizar atividades que incluem a recomendação de materiais ao professor buscando melhorar a qualidade do curso ou atividade, ajudar os alunos na escolha de qual cursos tomar, auxiliar o professor a identificar erros comuns e alunos com maior dificuldade (FRAIHAT; SHAMBOUR, 2015);
- SR da área da educação estão em um contexto pedagógico no qual questões como pré-requisitos, design instrucional, limitações de tempo, cenários pedagógicos e a interação social devem ser tomados em consideração (FRAIHAT; SHAMBOUR, 2015);
- Neste ambiente, fatores educacionais como o processo e a estratégia de aprendizagem, o conhecimento, as preferências, os estilos, os padrões, as

dificuldades, as atividades realizadas, o *feedback* apresentado, o progresso e a *expertise* afetam o SR (FRAIHAT; SHAMBOUR, 2015);

- Por fim, é possível categorizar os usuários em alguns grupos, de acordo com o papel que executam no processo de aprendizagem (aluno, professor, etc.), com o seu nível de conhecimento (iniciante, intermediário, avançado) ou mesmo com seu estilo de aprendizagem (FRAIHAT; SHAMBOUR, 2015).

O HS é um simulador de casos clínicos do tipo paciente virtual e seu objetivo é auxiliar o aluno pedagogicamente no processo de aprendizado. Dessa forma, é importante que o SR inserido nesta plataforma adresse as tarefas descritas no Quadro 3.2. Ainda, é importante que o sistema seja avaliado de forma a verificar como a sua utilização interfere no aprendizado do aluno.

Os próximos subcapítulos buscam mostrar a importância da transparência em um sistema de recomendação, tópico que deve ser abordado no SR para o HS, e também apresentar trabalhos que envolvem o uso de SR em plataformas voltadas à educação.

3.1 A importância da transparência

Diversos estudos apontam que o usuário ativo está mais propenso a confiar nas recomendações do SR caso este providencie uma explicação do processo utilizado para seleção dos itens indicados (LINDEN et al., 2009; SINHA; SWEARINGEN, 2002; TINTAREV; MASTHOFF, 2012). Entretanto, Sinhá e Swearingen (2002, p.1, tradução nossa) afirmam que muitos SR agem como “caixas pretas, não oferecendo ao usuário nenhuma ideia a respeito da lógica ou justificativa para as recomendações”. Os autores apontam que quando um indivíduo recebe uma recomendação por parte de outro, ele tem à disposição três maneiras de decidir se confia na recomendação, maneiras estas que deveriam também ser oferecidas por um sistema de recomendação:

- avaliar a similaridade de suas preferências com as de quem esta oferecendo a recomendação;
- verificar quão boas foram as recomendações realizadas no passado por esse mesmo indivíduo;
- questionar o motivo da recomendação prestada.

Já Tintarev e Masthoff (2012) listam motivos para a adoção de uma forma de explicação das recomendações no sistema:

Quadro 3.3 - Motivos para prover explicações em um SR

MOTIVOS PARA EXPLICAÇÕES EM SR	
Transparência	Explicar como o sistema funciona
Correção	Permitir que o usuário mostre que o sistema está errado
Confiança	Aumentar a confiança do usuário no sistema
Efetividade	Ajudar o usuário a fazer boas escolhas
Persuasão	Convencer o usuário a consumir o item recomendado
Eficiência	Ajudar o usuário a fazer uma boa escolha mais rapidamente
Satisfação	Aumentar a facilidade de utilização ou a satisfação do usuário

Fonte: adaptado de Tintarev e Masthoff (2012, p. 401)


Sinha e Swearingen (2002) conduziram um estudo em cinco sistemas diferentes e concluíram que os usuários estão mais inclinados a acreditar na recomendação quando esta é transparente. Vig, Sen e Riedl (2009) chegaram a conclusões similares após realizar um estudo em um sistema que usava *tags* como ferramenta para prestar a explicação, no qual 80% dos indivíduos participantes apontaram que a explicação apresentada os ajudou a decidir se a recomendação atendia a seus desejos.

Konstan e Riedl (2012) mostram que a interface das explicações pode apresentar formas variadas, sendo que até mesmo interfaces simples são bastante efetivas em convencer o usuário ativo. Métodos simples são adotados no Netflix e na Amazon, buscando convencer o usuário a consumir um item. A Amazon apresenta abaixo da lista de recomendação os itens acessados que levaram o sistema a apresentar tal indicação, como demonstrado na Figura 3.1. O Netflix adota uma tática similar, apresentando acima de algumas recomendações a frase “Porque você assistiu ...”, como visto na Figura 3.2.

Figura 3.1 - Explicação para recomendação na Amazon

Your Recently Viewed Items and Featured Recommendations

Inspired by Your Browsing History




You viewed



Fonte: Amazon (2016)

Figura 3.2 - Explicação para recomendação no Netflix



Fonte: Netflix (2016)

A comunidade acadêmica concorda que estudos nessa área ainda podem ser realizados, a fim de mostrar a extensão dos efeitos de adicionar um meio de prover explicação e transparência a um SR (KONSTAN; RIEDL, 2012), entretanto, os autores deste trabalho acreditam que esse tópico deve ser abordado pelo SR proposto para o HS.

3.2 Trabalhos relacionados – SR no auxílio à educação

Essa sessão do trabalho busca estudar plataformas de ensino que empregam SR com o intuito de auxiliar os alunos no processo de aprendizagem. Aqui, busca-se avaliar como as técnicas de recomendação foram empregadas, a fim de encontrar soluções de sucesso que possam ser empregadas também no HS. O primeiro trabalho apresentado emprega avaliações de bons alunos como uma forma de seleção dos itens recomendáveis. Em 3.2.2 é abordado o uso de algoritmos híbridos para a recomendação de objetos de aprendizagem. Já em 3.2.3 explana-se a respeito da utilização de SR em um ambiente de ensino colaborativo e, por fim, 3.2.4 mostra o uso de CF com restrições de competências para auxílio à aprendizagem em disciplinas do ensino superior.

3.2.1 Incorporando a avaliação de bons alunos em CBF

Ghauth e Abdullah (2011), preocupados com o rápido aumento do número de materiais disponíveis em sistemas de educação, que contrasta com o pouco tempo para que os alunos estudem cada um deles, propuseram um SR com o intuito de apresentar aos estudantes apenas os melhores objetos.

O trabalho focou em avaliar o efeito de incorporar a avaliação de bons estudantes (*good learners*) no processo de recomendação, baseado em estudos que mostram que o uso da aprendizagem em pares (*peer learning*) pode levar o indivíduo a adquirir conhecimentos e habilidades através da interação direta com outros estudantes, seja prestando auxílio ou sendo auxiliado (GHAUTH; ABDULLAH, 2011 apud TOPPING, 2007). O estudo aponta que alunos que fazem uso da aprendizagem em pares tem a oportunidade de aprender através da observação a outros alunos que apresentam bom aproveitamento. Com isso em mente, os autores propuseram o uso da avaliação de bons alunos à materiais do sistema como uma fonte de dados para o SR (GHAUTH; ABDULLAH, 2010, 2011).

Um *good learner* é um aluno com aproveitamento igual ou maior à 80% em um exame proposto pelo estudo. Desta forma, o sistema faz uso das avaliações destes alunos à materiais do sistema para junto a um CBF realizar recomendações de materiais que podem ser úteis ao processo de aprendizado do aluno ativo. Um professor deve prover materiais de ensino ao sistema, que são representados por informações que podem incluir o nome dos autores, o título e diversas palavras-chave. Essas palavras-chave são utilizadas pelo algoritmo de CBF para

calcular a similaridade entre os itens. Além disso, cada material apresenta uma média das avaliações de *good learners* para si. Na ausência de uma avaliação para qualquer dos itens, uma previsão do valor é realizada (GHAUTH; ABDULLAH, 2010, 2011).

Quando visualizando um material, ao usuário ativo é apresentado uma lista de outros materiais similares, juntamente com valor da avaliação dos *good learners*. Na fase de modelagem, os autores utilizaram a equação de TF-IDF para descobrir o peso de cada uma das palavras-chave para cada item. Essa informação é então utilizada na função da similaridade do cosseno para verificar a similaridade entre os materiais. Já na fase de recomendação, os *top-N* itens mais similares ao acessado pelo usuário são apresentados, juntamente com a média da avaliação dos *good learners*. Na ausência de avaliação para qualquer dos itens, uma previsão do valor é computada com base na equação (20), onde $sim(d_i, d_n)$ é a similaridade entre os itens i e n e R_n é a média da avaliação dos *good learners* ao item n (GHAUTH; ABDULLAH, 2010, 2011):

$$P_i = \sum_{n=1}^N \frac{sim(d_i, d_n) \times R_n}{sim(d_i, d_n)} \quad (20)$$

Um experimento foi realizado com 95 estudantes, divididos em 4 grupos, que utilizaram o sistema durante uma semana, avaliando a utilidade de cada material apresentado. Os 4 grupos estão descritos na sequência (GHAUTH; ABDULLAH, 2010, 2011):

- Grupo G1: 21 estudantes que utilizavam a plataforma de ensino sem o uso de qualquer sistema de recomendação;
- Grupo G2: 21 estudantes que utilizavam a plataforma de ensino com o uso de uma técnica de CBF;
- Grupo G3: 24 estudantes que utilizavam a plataforma de ensino com o uso da técnica de recomendação proposta;
- Grupo G4: 29 estudantes que utilizavam a plataforma de ensino com o uso de uma técnica de CF.

Antes de fazer uso do sistema os usuários realizar um pré-teste, buscando avaliar o seu conhecimento prévio. Após a semana de uso do sistema, os alunos passaram novamente por um teste, buscando avaliar o conhecimento adquirido. Com base nos testes realizados, foi possível notar uma melhora de ao menos 12.16% no desempenho dos alunos que utilizaram o sistema proposto em relação aos outros grupos. O estudo fez uso de MAE, *Precision*, *Recall* e *F-*

Measure para calcular a precisão do sistema de recomendação e foi possível constar que o algoritmo proposto tem acurácia maior que ambas as técnicas de CBF (83.28% maior) e CF (48.58% maior) (GHAUTH; ABDULLAH, 2010, 2011).

3.2.2 Recomendação de objetos de aprendizagem

Objetos de aprendizagem (OA) são recursos educacionais bastante utilizados nos últimos anos, principalmente após o crescimento da Internet, podendo ser descritos como qualquer arquivo digital utilizado para o ensino – pode incluir uma apresentação, um áudio, um vídeo no YouTube, um artigo, uma página web, etc. Objetos do tipo estão presentes em diversas ferramentas voltadas à educação (AUDINO, 2012; SOUZA FILHO, 2010).

Rodríguez, Duque e Ovalle (2016) propuseram um SR de OA baseado no perfil do usuário e fazendo uso de três diferentes técnicas de recomendação: CBF, CF e KBF. Os OA estão armazenados em um repositório de objetos de aprendizagem (ROA), intitulado Federación de Repositorios de Objetos de Aprendizaje Colombia (FROAC) (MORALES, et al., 2015), e somavam 621 itens de diversos tópicos na época da elaboração do trabalho. Os autores realizaram experimentos com diversos métodos de combinação (apresentados em 2.1.7), a fim de avaliar qual seria mais indicado para o cenário apresentado.

Para verificar a qualidade das recomendações apresentadas pelo sistema, os pesquisadores puseram um grupo de estudantes a avaliar os resultados de uma busca (sem qualquer método de recomendação) no ROA, onde cada estudante tinha de indicar o grau de relevância de cada objeto para o processo de aprendizagem no tema pesquisado. Com isso, os pesquisadores aplicaram as medidas de *Precision*, *Recall* e *F1-score* para os resultados de cada método de combinação (RODRÍGUEZ, DUQUE, OVALLE, 2016). Foi possível concluir que:

Quadro 3.4 - Avaliação de diversos métodos de combinação

RESULTADO DA AVALIAÇÃO DE DIVERSOS MÉTODOS DE COMBINAÇÃO		
Métrica	Método	Resultado
Precision	Ponderado	Bons resultados quando todos as três técnicas de recomendação são utilizadas e com maior peso para KBF.
	Adaptativo	Melhores resultados entre todos os métodos, porém apenas quando se utilizaram as técnicas CBF e CF.

RESULTADO DA AVALIAÇÃO DE DIVERSOS MÉTODOS DE COMBINAÇÃO		
Métrica	Método	Resultado
	Misto	Valor com pouca variância para a combinação das técnicas utilizadas, devido ao fato de que os resultados de todas as técnicas são apresentados.
	Cascata	Apresenta um bom valor de <i>Precision</i> , uma vez que poucos itens são retornados, elevando a precisão.
	Interseção dos conjuntos	Resultados similares aos encontrados pelo método cascata, entretanto, com <i>Precision</i> um pouco menor devido ao fato de que mais OA são recomendados.
Recall	Ponderado	Resultados similares ao método adaptativo, com resultados um pouco inferiores quando se usam combinações compostas pelas três técnicas de recomendação.
	Adaptativo	Valor varia bastante entre cada uma das combinações de técnica, ficando entre ≈ 6 e ≈ 3
	Misto	Maiores valores entre todos os métodos de combinação, uma vez que o número de OA recomendados é maior.
	Cascata	Valores baixos, uma vez que poucos itens são recomendados.
	Interseção dos conjuntos	Valores baixos quando utilizando apenas duas técnicas e razoáveis quando todas as técnicas são empregadas.
F1-score	Ponderado	Valor varia entre ≈ 6 e ≈ 4 para cada combinação, apresentando valores menores quando se utilizam três técnicas de recomendação.
	Adaptativo	Valor varia entre ≈ 6 e ≈ 4 para cada combinação.

RESULTADO DA AVALIAÇÃO DE DIVERSOS MÉTODOS DE COMBINAÇÃO		
Métrica	Método	Resultado
	Misto	Maiores valores entre todas as técnicas, uma vez que apresentou valores positivos em ambas as métricas anteriores.
	Cascata	Menores valores entre todos os métodos
	Interseção dos conjuntos	Valores similares aos apresentados pelo método cascata quando utilizando duas técnicas, que melhora quando se faz o uso de todas as técnicas.

Fonte: 1 Adaptado de Rodríguez, Duque e Ovalle (2016, p. 90 - 91)

Com isso, os pesquisadores concluíram que o uso de métodos mistos e adaptativos apresentam melhores resultados para mesclar as recomendações indicadas por cada técnica, salientando que um método misto tem a vantagem de geralmente apresentar um número maior de itens, tendo assim, um valor de *Recall* mais favorável em relação às outras estratégias.

3.2.3 SAPO Campus: um SR para uma plataforma colaborativa

O SAPO Campus é uma ferramenta educacional desenvolvida e mantida pela Universidade de Aveiro, de Portugal, que busca viabilizar acesso a diversos formatos de materiais a comunidades de aprendizado colaborativo. Na ferramenta, todo usuário tem acesso a um espaço pessoal, onde pode criar e compartilhar seu próprio conteúdo, além de acessar o conteúdo criado por outros usuários da plataforma. O SAPO Campus conta também com um SR focado em duas áreas distintas: recomendação de outros membros – os quais o usuário ativo pode ter interesse em seguir – e recomendação de conteúdo pertinente aos assuntos de preferência do usuário (PEDRO et al, 2012). O SR utilizado é baseado em um *framework* de recomendação chamado Easyrec¹¹, opção escolhida devido à facilidade de instalação e gerenciamento, além do seu poder de escalabilidade (ALVES, 2013).

Um estudo foi conduzido com 165 participantes, que incluíam alunos e professores, todos membros do sistema, buscando avaliar a utilidade e relevância do SR na tarefa de auxiliar

¹¹ Easyrec: <http://easyrec.org/>

a interação da comunidade. Para tal, um questionário com 10 perguntas foi aplicado aos participantes. Os resultados do estudo apontaram que grande parte dos participantes não recordava receber nenhuma recomendação de qualquer sistema da Internet e apenas 8 participantes lembravam de receber recomendações do sistema SAPO Campus. Quanto perguntados sobre a sua opinião a respeito das recomendações da plataforma de aprendizagem, entretanto, 17% dos estudantes afirmaram que o SR é útil para encontrar pessoas interessantes e 11% afirmaram que o SR era útil para encontrar materiais interessantes, enquanto 16% informaram não lembrar de receber qualquer recomendação (PEDRO et al., 2014).

Os resultados do estudo, embora confusos, levaram os pesquisadores a repensar a abordagem de recomendação utilizada, incluindo um tutorial ou material informativo a respeito do SR (PEDRO et al., 2014). Uma outra abordagem poderia ser focar-se em explicar as recomendações apresentadas, chamando assim a atenção do usuário para este módulo do sistema, como descrito em 3.1.

3.2.4 Filtros colaborativos para recomendação de objetos de aprendizagem

Cazella et al. (2009) propõem um SR para recomendação personalizada de OA baseado em CF e nas competências a serem desenvolvidas pelo usuário, podendo-se entender competência como “a inteligência prática para situações que se apoiam sobre conhecimentos adquiridos e os mobilizam, transformando-os de acordo com a complexidade das situações” (CAZELLA et al., 2009, p2). O trabalho busca auxiliar na procura de OA de qualidade que possam beneficiar o processo de aprendizagem em uma disciplina, baseando-se nas predileções e nas competências necessárias no plano de aula.

Após aplicada a técnica de CF para encontrar materiais de acordo com as preferências do usuário, o SR verifica uma série regras de competência para cada item. Nesta etapa, selecionam-se OA que atendem às competências necessárias, descartando itens com um valor de utilidade alto que não contribuam as competências indicadas como importantes para a disciplina em questão (CAZELLA et al., 2009). Sendo assim, o modelo apresentado pelos autores é baseado em três etapas: planejamento das aulas por parte do professor, que aponta as competências necessárias e OA que atendam a essas competências; aplicação de uma técnica de CF para seleção de itens que atendam às preferências do usuário; por fim, aplicação das regras de competências, para remover itens que não atendam às competências indicadas pelo professor na primeira etapa.

Um protótipo para o sistema proposto foi desenvolvido e utilizado pelos alunos, que fizeram avaliações a uma base de dados de OA que continha 30 artigos da disciplina de Banco de Dados, com competências associados a cada um deles. Após esta primeira rodada de avaliações, o SR indicou novos artigos aos usuários, que foram novamente avaliados pelos alunos com base na sua adequação à competência desenvolvida em sala de aula. Após esta segunda etapa, aplicou-se MAE para verificar a acurácia do valor de utilidade previsto pelo sistema para cada um dos itens recomendados, que indicou uma taxa de precisão de 76%. Além disso, 7 dos 10 alunos participantes indicaram que o sistema foi eficiente na tarefa de indicar itens apropriados para o desenvolvimento das competências requeridas (CAZELLA et al., 2009).

4 O DESENVOLVIMENTO DO SISTEMA DE RECOMENDAÇÃO

O presente capítulo descreve a implementação do sistema de recomendação híbrido, apresentando desde a arquitetura do HS até a justificativa da escolha das técnicas de recomendação utilizadas – de filtro colaborativo e baseada em conteúdo – e a maneira com que foram desenvolvidas e inseridas no simulador. É importante ressaltar que o HS é uma ferramenta que já se encontrava em fase de desenvolvimento durante a elaboração da presente pesquisa. Dessa forma, muitas das ferramentas, linguagens e técnicas utilizadas pelo SR já haviam sido selecionadas durante as fases anteriores do projeto. Um exemplo disto é o Sistema Gerenciador de Banco de Dados (SGBD) utilizado: o SQL Server, que é distribuído pela Microsoft¹². Por isso, acredita-se que não é papel deste trabalho justificar a escolha das ferramentas e linguagens empregadas. Busca-se abordar aqui apenas as questões que tangem ao desenvolvimento e implementação do SR.

O subcapítulo 4.1 explana a respeito do armazenamento dos dados no HS, referente ao modelo do banco de dados atual e das alterações inseridas. Em 4.2, apresenta-se a base de dados utilizada para o desenvolvimento do SR, enquanto em 4.3 e 4.4 explica-se a construção do perfil de usuários e itens, respectivamente. No tópico 4.5, apresenta-se a construção do grupo de vizinhos utilizados para as recomendações. Já em 4.6, listam-se as técnicas de recomendação desenvolvidas e a avaliação das mesmas é apresentada no subcapítulo 4.7.

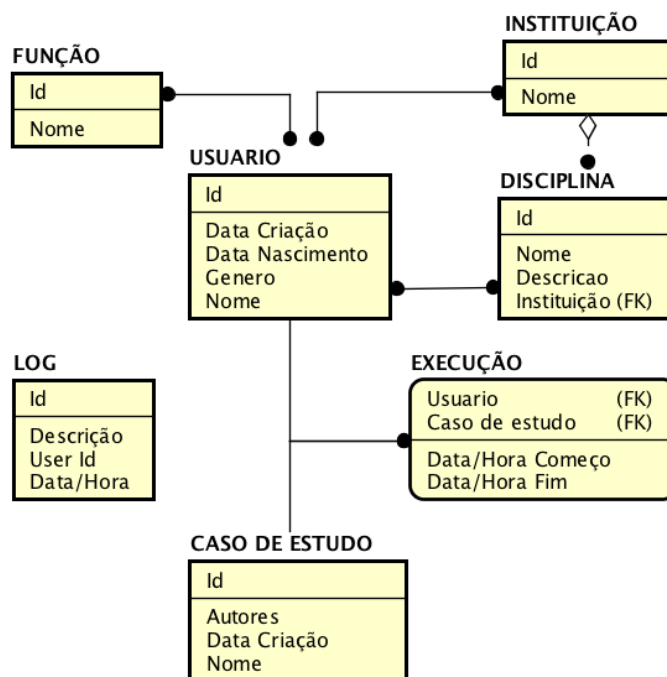
4.1 A respeito do armazenamento dos dados

O simulador já continha diversas entidades responsáveis por representar os objetos do sistema (casos de estudo, disciplinas, usuários, entre outros) e armazenar dados dos mesmos. Sendo assim, o trabalho inicialmente focou em observar quais seriam as alterações necessárias ao banco de dados (BD) – tais como a adição de novas entidades e/ou atributos em entidades já existentes – para que o HS suportasse o SR. A Figura 4.1 mostra o modelo entidade-relacionamento (ER) antes das alterações. Para simplificação e por motivos de segurança, apresenta-se aqui apenas as entidades e atributos utilizados pelo sistema de recomendação ou aqueles que se julga serem mais relevantes para a compreensão do modelo, omitindo entidades com funções do simulador, tais como Avatar, Cenas, entre outros. Para completar, os nomes de

¹² Microsoft SQL Server - <https://www.microsoft.com/pt-br/sql-server>

algumas entidades e atributos foram alterados, ou a relação entre as entidades foi simplificada para facilitar a compreensão do modelo original.

Figura 4.1 – Modelo ER original simplificado



Fonte: elaborado pelos autores

Foi utilizado o software Astah¹³ para a criação do modelo apresentado na Figura 4.1. É possível notar que um usuário do HS está associado à diversas instituições (de ensino, por exemplo), bem como, cursa diversas disciplinas – que estão associadas à uma única instituição. O usuário guarda também uma função – a de aluno e/ou professor, por exemplo. É possível também inferir os casos de estudo com os quais o usuário entrou em contato, sabendo, inclusive, o momento em que a interação ocorreu. É importante notar que, neste momento, casos de estudo não possuem relacionamento direto com instituição ou disciplina.

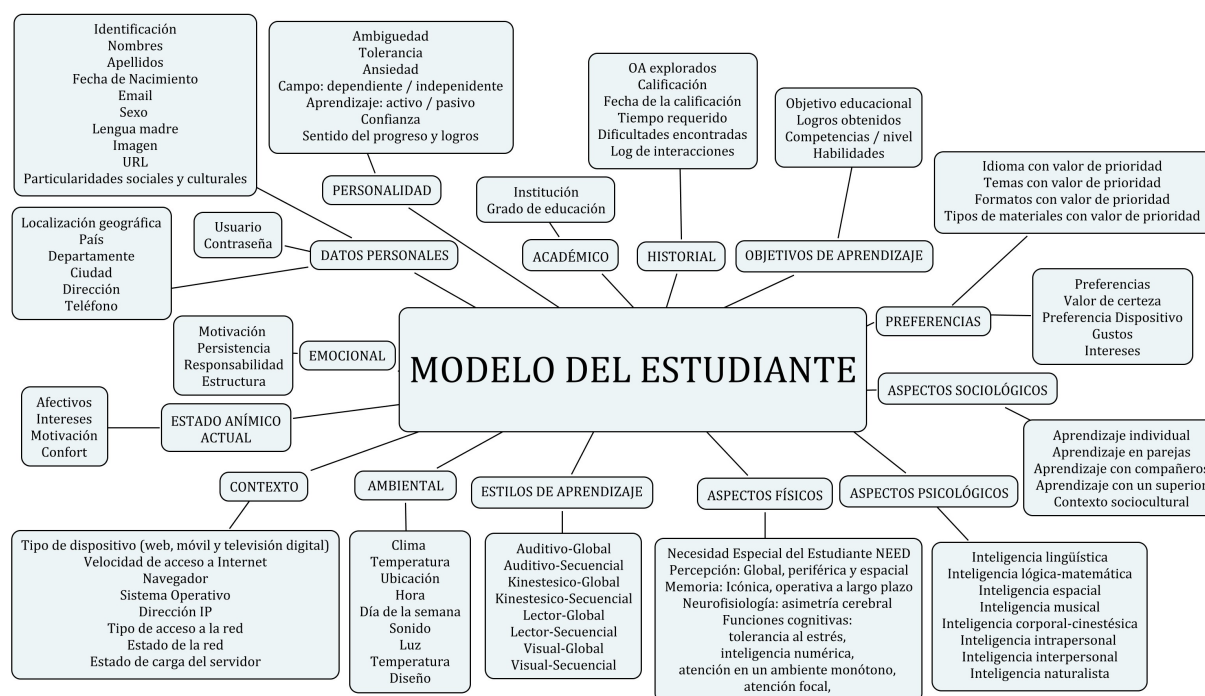
4.1.1 O modelo do usuário

A Figura 4.2 detalha o modelo de um usuário para um sistema de recomendação. É possível encontrar diversas categorias de dados, como informações pessoais, sobre as preferências, aspectos sociológicos ou objetivos de aprendizagem do aluno. Este modelo foi utilizado como referência para a construção do modelo de usuário a ser utilizado no SR do HS.

¹³ Astah - <http://astah.net/>

Ressalta-se que não se busca implementar um modelo que utilize todos os dados listados na figura, mas sim, selecionar aqueles que trarão maior relevância considerando o objetivo do simulador. Escolheu-se trabalhar com um modelo simples, que contém apenas as informações pessoais – muitas das quais já presentes no BD do HS –, acadêmicas, históricas e relativas ao objetivo de aprendizagem e às preferências do aluno. O resultado é apresentado na Figura 4.3.

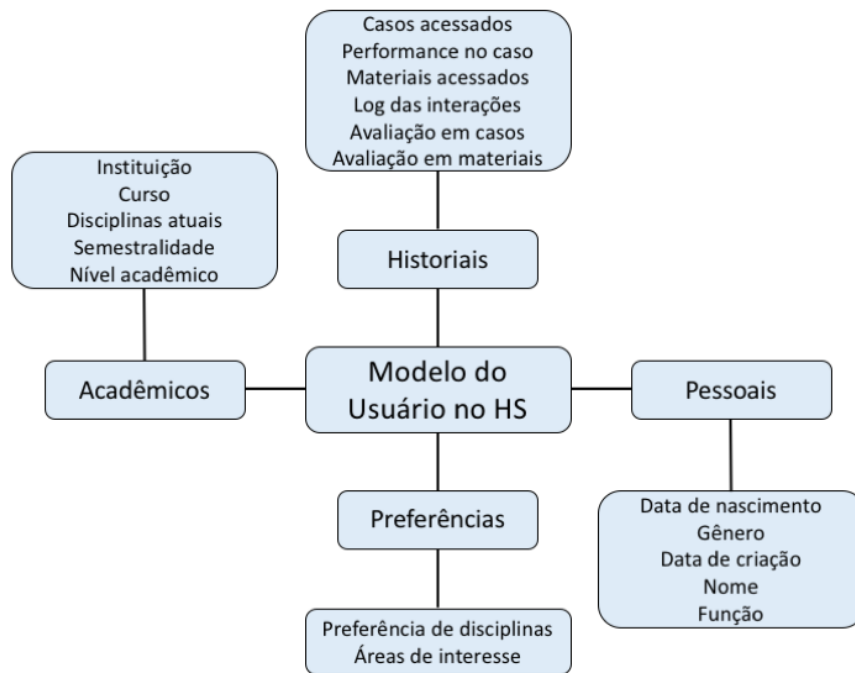
Figura 4.2 - Modelo de usuário detalhado



Fonte: Rodríguez (2016)

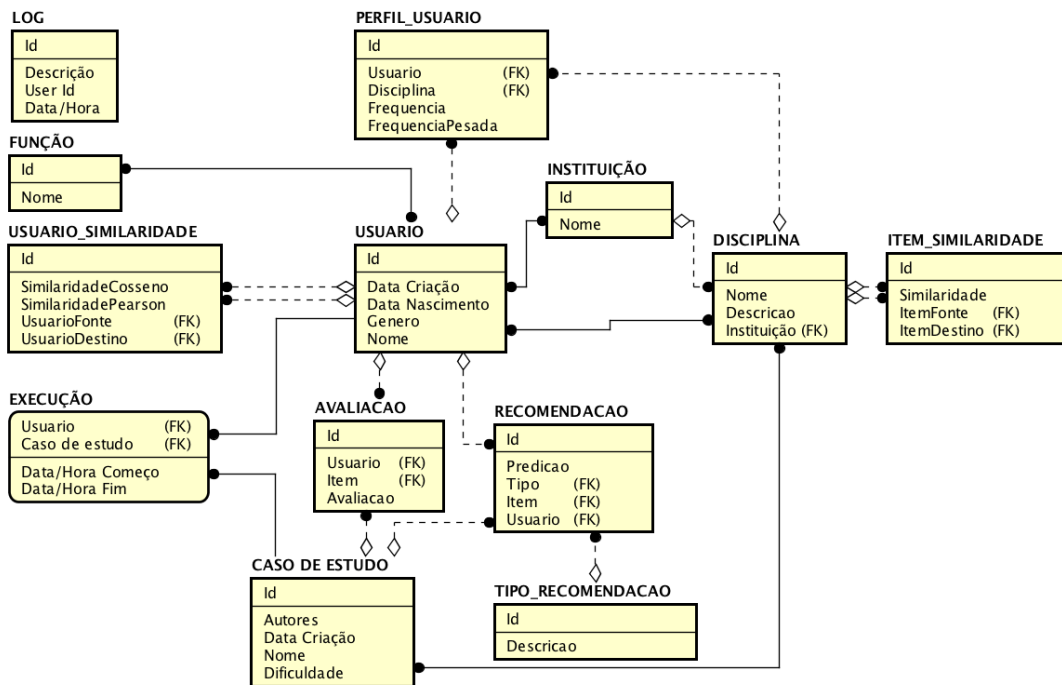
Com isso, alterações ao BD foram necessárias, para introduzir os dados a serem utilizados para a construção do modelo do usuário. Primeiramente, o armazenamento das avaliações realizadas pelos usuários aos casos de estudo no sistema é representado pela entidade “AVALIACAO”. Após, uma tabela para o armazenamento da similaridade entre usuários, que tem seu valor calculado para tanto com a similaridade do cosseno quanto de Pearson, foi implementada. Para permitir o cálculo, foi preciso o desenvolvimento de outra entidade, com o intuito de representar o perfil dos usuários com relação aos casos de estudo avaliados (PERFIL_USUARIO). De forma similar, a similaridade entre itens é registrada em outra tabela. Por fim, as recomendações são também armazenadas, bem como o seu tipo.

Figura 4.3 - O modelo de usuário no HS



Fonte: elaborado pelos autores

Figura 4.4 – Modelo ER resultante das alterações ao BD



Fonte: elaborado pelos autores

4.2 A respeito dos dados escolhidos para o desenvolvimento do SR

O HS, principalmente devido ao fato de ainda se encontrar em desenvolvimento, não conta com um sistema para armazenar a interação do usuário com o simulador. Além disso, não existia, até o início do presente trabalho, uma maneira para que o usuário dê *feedback* ao conteúdo que está consumindo, tornando impossível realizar inferências e predições a respeito das preferências do usuário. Devido a isto, para iniciar o desenvolvimento do SR, decidiu-se por utilizar os dados de uma base de dados aberta para carregar informação às entidades adicionadas ao sistema.

Neste trabalho, é chamado de *dataset* as informações que contém uma base de dados para um sistema de recomendação. São as informações, por exemplo, que dizem respeito às avaliações realizadas por um usuário u em um item i . O passo inicial foi procurar *datasets* abertos que pudessem ser adaptados ao modelo do HS. Diversas foram as opções encontradas, sendo parte delas apresentadas no Quadro 4.1.

Quadro 4.1 - *Datasets* abertos para SR

<i>DATASETS</i> ABERTOS PARA SR	
Yahoo ¹⁴	O Yahoo disponibiliza nove <i>datasets</i> de diferente tamanhos e formatos. Os dados incluem desde a avaliação prestada por usuários em itens como músicas, vídeos e imagens até o <i>click log</i> da interação do usuário (YAHOO, 2017).
Cornell ¹⁵	O departamento de Ciência da Computação da universidade americana Cornell disponibiliza <i>datasets</i> utilizados em algumas das pesquisas lá realizadas. Os dados incluem a avaliação em filmes em uma escala binária e numérica, em quantidades que variam entre 1400, 2000 e 10000 (igualmente divididas entre avaliações positivas e negativas) (PANG; LEE, 2017).

¹⁴ Yahoo – <https://br.yahoo.com>

¹⁵ Cornell – <http://www.cs.cornell.edu>

<i>DATASETS</i> ABERTOS PARA SR	
National University of Singapore ¹⁶	A Universidade Nacional de Singapura, no seu departamento de computação, viabiliza o acesso a <i>datasets</i> relacionados a publicações acadêmicas retirados de dois bancos de dados. O primeiro contém 597 artigos divididos em 28 áreas de estudo. Já o segundo, maior, 100531 publicações divididas em 50 áreas de interesse (SUGIYAMA; KAN, 2017).
Last.fm ¹⁷	Oferece dois <i>datasets</i> focados em músicas. O primeiro contém os artistas já ouvidos por um usuário – incluindo contagem do número de vezes que o usuário ouviu cada artista – para um total de aproximadamente 360 mil usuários. O segundo <i>dataset</i> apresenta o histórico completo das músicas consumidas por um usuário, para mil usuários (CELMA, 2017).

Fonte: adaptado pelos autores

4.2.1 Detalhando a base de dados escolhida

Embora alguns dos *datasets* apresentados tenham se mostrado opções viáveis para uso neste trabalho, o escolhido foi o disponibilizado pelo projeto GroupLens¹⁸ ao tornar acessível informações retiradas do *website* MovieLens¹⁹ (GROUPLENS, 2017). A base de dados é constituída, principalmente, de avaliações realizadas por usuários aos filmes disponíveis na ferramenta. As razões que levaram à escolha por essa opção foram, principalmente, as seguintes:

- Disponibilidade de duas versões de dados: uma menor (recomendada para o desenvolvimento) e outra maior, para pesquisa e publicações. Embora os *datasets* apresentem dados diferentes, o formato dos arquivos é o mesmo, viabilizando que um algoritmo utilizado no primeiro execute corretamente no segundo;

¹⁶ National University of Singagure – <http://www.comp.nus.edu.sg>

¹⁷ Last.fm – <https://www.last.fm>

¹⁸ GroupLens – <https://grouplens.org>

¹⁹ MovieLens – <https://movielens.org/>

- Fácil adequação dos dados ao BD do HS. As informações contidas no *dataset* podem ser incorporadas ao simulador de paciente virtual, servindo de base de dados para desenvolvimento e validação do SR;
- A base de dados é atualizada frequentemente.

Ambas as versões da base de dados apresentam avaliações de usuários a filmes disponíveis no *website*, que estão em uma escala numérica entre 0 e 5, com precisão de 0.5 (tornando possível uma avaliação de 3.5, por exemplo). Além disso, os filmes podem apresentar um ou mais gêneros (comédia, ação, musical, romance, e outras 16 opções) e estão relacionados à múltiplas *tags*. *Tags* são informações textuais similares a palavras-chaves que podem ser inseridas livremente por usuários da ferramenta. Nenhuma informação, que não um número de identificação – o número de usuário do sistema não é apresentado, sendo esse valor alterado para um valor em contagem crescente, tornando inviável a relação entre as avaliações disponibilizadas e o usuário real do serviço – é disponibilizada a respeito dos usuários do sistema, que foram escolhidos aleatoriamente. Os arquivos são formatados com os valores separados por vírgulas (*comma-separated values*, na língua inglesa), sendo as vírgulas em textos escapadas por aspas duplas.

As Figura 4.5, Figura 4.6, e Figura 4.7 mostram o cabeçalho e algumas linhas de conteúdo para três dos principais arquivos da base de dados. Identificadores são consistentes entre os arquivos, de forma que o usuário no arquivo de filmes equivale ao usuário no arquivo de *tags*. Apenas filmes com uma avaliação ou *tag* são incluídos na base de dados (GROUPLENS, 2017).

Figura 4.5 - Cabeçalho e conteúdo para o arquivo de filmes

```
movieId,title,genres
1,Toy Story (1995),Adventure|Animation|Children|Comedy|Fantasy
2,Jumanji (1995),Adventure|Children|Fantasy
3,Grumpier Old Men (1995),Comedy|Romance
4,Waiting to Exhale (1995),Comedy|Drama|Romance
5,Father of the Bride Part II (1995),Comedy
```

Fonte: adaptado de Harper e Konstan (2015, p. 3)

Figura 4.6 - Cabeçalho e conteúdo para o arquivo de avaliações

```
userId,movieId,rating,timestamp
1,2,3.5,1112486027
1,29,3.5,1112484676
1,32,3.5,1112484819
1,47,3.5,1112484727
1,50,3.5,1112484580
```

Fonte: adaptado de Harper e Konstan (2015, p. 3)

Figura 4.7 - Cabeçalho e conteúdo para o arquivo de tags

```
userId,movieId,tag,timestamp
18,4141,Mark Waters,1240597180
65,208,dark hero,1368150078
65,353,dark hero,1368150079
65,521,noir thriller,1368149983
65,592,dark hero,1368150078
```

Fonte: adaptado de Harper e Konstan (2015, p. 3)

A base de dados destinada ao desenvolvimento conta (no momento da elaboração deste trabalho) com duas versões:

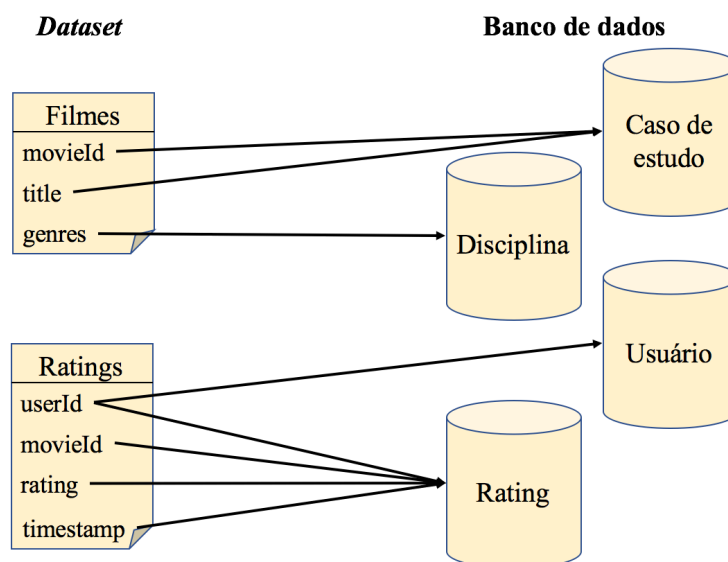
- Uma pequena, com 100.024 avaliações realizadas por 671 usuários a 9.125 filmes que referenciam 1.296 tags. Os usuários foram escolhidos aleatoriamente entre usuários que avaliaram ao menos 20 filmes. Os dados estão datados entre 9 de janeiro de 1995 e 10 de outubro de 2016 (HARPER; KONSTAN, 2015).
- Uma grande, com 24.404.096 avaliações realizadas por 259.137 usuários a 40.110 filmes que referenciam 668.953 tags. Os usuários foram escolhidos aleatoriamente entre usuários que avaliaram ao menos um filme. Os dados estão datados entre 9 de janeiro de 1995 e 17 de outubro de 2016 (HARPER; KONSTAN, 2015). Optou-se por não utilizar essa versão no desenvolvimento do trabalho, atendo-se apenas à versão menor.

Por fim, a versão indicada para pesquisas contém 20.000.263 avaliações de 138.493 usuários para 27.278 itens que são referenciados por 465.564 *tags*. Todos os usuários incluídos avaliaram ao menos 20 itens (HARPER; KONSTAN, 2015).

4.2.2 A inserção dos dados no HS

Uma vez definido o *dataset*, realizou-se a inserção dos dados ao BD. Para tal, os arquivos separados por vírgulas foram traduzidos para comandos SQL normalizados ao BD do HS. O conteúdo do arquivo de filmes foi inserido na entidade Caso de Estudo, com o título do filme sendo mapeado para o nome do caso de estudo. Os gêneros passaram a ser ocorrências da entidade Disciplina, mantendo-se a ligação entre o caso de estudo e a disciplina, obviamente. Cada valor para o número de usuário foi inserido na entidade Usuário, tendo sido os demais atributos obrigatórios escolhidos aleatoriamente. Por fim, as avaliações preencheram a entidade *Rating*, mantendo o valor de criação informado pelo *dataset* e as relações entre usuário e item. A Figura 4.8 ilustra o mapeamento entre o *dataset* e o BD do HS.

Figura 4.8 - Mapeamento entre dataset e BD



Fonte: adaptado pelos autores

4.3 A construção do perfil do usuário

Após importados os dados, foi possível iniciar a construção do perfil do usuário no HS. A construção do perfil é uma etapa importante para o SR, pois ele deve servir de base para

caracterizar cada indivíduo, com base em suas preferências e aptidões. Por isso, a construção do perfil muitas vezes determina o sucesso ou o fracasso de um SR na tarefa de apontar itens relevantes ao usuário. Com base nos dados disponíveis, verificou-se que é possível utilizar o método proposto por Symeonidis, Nanopoulos e Manolopoulos (2007), que constrói um perfil para cada usuário do sistema baseado nas avaliações por ele realizadas. Para tal, o método aponta um peso para cada característica (*feature*, na língua inglesa) de um item, calculado a partir de seu TF-IDF, que representa a importância da *feature* em questão para o indivíduo analisado. O processo que levou à construção do perfil do usuário no HS é descrito a seguir, de acordo com o método de *feature-weighting* proposto por Symeonidis, Nanopoulos e Manolopoulos (2007).

O passo inicial constitui a criação de uma matriz que represente a quantidade de avaliações realizadas pelo usuário para cada *feature* – no caso do HS, para cada disciplina – do sistema. Para tal, é preciso cruzar as avaliações realizadas pelo usuário aos itens e, então, recuperar as disciplinas associadas à cada item. A Figura 4.9 exemplifica o processo, onde U_{1-4} são usuários do HS, I_{1-6} são os itens recomendáveis – casos de estudo, neste momento – e F_{1-4} são as disciplinas associadas aos casos.

Figura 4.9 - Matrizes iniciais para a construção do perfil

	I_1	I_2	I_3	I_4	I_5	I_6
U_1	-	4	-	-	5	-
U_2	-	3	-	4	-	-
U_3	-	-	-	-	-	4
U_4	5	-	3	-	-	-

(a)

	F_1	F_2	F_3	F_4
I_1	0	1	0	0
I_2	1	1	0	0
I_3	0	1	1	0
I_4	0	1	0	0
I_5	1	1	1	0
I_6	0	0	0	1

(b)

	F_1	F_2	F_3	F_4
U_1	2	2	1	0
U_2	1	2	0	0
U_3	0	0	0	1
U_4	0	2	1	0

(c)

Fonte: Symeonidis, Nanopoulos e Manolopoulos (2007, p. 4)

É importante ressaltar que para a construção da matriz a no HS, levou-se em consideração apenas os itens que receberam avaliação maior ou igual a 4 (na escala de 0 – 5). A matriz b é retirada da relação entre casos de estudo e disciplinas. A matriz c é a frequência em que cada uma das disciplinas ocorre nos itens avaliados pelo usuário, representada na Equação ((21), onde $F(i, f)$ é 1 se o item i é relacionado à disciplina f e 0 se não e $R(u, i)$ é a

avaliação do usuário u para o item i (SYMEONIDIS; NANOPOULOS; MANOLOPOULOS, 2007):

$$P(u, f) = \sum_{\forall R(u,i) \geq 4} F(i, f) \quad ((21))$$

O próximo passo requer o uso de TF-IDF para definir o peso de cada disciplina no perfil e encontrar aquelas que melhor descrevem o usuário em questão e o distinguem dos outros membros do HS (SYMEONIDIS; NANOPOULOS; MANOLOPOULOS, 2007). Para tal, é preciso encontrar os seguintes valores:

- $P(u, f)$, já definido anteriormente;
- $UF(f)$, chamada de *User Frequency* (frequência em usuários) no estudo de Symeonidis, Nanopoulos e Manolopoulos (2007). Aponta o número perfis em que a disciplina f ocorre ao menos uma vez;
- $IUF(f)$, chamada de *Inverse User Frequency* (frequência inversa em usuários). É calculada pela Equação (22), onde \mathcal{U} é o número de usuários do sistema. O fator $IUF(f)$ será baixo se a disciplina f está presente em muitos perfis e alto se ela ocorre raramente.

$$IUF(f) = \log \frac{\mathcal{U}}{UF(f)} \quad (22)$$

Com isso, é possível calcular o peso da disciplina f para o usuário u de acordo com a Equação (23). Dessa forma, duas disciplinas que ocorrem com frequência no perfil do usuário poderão ter valores diferentes, uma vez que aquelas que são comuns à muitos outros perfis terão seu valor decrescido (SYMEONIDIS; NANOPOULOS; MANOLOPOULOS, 2007).

$$W(u, f) = P(u, f) \times IUF(f) \quad (23)$$

A Figura 4.10 mostra o perfil resultante para o usuário 354 para 10 disciplinas do HS. É importante notar que mesmo que a disciplina 0 ocorra mais frequentemente se comparada à disciplina 1, o peso da disciplina 1 para distinguir o usuário 354 é maior.

Figura 4.10 - Perfil resultante para um usuário no HS

Usuario	Disciplina	Frequencia	Peso
354	0	13	0,01938852
354	1	7	1,008129
354	2	9	0,7696996
354	3	23	0,03430276
354	4	11	0,4006513
354	5	15	0,08968636
354	6	18	0
354	7	19	0
354	8	10	0,07479466
354	9	11	0,03283584

Fonte: elaborado pelos autores

4.4 A construção do perfil para itens

Para a construção do SR, é preciso também reunir informações a respeito dos itens a serem recomendados. No HS, busca-se construir um algoritmo capaz de recomendar tanto casos de estudo quanto matérias de apoio associados aos casos. Dessa forma, viu-se a necessidade da construção do perfil que represente o conteúdo abordado em um item, seja o caso ou o material de apoio. Para ambos, propõe-se o uso de Symeonidis, Nanopoulos e Manolopoulos (2007), descrito em 4.3. O perfil para um caso de estudo é constituído pelas disciplinas – *features* – as quais ele está associado. Já o perfil dos materiais de apoio, tais quais artigos, vídeos, imagens, entre outros, pode ser construído com o uso de um método de folksonomia, ou com técnicas de mineração de dados, como TF-IDF para os objetos textuais.

4.5 A seleção do grupo de vizinhos

O passo seguinte, após a construção dos perfis que descrevem usuários e itens, foi a implementação dos cálculos de similaridade. Para tal, os algoritmos descritos em 2.1.3.1 foram aplicados ao banco de dados do HS, sendo o método de Pearson (LAMPROPOULOS; TSIHRINTZIS, 2015; TESTA, 2013) aplicado apenas ao filtro colaborativo e a distância do cosseno (CATAE, 2012, p. 34) à ambas as técnicas (CF e CBF). A similaridade entre usuários e entre itens foi então calculada para cada ocorrência destes no sistema. Parte dos resultados é apresentado na Figura 4.11, onde o quadro (a) apresenta o resultado do cálculo da similaridade do Usuário 1 para outros 10 usuários e o quadro (b) mostra a similaridade do Item 1 para outros 10 itens.

Figura 4.11 - Similaridade para usuários e itens

	Usuario	Comparado	Cosseno	Pearson
1	1	471	0,05024774	-1
2	1	212	0,06077787	-0,002793165
3	1	308	0,006482903	-1
4	1	533	0,3498239	0,497105
5	1	90	0,1642979	1
6	1	134	0,1224362	1
7	1	654	0,08279055	-0,744487
8	1	619	0,03365316	1
9	1	361	0,07339171	1
10	1	309	0,03573377	0,09969587

(a) Similaridade para Usuário 1

	Item	Comparado	Cosseno
1	1	1024	0,5163978
2	1	1085	0,3162278
3	1	3157	0,7745967
4	1	3743	0,3162278
5	1	1082	0
6	1	3845	0
7	1	56169	0
8	1	5313	0,4472136
9	1	89753	0
10	1	1801	0,2581989

(b) Similaridade para Item 1

Fonte: elaborado pelos autores

Como a complexidade dos algoritmos utilizados é alta, assim como o número de usuários e itens inseridos ao banco de dados, essa etapa deve tomar um tempo considerável. Devido a isso, adotou-se a estratégia de calcular a similaridade para um grupo menor de usuários e itens e fazê-lo diariamente, em um período de pouca utilização do sistema. Dessa forma, toda vez que os algoritmos são executados cada usuário/item tem a sua similaridade calculada para outros 100 usuários/itens escolhidos de forma arbitrária. Esse procedimento é realizado diariamente, garantindo que o número de comparações disponíveis cresça com o tempo.

Uma vez calculadas as similaridades, basta escolher aqueles que são mais similares ao usuário ou item para o qual se busca realizar uma recomendação. Nesta etapa, optou-se por descartar do grupo de vizinhos todos aqueles que apresentem uma similaridade menor a 0.8 e utilizar os restantes para a construção da recomendação.

4.6 As técnicas de recomendação desenvolvidas

Por fim, as técnicas de recomendação foram implementadas, consumindo as informações resultantes dos algoritmos de similaridade. Para tal, os métodos do filtro colaborativo baseado em usuários e da recomendação baseada em conteúdo foram desenvolvidos. Após, os métodos híbridos adaptativo, misto e da intersecção dos conjuntos foram construídos.

Todos os métodos foram avaliados e comparados de acordo com as métricas descritas em 2.4, estando os resultados obtidos descritos no subcapítulo 4.7. Todas as técnicas foram desenvolvidas e armazenadas no banco de dados do HS, utilizando a linguagem Transact-SQL. As implementações são descritas a seguir.

4.6.1 Filtro colaborativo baseado no usuário

Para a criação da técnica de filtro colaborativo, busca-se inicialmente por todas as avaliações realizadas por usuários com uma similaridade maior ou igual a um limite estabelecido para com o usuário ativo. No caso desta técnica, notou-se que um limite de similaridade de 0.8 apresenta bons resultados na busca pelo grupo de vizinhos. Uma vez conhecido este grupo, faz-se a média ponderada entre as avaliações realizadas aos itens e a similaridade, para cada um dos itens – limitando-se apenas a considerar os itens com avaliações maiores ou iguais a 4, como apontado por Symeonidis, Nanopoulos e Manolopoulos (2007).

Os resultados dessa consulta formam uma relação entre itens (casos de estudo) e a média ponderada das avaliações realizadas pelos usuários membros do grupo de vizinhos do indivíduo a quem se deseja recomendar. Antes de armazenar esses resultados na tabela de recomendações realiza-se um arredondamento da média, visando maior precisão nas métricas de acurácia. Uma vez que a base de dados contém avaliações entre 0 e 5, num intervalo de 0.5 não é viável que um usuário avalie um item com 4.1618 ou 4,45 por exemplo. Dessa forma, arredonda-se o valor da predição sempre para o múltiplo de 0.5 mais próximo (neste exemplo, 4 e 4.5 respectivamente).

4.6.2 Recomendação baseada em conteúdo

Para as recomendações baseadas em conteúdo, busca-se pelos itens bem avaliados pelo usuário ativo. Para cada um destes, procura-se por outros itens com um perfil idêntico – similaridade igual a 1 – ao item em questão. Estes itens são então recomendados ao usuário, com a predição igual ao valor do item inicialmente avaliado pelo usuário.

4.6.3 Método híbrido adaptativo

Um método híbrido adaptativo foi construído no banco de dados, buscando aumentar o número de recomendações disponíveis ao usuário na ocorrência de serem poucos os resultados

apresentados pela técnica colaborativa. Desta forma, uma vez executada a técnica colaborativa para um usuário e notando-se que o número de recomendações geradas é inferior a 20, executa-se em sequência a técnica baseada em conteúdo. Na ocorrência de um item ser recomendado por ambos os métodos, a predição do valor da recomendação será a média do valor previsto pelas técnicas.

4.6.4 Método híbrido misto

O método híbrido é bastante simples: executa-se primeiro a recomendação de filtro colaborativo e logo a seguir o algoritmo baseado em conteúdo. O resultado de ambas as técnicas é apresentado ao usuário, como recomendação. Na ocorrência de um item ser recomendado por ambos os métodos, a predição do valor da recomendação será a média do valor previsto pelas técnicas.

4.6.5 Método híbrido da intersecção dos conjuntos

O método da intersecção dos conjuntos apresenta como recomendação somente os itens presentes no resultado de ambas as técnicas. Desta forma, é normal que este método apresente um número de recomendações menor que o resultante dos outros métodos utilizados. O valor da predição é, novamente, a média do valor previsto pelas técnicas.

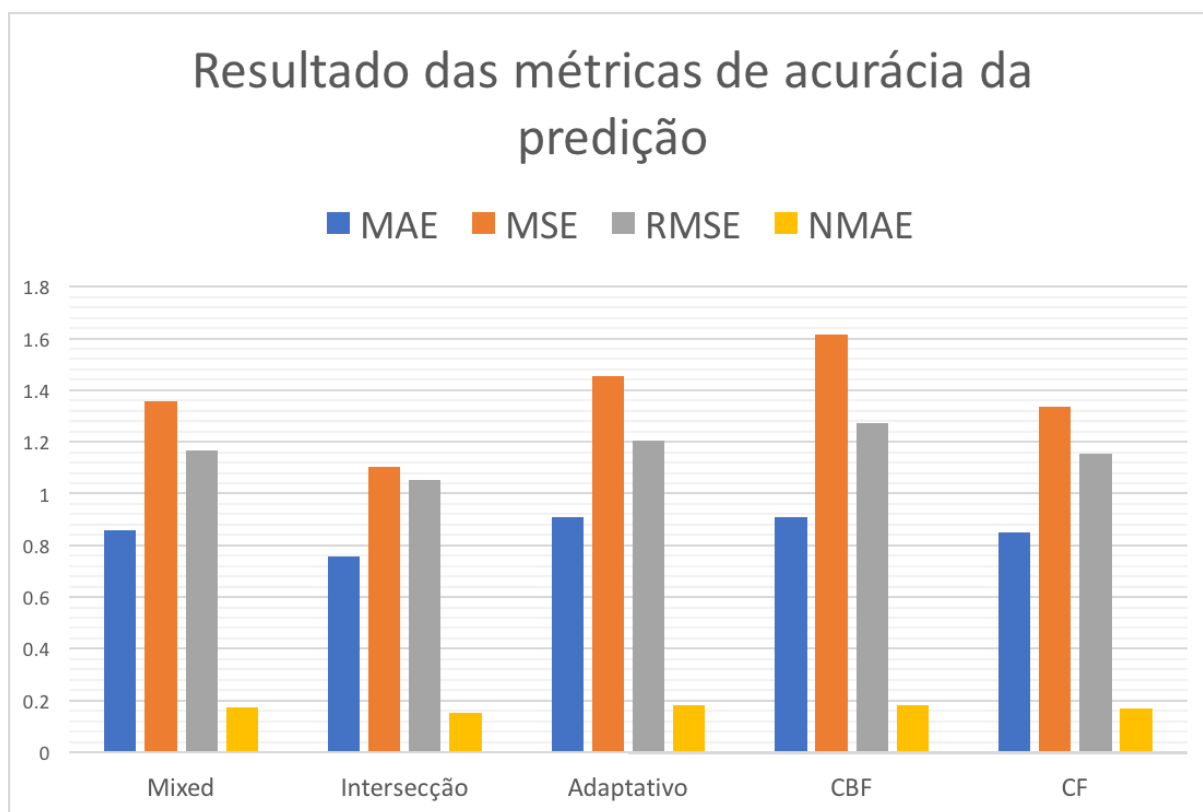
4.7 Resultados obtidos

Todos os métodos desenvolvidos foram avaliados de acordo com as métricas de acurácia da predição e da classificação descritas em 2.4. Os resultados são apresentados neste capítulo, bem como uma discussão a respeito dos mesmos. De maneira geral, o método da intersecção dos conjuntos obteve melhores resultados no que diz respeito às métricas de acurácia da predição.

A Figura 4.12 mostra as métricas de acurácia da predição obtidas para cada um dos métodos implementados. Em todas as métricas, a técnica que apresentou melhores resultados foi o algoritmo híbrido da intersecção dos conjuntos. Para MAE, que aponta o erro médio da predição com relação ao valor real avaliado pelo usuário, o menor valor obtido foi 0.75, enquanto o pior foi 0.9107, com o método adaptativo. Obteve-se, portanto, pouca variação entre as 5 técnicas desenvolvidas. Com relação às métricas de MSE e RMSE, que penalizam mais

severamente os erros maiores – se comparado à MAE – os piores valores obtidos foram com o método de recomendação baseada em conteúdo (1,6149 e 1,2707, respectivamente). Já o algoritmo de filtros colaborativos apresentou resultados melhores (1,3363 e 1,1559). Devido a isto, conclui-se que CFB está impactando negativamente no resultado das demais algoritmos híbridos, uma vez que CF apresentou resultados melhores que as outras técnicas com exceção do método da intersecção dos conjuntos. Acredita-se que o valor menor para a técnica da intersecção se de ao fato de que esse método é mais rigoroso na escolha dos itens a serem recomendados, incluindo apenas aqueles presentes em ambas as técnicas de CF e CBF. NMAE também foi calculada e apresentada, permitindo que as técnicas sejam comparadas entre sistemas que usam escalas de avaliação diferentes.

Figura 4.12 - Resultado das métricas de acurácia da predição

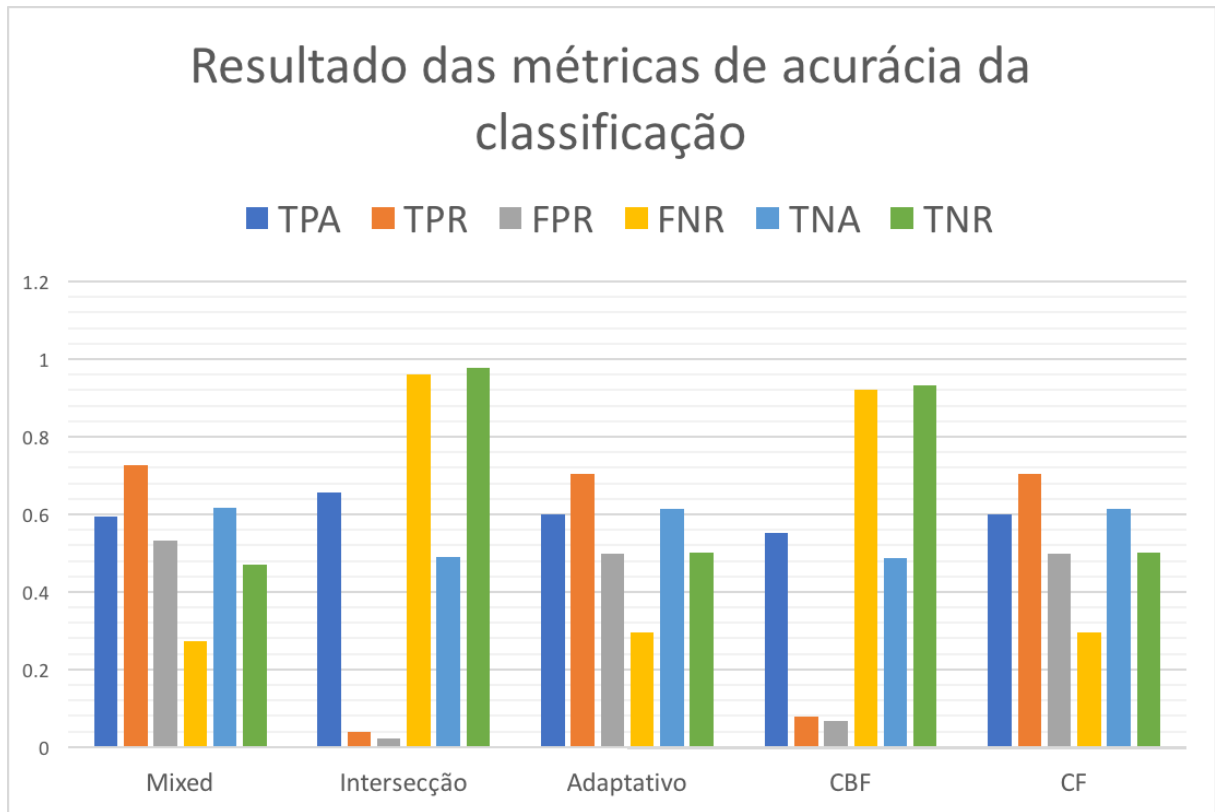


Fonte: elaborado pelos autores

A Figura 4.13 mostra o resultado das métricas de acurácia da classificação. No que diz respeito à precisão (TPA), novamente o método híbrido da intersecção dos conjuntos apresentou melhores resultados, com uma porcentagem de pouco mais de 65%. Esta métrica aponta a fração dos itens recomendados que são de fato relevantes ao usuário. A variação entre o restante dos algoritmos, entretanto, não é grande, com o pior valor sendo de 55%, obtido com

CBF. Com relação à sensibilidade (TPR), entretanto, a intersecção dos conjuntos apresentou resultados muito ruins, assim como CBF – 3% e 7%, respectivamente. Tais resultados são explicados pelo fato de estas técnicas terem gerado poucas recomendações se comparadas à CF. Para os 671 usuários, CFB apresentou 126.697 recomendações e a intersecção dos conjuntos apresentou 17.703, enquanto CF gerou 653.901 recomendações. Sendo assim, para TPR, o melhor valor foi obtido com o método misto – o que é justificado pelo fato de que este algoritmo apresenta o maior número de resultados entre todas as técnicas. O *miss rate* – métrica que aponta a porcentagem de itens que deveriam ser recomendados e não foram – apresenta resultados similares, com técnicas que geram um grande número de recomendações apresentando os melhores resultados. Já pra *Fallout* (FPR), que aponta a probabilidade de um item irrelevante ser recomendado, a relação se inverte, com algoritmos que apresentam grande quantidade de recomendações com resultados ruins, enquanto a intersecção e CBF apresentam ótimos resultados. O mesmo ocorre com TNR, uma vez que esses algoritmos filtram mais precisamente os itens irrelevantes. Com a métrica de TNA, que apresenta a percentagem de itens não recomendados que são de fato irrelevantes, notou-se que CBF, mais uma vez, apresenta os piores resultados, enquanto os outros métodos (diretamente impactados por CF) apresentam resultados melhores – embora apenas ligeiramente acima de 60%.


Figura 4.13 - Resultado das métricas de acurácia da classificação I



Fonte: elaborado pelos autores

A Figura 4.14 mostra o resultado das métricas combinadas. É possível notar que F1 apresenta resultados melhores onde há balanço entre TPA e TPR. Dessa forma, nos métodos híbridos onde CF impacta com mais peso, os resultados são melhores. O mesmo fenômeno pode ser observado para as demais métricas: os métodos onde há forte impacto de CF apresentam todos resultados bastante similares.

Figura 4.14 - Resultado das métricas de acurácia da classificação II



Fonte: adaptado pelos autores

Sendo assim, é possível notar que o SR do tipo CBF necessita de alterações, buscando melhorar a qualidade das indicações realizadas. Apesar disto, o SR do tipo CF apresentou bons resultados, já podendo ser utilizado para apontamento de casos de estudo no HS. Ainda é necessário, entretanto, adaptar o *front-end* do jogo, possibilitando ao usuário uma maneira para avaliar os materiais e casos de estudo consumidos, bem como criar uma interface onde ele poderá acessar as recomendações selecionadas pelos algoritmos executados. Na conclusão deste trabalho, estes tópicos são abordados e discutidos, principalmente no que diz respeito à trabalhos futuros.

CONCLUSÃO

O presente trabalho teve como objetivo desenvolver um sistema de recomendação de casos clínicos e materiais de estudo que favoreçam o aprendizado do aluno no HS, fazendo-se uso de estratégias de recomendação modernas que possam ser aplicadas à área da educação em saúde. Para tal, o sistema deve auxiliar pedagogicamente o aluno, atuando de forma ativa durante a partida, avaliando o desempenho do aluno e oferecendo recomendações pertinentes à sua fase de aprendizado.

No Capítulo 1, introduziu-se o tema dos simuladores de ensino em saúde, apresentando também o HS, plataforma para a qual o sistema de recomendação foi construído. Já no Capítulo 2, foram estudados os conceitos gerais da área de SR e analisaram-se as diferentes técnicas de recomendação utilizadas na comunidade científica. O Capítulo 3 discutiu o tema de SR em plataformas voltadas à educação, abordando as necessidades e requisitos especiais para este tipo de sistema. Por fim, o Capítulo 4 apresentou o desenvolvimento das técnicas de recomendação, bem com a sua implantação no HS e a posterior avaliação dos mesmos. Sendo assim, todos os objetivos específicos deste trabalho foram alcançados.

O referencial teórico utilizado neste trabalho apontou que as técnicas de recomendação mais comuns são as de filtro colaborativo e baseadas em conteúdo, com os métodos mistos e adaptativos mostrando melhores resultados para fazer a junção das técnicas em um algoritmo híbrido. Desta forma, os métodos de CBF e CF foram implantados ao *back-end* do simulador, juntamente com algoritmos híbridos mistos, adaptativos e da intersecção dos conjuntos. Os estudos apontam também a importância da escolha correta no que diz respeito à avaliação das recomendações geradas pelo SR, uma vez que a escolha de uma métrica ruim pode causar impacto negativo sobre a qualidade da recomendação. Por este motivo, todos os métodos construídos foram avaliados tanto no que diz respeito à precisão da predição, quanto à acurácia da classificação.

Os resultados mostram que o algoritmo do tipo CF obteve melhores resultados, se comparado a CBF. O método de CBF desenvolvido não foi capaz de gerar uma quantidade grande de recomendações, fazendo com que métricas como a sensibilidade e o *miss rate* sejam impactadas diretamente e, por isso, apresentem resultados ruins. Como consequência de o método híbrido da intersecção dos conjuntos depender diretamente da qualidade da recomendação, tanto de CBF quando de CF, seu resultado também sofreu influência. Não obstante, o valor da precisão para este método também é baixo, tornando possível a conclusão

que CFB está impactando negativamente no resultado dos demais algoritmos híbridos. Conclui-se que é preciso fazer alterações ao método proposto, para que gere maior número de recomendações e que estas sejam mais pertinentes ao usuário ativo.

Por outro lado, o método de CF proposto apresentou resultados satisfatórios, com precisão próxima a 60%, sensibilidade próxima a 70% e MAE em torno de 0.85. Embora reconheça-se que estes resultados ainda não sejam ideais, acredita-se que o algoritmo já possa ser utilizado no HS, ressaltando-se a necessidade de atualizações que busquem melhorar o resultado das métricas calculadas.

É importante, também, apontar a importância da escolha adequada dos dados que irão compor o modelo de usuários e itens – com informações que podem ser implícitas ou explicitamente adquiridas – no processo de melhoria dos métodos propostos. No presente cenário, onde o HS está ainda em fase de desenvolvimento, não foi possível fazer uso de dados reais a respeito dos usuários ou itens, em um ambiente adequado ao simulador. Utilizou-se de uma base de dados aberta, oriunda de um sistema com um objetivo diferente do buscado pelo HS. Desta forma, não foi possível trabalhar exaustivamente no modelo de usuários e itens. Acredita-se que, uma vez que o sistema esteja pronto para ser utilizado e contenha dados reais, será possível usar informações mais relevantes ao SR. Isto deve melhorar a qualidade da recomendação realizada e auxiliar ainda mais o aluno no processo de aprendizado.

Ressalta-se que a base de dados utilizada para realização do trabalho foi uma base de dados de desenvolvimento, não recomendada para utilização em publicações. A justificativa desta escolha não foi outra senão o tamanho das bases de dados, se comparado ao volume de informação no HS. A base utilizada conta com aproximadamente 100 mil avaliações, enquanto a recomendada para publicações conta com mais de 24 milhões de registros. Desta forma, acredita-se que a base menor descreva melhor o cenário esperado para o HS.

Além disto, diversas outras são as oportunidades de trabalhos futuros neste tópico. Inicialmente, é preciso realizar alterações ao *front-end* do simulador, permitindo que o usuário visualize as recomendações de uma maneira imersiva ao jogo sério. É necessário, também, que o usuário possa realizar avaliações ao conteúdo por ele acessado, seja aos materiais ou aos casos de estudo. Ainda a respeito do *front-end*, é preciso fornecer a possibilidade de o aluno informar as suas áreas e disciplinas de interesse e, obviamente, utilizar essas informações na construção das recomendações.

De outro lado, a pesquisa realizada apontou que os sistemas de recomendação de propósito geral não são indicados para uso em plataformas voltadas à educação, principalmente por deixar de abordar questões importantes para essa área. Desta forma, acredita-se que não se deva encarar os algoritmos desenvolvidos como uma solução definitiva para uso no HS. Eles são um passo inicial na construção de um sistema capaz de ajudar o aluno durante a execução dos casos e posteriormente, na escolha de um novo desafio a se trabalhar. Uma das tarefas ainda pendentes é a utilização das informações armazenadas nas redes bayesianas do simulador na elaboração das recomendações.

Ainda, a experiência adquirida pela análise de trabalhos relacionados mostrou que, muitas vezes, mais do que uma recomendação extremamente precisa, um usuário valoriza uma boa justificativa para a recomendação proposta. Desta forma, busca-se construir também esta funcionalidade no HS. Para tal, alterações serão necessárias tanto no *front-end* quanto no *back-end*. Acredita-se que isto deverá impactar positivamente no número de itens acessados devido à recomendação, e mostra-se como uma boa oportunidade para pesquisas futuras.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALVES, F. A. S. **Sistema de recomendações no SAPO Campus**: desenvolvimento e avaliação. 2013. 100 f. Dissertação (Mestrado em Comunicação Multimídia) – Departamento de Comunicação e Arte, Universidade de Aveiro, Aveiro, Portugal, 2013. Disponível em: <<https://ria.ua.pt/bitstream/10773/12312/1/tese.pdf>>. Acesso em: 2 nov. 2016.
- AMAZON. Disponível em: <<https://www.amazon.com/>>. Acesso em: 20 out. 2016.
- AUDINO, D. F. **Objetos de aprendizagem hipermídia aplicado à cartografia escolar no sexto ano do ensino fundamental em geografia**. 2012. 152 f. Dissertação (Mestrado em Geografia) – Programa de Pós-Graduação em Geografia, Universidade Federal de Santa Catarina, Florianópolis, 2012. Disponível em: <<https://repositorio.ufsc.br/bitstream/handle/123456789/99501/303100.pdf>>. Acesso em: 30 out. 2016.
- BANKS, J. et al. **Discrete-event system simulation**. 5 ed. New Jersey, US: Prentice Hall, 2009. 640p.
- BARROS, P. R. M. et al. Um simulador de casos clínicos complexos no processo de aprendizagem em saúde. **Novas Tecnologias na Educação**, Porto Alegre, v. 10, n. 1, jul. 2012. Disponível em: <<http://seer.ufrgs.br/index.php/renote/article/view/30867/19223>>. Acesso em: 20 ago. 2012.
- BEEL, J. et al. *The impact of demographics (age and gender) and other user-characteristics on evaluating recommender systems*. In: Proceedings of the 17th International Conference on Theory and Practice of Digital Libraries, 2013, Valleta. **Anais...** Springer: New York, 2013. p.400-404.
- BEZ, M. R., VICARI, R. M., FLORES, C. D. Métodos ativos de aprendizagem: simulador de casos clínicos – SimDeCS. **RETEME**, São Paulo, v. 2, n. 2, jun. 2012. p.146-166.
- BEZ, M. R. **Construção de um modelo para o uso de simuladores na implementação de métodos ativos de aprendizagem nas escolas de medicina**. 2013. 314 f. Tese (Doutorado em Informática na Educação) – Programa de Pós-graduação em Informática na Educação, Centro Interdisciplinar de Novas Tecnologias na Educação, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2013. Disponível em: <<http://www.lume.ufrgs.br/handle/10183/70612>>. Acesso em: 10 set. 2016.
- BEZ, M. R. et al. Influence diagram for selection of pedagogical strategies in a multi-agent system learning. In: Proceedings of the 13th edition of the Ibero-American Conference on Artificial Intelligence, 2012, Cartagena. **Anais...** Berlin: Springer Verlag, 2012. v. 1, p. 621-630.
- BEZ, M. R. et al. Simulador inteligente para a tomada de decisão em cuidados de saúde – SimDeCS. **Espaço para a Saúde**, Londrina, v. 15, n. 1, jun. 2014. p.599-609.
- BEZ, M. R. et al. Health Simulator. In: Congresso de Indústria Criativa, 2015, Novo Hamburgo. **Anais eletrônicos...** Novo Hamburgo: Feevale, 2015. p. 60-65. Disponível em: <<http://www.feevale.br/Comum/midias/91604e72-f948-4058-8727-0cb7df6b9183/Indústrias%20Criativas.pdf>>. Acesso em: 20 ago. 2016.
- BOBADILLA, J., ORTEGA, F., GUTIÉRREZ, A. *Recommender systems survey*. **Knowledge-Based Systems**, Madrid, v. 46, p.109-132, jun. 2013.

- BOTEZATU, M.; HULT, H.; FORS, U. G. *Virtual patient simulation: what do students make of it? A focus group study*. **BMC Medical Education**, [Londres, UK], v. 10, n. 91, dez. 2010. Disponível em: <<https://bmcmmededuc.biomedcentral.com/articles/10.1186/1472-6920-10-91>>. Acesso em: 15 ago. 2010.
- BURKE, R. *Hybrid web recommender systems*. In: BRUSILOVSKY, P., KOBSA, A., NEJDL, W. **The adaptive web: Methods and strategies of web personalization**. New York: Springer, 2002. cap. 12, p.377-408.
- BURKE, R. Integrating knowledge-based and collaborative-filtering recommender systems. **Proceedings of the Workshop on AI and Electronic Commerce**, [S.l.], v.1 n.1, p.69-72, 1999.
- CAMPOS, L. M., et al. *Combining content-based and collaborative recommendations: a hybrid approach based on Bayesian networks*. **International Journal of Approximate Reasoning**, New York, v. 51, n. 7, p.785-799, set. 2010.
- CATAE, F. S. **Classificação automática de texto por meio de similaridade entre palavras: um algoritmo mais eficiente**. 2012. 106 f. Dissertação (Mestrado em Engenharia Elétrica) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2012. Disponível em: <http://www.teses.usp.br/teses/disponiveis/3/3141/tde-06072014-225124/publico/Diss_FabricioCatae.pdf>. Acesso em: 30. out. 2016.
- CAZZELA, S. C. et al. Recomendação de Objetos de Aprendizagem empregando filtragem colaborativa e competências. In: XX Simpósio Brasileiro de Informática na Educação, 2009, Florianópolis. **Anais eletrônicos...** Florianópolis: UFSC, 2009. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/issue/view/36>>. Acesso em: 2 nov. 2016.
- CELMA, O. **Music recommendation datasets for research**. Disponível em: <<http://www.dtic.upf.edu/~ocelma/MusicRecommendationDataset/index.html>>. Acesso em: 30 abr. 2017.
- CHAI, T., DRAXLER, R. R. Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. **Geoscientific Model Development**, Munich, v. 7, n. 3, p.1247-1250, jun. 2014.
- CREMONESI, P.; KOREN, Y.; TURRIN, R. *Performance of recommender algorithms on top-N recommendation tasks*. In: Proceedings of the 4th ACM conference on Recommender systems, 2010, New York. **Anais...** ACM: New York, 2010. p.39-46.
- FAZIO, M. R. **Previsão de avaliações em sistemas de recomendação para nichos de mercado**. 2013. 114 f. Dissertação (Mestrado em Engenharia de Sistemas e Computação) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2013. Disponível em: <<http://www.cos.ufrj.br/uploadfile/1365598708.pdf>>. Acesso em: 26 ago. 2016.
- FENG, D. Utility-based recommender systems using implicit utility and genetic algorithm. In: 2015 International Conference on Mechatronics, Electronic, Industrial and Control Engineering, 2015, Shenyang. **Anais...** Atlantis Press: Amsterdam, 2015. p.860-864.
- FRAIHAT, S. SHAMBOUR, Q. *A framework of semantic recommender system for e-Learning*. **Journal of Software**, [S.l.], v. 10, n. 3, p.317-330, mar. 2015.
- GHAUTH, K. I., ABDULLAH, N. A. *Learning materials recommendation using good learners' ratings and content-based filtering*. **Educational Technology Research and Development**, New York, v. 58, n. 6, p.711-727, mar. 2010.

GHAUTH, K. I., ABDULLAH, N. A. *The effect of incorporating good learners' ratings in e-Learning content-based recommender system*. **Educational Technology & Society**, [S.l], v. 14, n. 2, p.248-257, abr. 2011.

GOLDBERG, D. et al. *Using collaborative filtering to weave an information Tapestry*. **Communications of the ACM**, [S.l], v. 35, n. 12, p.61-70, dez. 1992.

GROUPLENS. *MovieLens datasets*. Disponível em <<https://grouplens.org/datasets/movielens/>>. Acesso em 30 abr. 2017.

GUNAWARDANA, A., SHANI, G. *A survey of accuracy evaluation metrics of recommendation tasks*. **Journal of Machine Learning Research**, [S.l], v. 10, p.2935-2962, nov. 2009.

HARPER, F. M., KONSTAN, J. A. *The MovieLens datasets: history and context*. **ACM Transactions on Interactive Intelligent Systems**, [S. l], v. 5, n. 4, 19 – 19:19, dez. 2015.

HECKEL, G. et al. Projeto Health: produção de personagens tridimensionais. In: Gamepad VIII, 8., 2015, Novo Hamburgo. **Anais...** Novo Hamburgo: Feevale, 2015. p. 1-17.

HELWANGER, F. A.; ROLIM, M. P.; BARROS, P. R. M. Arquitetura de comunicação do Health Simulator. In: Gamepad VIII, 8., 2015, Novo Hamburgo. **Anais...** Novo Hamburgo: Feevale, 2015. p. 1-14.

HERLOCKER, J. et al. *Evaluating collaborative filtering recommender systems*. **Transactions on Information Systems**, New York, v. 22, n. 1, 2004. Disponível em: <<http://grouplens.org/site-content/uploads/evaluating-TOIS-20041.pdf>>. Acesso em: 16 out. 2016.

HIGGS, J. et al. *Clinical reasoning in the health professions*. 3. ed. Sydney, AU: Elsevier Health Sciences, 2008.

HOLZINGER, A. et al. Learning performance with interactive simulations in medical education: lessons learned from results of learning complex physiological models with HAEMODynamics SIMulator. **Computer & Education**, [Amsterdam, NL], v. 52, n. 2, p. 292-301, fev. 2009.

HUANG, S. Designing utility-based recommender systems for e-commerce: Evaluation of preference-elicitation methods. **Electronic Commerce Research and Applications**, New York, v. 10, n. 4, p.398-407, jun. 2011.

IMISON, M., HUGHES, C. *The virtual patient project: using low fidelity, student generated online cases in medical education*. In: ascilite, 2008, Melbourne. **Anais...** Melbourne: Deakin University, 2008. Disponível em: <<http://www.ascilite.org/conferences/melbourne08/procs/imison.pdf>>. Acesso em: 13 out. 2016.

KENDALL, M. *A new measure of rank correlation*. **Biometrika**, [S.l], v. 30, n. 2, p.81-89, 1938.

LAMPROPOULOS, A. S.; TSIHRINTZIS, G. A. *Review of previous work related to recommender systems*. In: _____. **Machine Learning Paradigms**. New York, USA: Springer, 2015. cap. 1, p.13-30.

LIKERT, R. *A technique for the measurement of attitudes*. **Archives of Psychology**, New York, v. 22, n. 140, p.5-55, jun. 1932.

- LIMA, A. et al. Projeto para desenvolvimento do simulador Health Simulator. In: *Computer on the Beach*, 2015, Florianópolis. **Anais...** Florianópolis: UNIVALI, 2015. p.279-288.
- LIMA, M. A., VARELO, M. F. F., NASCIMENTO, A. Q. O uso de simuladores virtuais para o ensino de química. In: VII Congresso Norte Nordeste de Pesquisa e Inovação, 2012, Palmas. **Anais...** Palmas: Instituto Federal do Tocantins, 2012.
- LINDEN, G., et al. Recommendation algorithms, online privacy, and more. **Communications of the ACM**, [S.l.], v. 52, n. 5, p.10-11, mai. 2009.
- LOPES, G. R. **Avaliação e recomendação de colaborações em redes sociais acadêmicas**. 2012. 129 f. Tese (Doutorado em Ciência da Computação) – Programa de Pós-graduação em Computação, Instituto de Informática, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2012. Disponível em: <<https://www.lume.ufrgs.br/bitstream/handle/10183/54886/000854154.pdf>>. Acesso em: 26 ago. 2016.
- MACEDO, J. A., DICKMAN, A. G., ANDRADE, I. S. F. Simulações computacionais como ferramentas para o ensino de conceitos básicos de eletricidade. **Caderno Brasileiro de Ensino em Física**, v. 29, n. 1, p. 562-613, set. 2012.
- MANOUSELIS, N. et al. *Recommender systems in technology enhanced learning*. In: RICCI, F. et al. **Recommender systems handbook**. New York, USA: Springer, 2010. p.387-409.
- MARONI, Vinícius. Construção de um motor de inferência para análise de desempenho em ambientes virtuais de aprendizagem aplicados ao ensino da medicina de família e comunidade. 2013. 103 f. Dissertação (Mestrado em Ciências da Saúde) – Universidade Federal de Ciências da Saúde de Porto Alegre, Porto Alegre, RS, 2013.
- MARQUES, R. L., DUTRA, I. Redes Bayesianas: o que são, para que servem, algoritmos e exemplos de aplicações. **Coppe Sistemas**, Rio de Janeiro, 2002. Disponível em: <<http://www.cos.ufrj.br/~ines/courses/cos740/leila/cos740/Bayesianas.pdf>>. Acesso em: 14 nov. 2016.
- MARTINS, J. C. A. et al. **A simulação no ensino de enfermagem**. Coimbra: Escola Superior de Enfermagem de Coimbra, 2014. 310 p.
- MELLO, B., STAHNKE, F., BEZ, M. Projeto para desenvolvimento do simulador Health Simulator. In: *Gamepad VIII*, 8., 2015, Novo Hamburgo. **Anais...** Novo Hamburgo: Feevale, 2015. p. 1-8.
- MORALES, V. T. et al. FROAC: Una iniciativa colombiana para la integración de repositorios de objetos de aprendizaje. **Campus Virtuales**, Colombia, v. 1, n. 4, p.108-117, mar. 2015.
- NETFLIX. Disponível em: <<https://www.netflix.com/>>. Acesso em: 20 out. 2016.
- NILSSON, N. J. **Artificial intelligence: a new synthesis**. San Francisco: Morgan Kaufmann, 1998. 513 p.
- PANG, B., LEE, L. **Movie review data**. Disponível em: <<http://www.cs.cornell.edu/people/pabo/movie-review-data/>>. Acesso em: 30 abr. 2017.
- PARK, M., SUMMONS, P. *A computer-generated digital patient for oral interview training in pharmacy*. **Advanced Science and Technology Letters**, v.28, ago. 2013. Disponível em: <http://onlinepresent.org/proceedings/vol28_2013/24.pdf>. Acesso em: 13 out. 2016.

- PEDRO, L. et al. Building a shared personal learning environment with SAPO Campus. In: The PLE Conference, 2012, Aveiro. **Anais eletrônicos...** Aveiro: Universidade de Aveiro, 2012. Disponível em: <<http://revistas.ua.pt/index.php/ple/article/view/1426/2301>>. Acesso em: 02 nov. 2016.
- PEDRO, L. et al. *The SAPO Campus recommender system: a study about students' and teachers' opinions*. **Journal of the Association for Learning Technology**, v. 22, ago 2014. Disponível em <<http://www.researchinlearningtechnology.net/index.php/rlt/article/view/22921>>. Acesso em: 2 nov. 2016.
- PINHEIRO, D. et al. Redes Bayesianas como geração de conhecimento para games. In: Gamepad VIII, 8., 2015, Novo Hamburgo. **Anais...** Novo Hamburgo: Feevale, 2015. p. 1-12
- POWERS, D. M. W. *From precision, recall and F-factor to ROC, informedness, markedness and correlation*. **Journal of Machine Learning Technologies**, Australia, v. 2, n. 1, p.37-63, dez. 2011.
- PRASAD, B. *A knowledge-based product recommendation system for e-commerce*. **International Journal of Intelligent Information and Database Systems**, Geneva, v. 1, n. 1, p.18-36, abr. 2007.
- RAJARAMAN, A., ULLMAN, J. D. *Data mining*. In: _____. **Mining of massive datasets**. Cambridge: Cambridge University Press, 2012. p.1-17.
- RICCI, F., ROKACH, L., SHAPIRA, B. *Introduction to recommender systems handbook*. In: RICCI, F. et al. **Recommender systems handbook**. New York: Springer, 2010. p.1-38.
- RICCI, F., MAHMOOD, T. Improving recommender systems with adaptive conversational strategies. In: Proceedings of the 20th ACM conference on Hypertext and hypermedia, 2009, Torino. **Anais...** ACM: New York, 2009. p.73-82.
- ROCHA, A. K., MORENO, J. A folksonomia como ferramenta para a representação do conhecimento na web sob a ótica das redes sociais. In: XXXV Encontro Nacional de Estudantes de Biblioteconomia, Documentação, Ciência da Informação e Gestão da Informação, 35., Belo Horizonte. **Anais...** Belo Horizonte: Universidade Federal de Minas Gerais, 2012.
- ROCHA, B. J. B. **O paciente virtual no ensino de competências para a prática da atenção farmacêutica**. 2013. 201 f. Tese (Doutorado em Ciências da Saúde) – Núcleo de Pós-graduação em Medicina, Universidade Federal de Sergipe, Aracaju, SE, 2013. Disponível em: <http://bdtd.ibict.br/vufind/Record/UFS_06e2f52a88f2cca7f48dd8d449fead2f/Details>. Acesso em: 7 out. 2016.
- RODRÍGUEZ, P. A., DUQUE, N. D., OVALLE, D. A. *Método híbrido de recomendación adaptativa de objetos de aprendizaje basado en perfiles de usuario*. **Formación Universitaria**, [S.l.], v. 9, n. 4, p.83-94, jan. 2016.
- RODRÍGUEZ, P. A. et al. *Argumentation-based hybrid recommender system for recommending learning objects*. **Multi-Agent Systems and Agreement Technologies**, New York, v. 9571, p.234-248, abr. 2016.
- RUSSELL, S., NORVIG, P. **Artificial Intelligence: A modern approach**. 3rd ed. New Jersey: Prentice-Hall. 1995. 1132 p.

- SAFOURY, L., SALAH, A. *Exploiting user demographic attributes for solving cold-start problem in recommender system*. **Lecture Notes on Software Engineering**, Cairo, v. 1, n. 3, p.303-307, aug. 2013.
- SCHICK, A. G., GORDON, L. A., HAKA, S. *Information overload: A temporal approach*. **Accounting, Organizations and Society**, [S.l.], v. 15, n. 3, p.199-220, 1990.
- SCHRÖDER, G., THIELE, M., LEHNER, W. Setting goals and choosing metrics for recommender system evaluations. In: Workshop of the 5th ACM Recommender Systems Conference, 2011, Chicago. **Anais eletrônicos...** ACM: New York, 2011. Disponível em: <<http://ucersti.ieis.tue.nl/files/papers/4.pdf>>. Acesso em: 31 out. 2016.
- SCHWARTZ, B. *The paradox of choice: why more is less*. 1 ed. New York: HarperCollings Publishers, 2004. 282p.
- SEBASTIANI, R. L. et al. Validação do simulador de paciente virtual SIACC. **Espaço para a Saúde**, Londrina, v. 15, n. 1, jun. 2014. p.665-675.
- SINHA, R., SWEARINGEN, K. The role of transparency in recommender systems. In: Conference on Human Factors in Computing Systems, 2002, Minineapolis. **Anais...** ACM: New York, p.830-831, 2002.
- SITTNER, B. J. *Engaging students in simulation through virtual immersion*. **Clinical Simulation in Nursing**, St. Louis, USA, v. 5, n. 3, p. e150, mai. 2009.
- SMITH, S. J. High-fidelity simulation: Factor correlated with nursing student satisfaction and self-confidence. **Clinical Simulation in Nursing**, St. Louis, USA, v.5, n.3, p. e150, mai. 2009.
- SOUZA FILHO, G. F. **Simuladores computacionais para o ensino de física básica: uma discussão sobre produção e uso**. 2010. 86 f. Dissertação (Mestrado em Ensino de Física) – Programa de Pós-graduação em Ensino de Física, Instituto de Física, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, 2010. Disponível em: <http://www.if.ufrj.br/~pef/producao_academica/dissertacoes/2010_Geraldo_Felipe/dissertacao_Geraldo_Felipe.pdf>. Acesso em: 6 nov. 2016.
- SUGIYAMA, K., KAN, M. Y. *Scholarly paper recommendation dataset*. Disponível em <<http://www.comp.nus.edu.sg/~sugiyama/SchPaperRecData.html>>. Acesso em: 30 abr. 2017.
- SYMEONIDIS, P., NANOPOULOS, A., MANOLOPOULOS, Y. *Feature-Weighted user model for recommender systems*. In CONATI, C., McCOY, K., PALIOURAS, G. **User modeling 2007**. Heidelberg: Springer, 2007. p.97-106.
- TESTA, G. **Uma abordagem híbrida para recomendação de parceiros em ambientes virtuais colaborativos de composição musical**. 2013. 77 f. Dissertação (Mestrado em Ciência da Computação) – Programa de Pós-graduação em Computação, Instituto de Informática, Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, 2013. Disponível em: <<http://www.lume.ufrgs.br/bitstream/handle/10183/94626/000916281.pdf>>. Acesso em: 26 ago. 2016.
- THEFORCEAWAKENSAILY. *Who is your favorite character from the original trilogy?* Disponível em: <<https://www.instagram.com/p/BTbn6BiAj2e/?tagged=c3po>>. Acesso em: 30 abr. 2017.
- TINTAREV, N., MASTHOFF, J. Evaluating the effectiveness of explanations for recommender systems. **User Modeling and User-Adapted Interaction**, [S. l], v. 22, n. 4, p.399-439, out. 2012.

TOPPING, K. J. Trends in peer learning. **Educational Psychology**, [S.l.], v. 25, n. 6, p.631-645, jan. 2007.

TRAN, T. Combining collaborative filtering and knowledge-based approaches for better recommendation systems. **Journal of Business and Technology**, [S.l.], v. 2, n. 2, p.17-24, 2007.

TSUJI, H.; SILVA, R. H. A. Aprender e ensinar na escola vestida de branco: do modelo biomédico ao humanístico. São Paulo: Phorte, 2010. 240p.

VIG, J., SEN, S., RIEDL, J. Tagsplanations: explaining recommendations using tags. In: Proceedings of the 13th international conference on Intelligent user interfaces, 2008, Canary Islands. **Anais...** ACM: New York, 2009.

YAHOO. **Ratings and classification data**. Disponível em:

<<https://webscope.sandbox.yahoo.com/catalog.php?datatype=r>>. Acesso em: 30 abr. 2017.

ZIV, A.; BEN-DAVID, S.; ZIV, M. *Simulation based medical education: an opportunity to learn from errors*. **Medical Teacher**, [Bethesda, USA], v. 27, n. 3, p. 193-199, mai. 2005.