

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO

VERLANI TIMM HINZ

**Integrando Reputação às Técnicas de Recomendação de Objetos de
Aprendizagem em Ambientes de *e-learning***

Tese apresentada como requisito parcial
para a obtenção do grau de Doutor em
Ciência da Computação

Prof. Dr. Marcelo Soares Pimenta
Orientador

Porto Alegre, outubro de 2018.

CIP – CATALOGAÇÃO NA PUBLICAÇÃO

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Reitor: Prof. Carlos Alexandre Netto

Vice-Reitor: Prof. Rui Vicente Oppermann

Pró-Reitor de Pós-Graduação: Prof. Celso Giannetti Loureiro Chaves

Diretor do Instituto de Informática: Prof. Luis da Cunha Lamb

Coordenador do PPGC: Prof. Luigi Carro

Bibliotecária-chefe do Instituto de Informática: Beatriz Regina Bastos Haro

Dedico este trabalho a minha filha Marina, que nasceu durante o andamento dessa tese, e ao meu filho Erick, que sempre me acompanha nas minhas jornadas - eles são meus maiores presentes que Deus poderia ter me dado nesta vida.

AGRADECIMENTOS

Então é hora de agradecer pela conquista de mais um sonho realizado e, primeiramente, gostaria de agradecer a Deus por iluminar meu caminho e me dar forças para seguir sempre em frente.

Expresso meu especial agradecimento aos meus pais, Eno e Vanda, que sempre me incentivaram a estudar e aprofundar meus conhecimentos e, muitas vezes, renunciaram aos seus sonhos, para que eu pudesse realizar os meus. Minhas queridas irmãs Ervanda, Vanderlisa e Elizabete, prima Margarete, sobrinha Victoria e afilhados Eduardo e Murilo, que cada uma, à sua maneira, me apoiou durante o desenvolvimento deste trabalho.

Sou, também, extremamente grata, ao meu marido Luciano que esteve sempre ao meu lado, me apoiando e me dando forças para que eu continuasse e concluísse mais essa etapa importante da minha vida.

Agradeço aos meus filhos, Erick e Marina, que compreenderam minhas ausências, contribuindo muito para o andamento desse trabalho, me proporcionando momentos únicos de alegria. Sem eles eu nada seria!

Ao meu orientador professor Marcelo Soares Pimenta pela paciência, compreensão e atenção dedicadas, sempre me conduzindo, da melhor forma, em todo o processo de andamento dessa tese.

Ao IFSul, especialmente ao CAVG, pelo apoio institucional e pela oportunidade proporcionada através do Convênio firmado entre as instituições. Também aos colegas de área do IFSUL/CAVG, em especial ao João Ladislau, a Maria Isabel, o Fernando Brod e o Guilherme, que foram muito mais que colegas, sempre prontos para me auxiliar e incentivar a concluir este trabalho.

Agradeço, também, o amigo, Edécio Fernando Iepsen, que me auxiliou com seus conhecimentos práticos de programação, que foram de grande valia e contribuição para que o experimento pudesse ser realizado.

Aos meus ex-professores da Graduação e Pós-Graduação que sempre me ajudaram toda vez que tive que recorrer à eles.

E por fim, agradeço à todos amigos, que de alguma forma, direta ou indiretamente, me auxiliaram para a realização deste trabalho, assim como torceram pela minha vitória.

Integrating Reputation to Recommendation Techniques for Learning Objects in e-learning Environments

ABSTRACT

Distance learning (DL) in Brazil has grown significantly in recent years, increasing significantly the use of Virtual Learning Environments (VLE), which are computational environments, used in the teaching-learning process. In these environments are the learning objects (LO), which are the didactic materials used in the courses, such as text documents, handouts, audio and video files. However, it is verified that each day the number of LOs available to users grows considerably, making it difficult to choose the objects that satisfy the real needs and preferences of the students, making it important to have a tool that makes personalized recommendations to the users of these *e-learning* environments. In addition, another factor that hinders decision making is the lack of confidence that users have in relation to the material made available, as well as in relation to the person who made the material available. Therefore, this thesis aims to investigate the incorporation of reputation models in an *e-learning* environment to generate personalized recommendations. The proposed architecture, called e-RecRep, aims to allow the recommendation of LOs in an *e-learning* environment, where the reputation of users who recommend these LOs is considered. With the adoption of e-RecRep, the student receives suggestions - from the system and other users - of learning objects that relate to the studied content, encouraging the student to complement his / her learning. Preliminary results allow us to conclude that the suggestions of a person who presents a good reputation to a group make the recommended information more relevant, improving not only the credibility of the information, but also its robustness, diversity and surprise (serendipity). The architecture is evaluated through the TAM methodology, which considers the utility of the developed prototype, as well as a comparative analysis to evaluate the improvement of the teaching and learning process of the students.

Keywords: *E-learning*, Reputation Models, Learning Objects, Recommendation Techniques

RESUMO

A educação a distância (EaD) no Brasil tem crescido bastante nos últimos anos, aumentando, com isso, significativamente o uso dos Ambientes Virtuais de Aprendizagem (AVA), que são ambientes computacionais, usados no processo de ensino-aprendizagem. Nesses ambientes encontram-se os objetos de aprendizagem (OA), que são os materiais didáticos utilizados nos cursos, como, por exemplo, documentos de texto, apostilas, arquivos de áudio e vídeo. Entretanto, verifica-se que a cada dia o número de OAs disponíveis aos usuários cresce consideravelmente, dificultando a escolha pelos objetos que satisfaçam as reais necessidades e preferências dos estudantes, tornando-se importante a existência de uma ferramenta que faça recomendações personalizadas aos usuários desses ambientes de *e-learning*. Além disso, outro fator que dificulta a decisão de escolha é a falta de confiança que os usuários têm em relação ao material disponibilizado, assim como, em relação à pessoa que disponibilizou o material. Diante disso, essa tese tem por objetivo a incorporação de modelos de reputação em um ambiente de *e-learning* para gerar recomendações personalizadas. A arquitetura proposta, chamada e-RecRep, tem como contribuição central permitir a recomendação de OAs em um ambiente de *e-learning*, onde a reputação dos usuários que recomendam estes OAs é considerada. Com a adoção do e-RecRep, o aluno recebe sugestões - do sistema e de outros usuários - de objetos de aprendizagem que se relacionam com o conteúdo estudado, incentivando o aluno a complementar sua aprendizagem. Os resultados obtidos permitem concluir que as sugestões de uma pessoa que apresenta uma boa reputação a um grupo tornam a informação recomendada mais relevante, melhorando não só a credibilidade da informação, mas também sua robustez, diversidade e surpresa (*serendipity*). A arquitetura é avaliada através da metodologia TAM, a qual considera a utilidade do protótipo desenvolvido, bem como uma análise comparativa para avaliar a melhoria do processo de ensino e aprendizagem dos alunos.

Palavras-chave: *E-learning*, modelos de reputação, objetos de aprendizagem, técnicas de recomendação.

LISTA DE FIGURAS

Figura 2.1 - Interface do Ambiente Virtual de Aprendizagem TelEduc.....	24
Figura 2.2 - Interface do Ambiente Virtual de Aprendizagem TelEduc.....	25
Figura 2.3 - Arquitetura do ambiente AulaNet baseado no modelo de colaboração 3C.	26
Figura 2.4 - Arquitetura do Ambiente AdaptWeb.....	28
Figura 2.5 – Participação da Comunidade Virtual do MOODLE.....	29
Figura 2.6 - Interface do Ambiente Virtual de Aprendizagem MOODLE do Instituto Federal Sul-rio-grandense/Campus Pelotas - Visconde da Graça – Tela principal.....	30
Figura 2.7 – Instituto Federal Sul-rio-grandense/Câmpus Pelotas - Visconde da Graça – Tela dos Cursos.....	30
Figura 2.8 - Atividades e recursos do MOODLE.	31
Figura 2.9 - Página de avaliação do <i>MovieLens</i>	39
Figura 2.10 - Página de recomendação do <i>MovieLens</i>	39
Figura 2.11 - Estrutura de sistemas de reputação.....	48
Figura 2.12 - Tipologia de reputação.....	49
Figura 2.13 - Classificação baseada em perfis.....	54
Figura 2.14 - Classificação baseada em níveis.	55
Figura 2.15 - Classificação baseada em membros.	55
Figura 2.16 - Classificação baseada em pontos.....	56
Figura 2.17 - Classificação baseada em ranking.....	56
Figura 4.1 - Arquitetura do e-RecRep	76
Figura 4.2 - Visão geral dos <i>plugins</i> instalados no MOODLE.....	83
Figura 4.3 - <i>Plugin</i> instalado como ferramenta externa no MOODLE.	83
Figura 4.4 - <i>Plugin</i> implementado no MOODLE.	84
Figura 4.5 - Tela principal do ambiente com o <i>plugin</i> criado.	85
Figura 4.6 - <i>Plugins</i> desenvolvidos.....	85
Figura 4.7 - Tela do ambiente com o botão de preciso de material complementar.....	86
Figura 4.8 - Listagem de OAS recomendados	87
Figura 4.9 - Tela de cadastro de autores	88

Figura 4.10 - Tela mostrando o perfil de autor	88
Figura 4.11 – Tela principal com opção de recomendação na Unidade.....	89
Figura 4.12 - Tela principal com opção de recomendação no curso.	89
Figura 4.13 - Tela de Recomendação de material	90
Figura 4.14 – Lista de material recomendado atualizada.....	91
Figura 4.15 – Avaliação do material recomendado	91
Figura 4.16 – Dados da reputação de Marina	92
Figura 4.17 – Tela mostrando o perfil da a aluna Marina	93
Figura 5.1 - Participantes de uma turma que utilizou o ambiente virtual para realização das atividades do ambiente virtual.....	97
Figura 5.2 – Exemplo da aplicação da escala de <i>Likert</i>	99
Figura 5.3 - Avaliação de Facilidade de Uso e Percepção de Utilidade	100
Figura 5.4 – Exemplo de log de acesso no ambiente.....	100
Figura 5.5 – Avaliação da Percepção da Utilidade.....	103
Figura 5.6 - Avaliação da Percepção de utilidade das afirmações 2 e 3.	103
Figura 5.7 - Avaliação da Percepção de utilidade das afirmação 4.....	104
Figura 5.8 - Avaliação da Percepção de utilidade da afirmação 5.....	105
Figura 5.9 – Comparativo de média dos dois experimentos	106

LISTA DE TABELAS

Tabela 2.1 - Dados sobre utilização do MOODLE.....	33
Tabela 2.2: Resumo da Filtragem Baseada em Conteúdo.....	37
Tabela 2.3 - Exemplo de uma matriz de avaliação usuário-usuário	42
Tabela 2.4 - Resumo da Filtragem Colaborativa	45
Tabela 3.1 - Categorias e elementos definidos no modelo de Cervi et al. (2011).	68
Tabela 3.2: Classificação da reputação definida no modelo de Cervi et al. (2011).....	70
Tabela 3.3 - Tabela comparativa entre alguns sistemas de recomendação aplicados em ambientes de <i>e-learning</i>	72
Tabela 3.4: Tabela comparativa dos trabalhos relacionados à reputação	73
Tabela 3.5: Tabela comparativa	74
Tabela 4.1 - Atributos dos usuários e seus valores.....	79
Tabela 4.2 - Classificação da reputação em baseada em níveis numéricos	80
Tabela 4.3 – Atributos de Marina	94
Tabela 5.1 - Formulário de avaliação aplicado.....	98
Tabela 5.2 – Resultados obtidos	99
Tabela 5.3 - Formulário de Avaliação.....	102
Tabela 5.4 - Avaliação da Percepção de Utilidade.....	102
Tabela 6.1: Publicações realizadas.....	109

SUMÁRIO

RESUMO.....	6
LISTA DE FIGURAS.....	7
LISTA DE TABELAS	9
LISTA DE ABREVIATURAS E SIGLAS.....	12
1 INTRODUÇÃO.....	13
1.1 Motivação	15
1.2 Objetivos	17
1.3 Organização do Texto	18
2 FUNDAMENTAÇÃO TEÓRICA.....	19
2.1 Ambientes de <i>e-learning</i>.....	19
2.1.1 Objetos de Aprendizagem.....	20
2.1.2 Principais projetos de <i>E-learning</i>.....	22
2.1.3 Síntese dos ambientes de <i>e-learning</i>.....	32
2.2 Técnicas de Recomendação.....	33
2.2.1 Filtragem Baseada em Conteúdo.....	34
2.2.2 Filtragem Colaborativa	37
2.3 Reputação e Confiança.....	45
2.3.1 Componentes de Sistemas de Reputação.....	47
2.3.2 Tipologia	49
2.3.3 Modelos de Cálculo.....	51
2.3.4 Modelos de Classificação	54
2.3.5 Limitações.....	57
2.3.6 Considerações do capítulo.....	58
3 TRABALHOS RELACIONADOS.....	60
3.1 Sistemas de Recomendação	60
3.2 Modelos de reputação.....	65
3.3 Sistemas de recomendação e modelos de reputação.....	70
3.4 Síntese dos trabalhos relacionados	71
3.5 Considerações do capítulo.....	75

4	ARQUITETURA PROPOSTA.....	76
4.1	Visão Geral da Arquitetura	76
4.2	Observações	80
4.3	Implementação da arquitetura.....	82
4.4	Cenários de uso.....	85
5	AVALIAÇÃO DA ARQUITETURA E-RECREP	95
5.1	Avaliação com Método TAM	95
5.1.1	Participantes	96
5.1.2	Instrumentos e Métodos.....	97
5.1.3	Análise e Discussão dos resultados.....	105
6	CONSIDERAÇÕES FINAIS.....	107
6.1	Contribuições	108
6.2	Publicações.....	108
6.3	Limitações.....	109
6.4	Trabalhos futuros	109
7	REFERÊNCIAS	111
	APÊNDICE A – ARQUITETURA E-RECREP	118

LISTA DE ABREVIATURAS E SIGLAS

AVA	Ambiente Virtual de Aprendizagem
EaD	Educação à Distância
FBC	Filtragem Baseada em Conteúdo
FC	Filtragem Colaborativa
FCUU	Filtragem Colaborativa usuário-usuário
FH	Filtragem Híbrida
IEEE	Institute of Electrical and Electronics Engineers
LMS	Learning Management System
LTSC	Learning Technology Standard Committee
MR	Modelos de reputação
OA	Objeto de Aprendizagem
SR	Sistemas de Recomendação
TF-IDF	Frequência de termos - frequência inversa do documento

1 INTRODUÇÃO

A Educação a Distância (EaD) vem crescendo em muitos países, especialmente no Brasil, e representa parte dos alunos nos ensinos técnico, profissionalizante e superior do país. Segundo dados obtidos do Censo EaD de 2016 (ABED, 2016) é notório o crescimento no número de matrículas em cursos de ensino à distância em comparação a anos anteriores, sendo que em 2004, haviam cerca de 60 mil alunos matriculados; cresceu rapidamente e atingiu em 2016 a marca de 1,5 milhão de matrículas.

Segundo Sathler¹ os motivos para essa expansão são diversos, sendo os principais o Decreto Nº 5622, de 2005, que reconhece a EaD como uma modalidade de ensino, e sua consequente regulação pelo MEC, em 2006. A facilidade de acesso às tecnologias oferecidas pela Internet, também é outro fator determinante para essa expansão, pois além de facilitar a troca de informações, também é um importante veículo de comunicação entre as pessoas, pois os alunos e seus professores não precisam, necessariamente, estarem fisicamente presentes em um ambiente formal de ensino e de aprendizagem, permitindo, dessa forma, que o aluno possa gerenciar seu próprio aprendizado, desenvolvendo, assim, sua autonomia e gerenciando o tempo do estudo da forma que achar mais conveniente.

Para essa modalidade de ensino que pode ser ofertada através da Internet, dá-se o nome de *e-learning* e para dar suporte aos alunos do EaD são utilizados sistemas *Web* chamados Ambientes Virtuais de Aprendizado (AVA). O termo LMS (*Learning Management System*) também é frequentemente usado como sinônimo de AVA.

Nos ambientes de *e-learning* encontram-se os Objetos de Aprendizagem (OA), que podem ser definidos como qualquer entidade digital que pode ser usada, reusada e referenciada no processo de ensino apoiado pela tecnologia (IEEE, 2002). OAs são construídos para um assunto específico,

¹ Diretor da Associação Brasileira de Educação a Distância (ABED) e Diretor de EAD da Universidade Metodista. Fonte: <http://www.lante.uff.br>.

permitindo assim que sejam referenciados quando o assunto é discutido em diversas disciplinas.

Exemplos de Objetos de Aprendizagem incluem conteúdos de aplicações multimídia, conteúdos instrucionais, ferramentas de software e software instrucional, pessoas, organizações ou eventos referenciados durante o processo de suporte da tecnologia ao ensino e aprendizagem (LOM, 2000).

No entanto, há uma tendência crescente no aumento da quantidade de OA disponíveis para estudantes e professores nos ambientes de *e-learning*, ocasionando uma sobrecarga de informações. Assim, o uso de Sistemas de Recomendação (SR) pode desempenhar um papel importante para esta escolha, filtrando os OAs mais apropriadas para o perfil de um usuário, ou mesmo sugerindo OAs mais relacionadas ao conteúdo estudado, alcançando o principal benefício de OA que é a reutilização do material produzido.

O uso de sistemas de recomendação em áreas como o *e-commerce* é cada vez mais comum, pois consegue filtrar o produto mais adequado ao usuário diante de tantas opções disponíveis. Na área de *e-learning*, o uso do SRs, serve para recomendar o material de aprendizagem mais adequado a um usuário ou grupo de usuários. Em um primeiro momento imagina-se que seja similar, no entanto quando estamos tratando do contexto educacional isso se torna mais complexo e desafiador, pois envolve usuários que necessitam de material que irá contribuir no seu processo de aprendizado, então um único material poderá não ser suficiente à um aluno, pois cada aluno tem seu estilo de aprendizagem, assim como outros fatores que podem influenciar no processo de ensino e aprendizagem desse aluno (SOUTO et al., 2002).

Da mesma forma, o uso de sistemas de reputação também algo é importante, visto que envolve o intercâmbio de informação e conhecimento entre membros da uma comunidade, e há uma grande necessidade de classificar a informação, distinguindo-a entre útil e não útil ou entre fidedigna e duvidosa (CRUZ et al., 2007).

Para Cruz et al. (2007), é difícil, também, confiar na competência das pessoas que não são conhecidas, especialmente em um cenário como o da internet, em que há uma grande quantidade de informações disponíveis por meio de fontes não confiáveis. A partir disso verifica-se que a reputação está

ligada à confiança, pois dependendo da reputação de uma pessoa, outra pode decidir se confia nela ou não. É possível inferir que as pessoas com boa reputação são mais confiáveis, pelo menos para aqueles que nunca interagiram com elas, pois seu comportamento foi avaliado por outros.

Em um ambiente de *e-learning* isso se torna algo fundamental, pois os alunos precisam de material de qualidade, assim como provido de uma fonte confiável para que possam realizar suas atividades e complementar seu aprendizado.

Assim, este trabalho propõe a criação de uma arquitetura, denominada e-RecRep, que tem por objetivo recomendar OAs em um ambiente de *e-learning*, considerando a reputação dos usuários que recomendam os OAs. Através do sistema o aluno recebe sugestões de Objetos de Aprendizagem que se relacionam com o conteúdo estudado, incentivando o aluno a complementar seu aprendizado. Além disso, a ideia é de que se a sugestão for de uma pessoa que apresenta uma boa reputação perante um grupo, a informação recomendada poderá ser mais relevante para o aluno, melhorando a credibilidade da informação.

Este Capítulo tem por objetivo contextualizar a tese, apresentando suas motivações, problemas de pesquisa e objetivos.

1.1 Motivação

Os ambientes de *e-learning* tradicionais (MOODLE, TelEduc, AulaNet, ...) disponibilizam uma grande quantidade e diversidade de Objetos de Aprendizagem, dificultando a escolha dos objetos que melhor satisfaçam as necessidades e preferências dos alunos. Os estudantes muitas vezes não possuem conhecimento suficiente para encontrar o material desejado, pois somente a pesquisa por palavras-chave disponibilizada nos repositórios de OA não são suficientes para o aluno encontrar o que deseja.

A recomendação de materiais de outros colegas - geralmente pessoas com um perfil semelhante - também pode melhorar o processo de ensino e de aprendizagem.

Conforme já mencionado, outro fator que dificulta a decisão de escolha é a falta de confiança que os usuários têm em relação ao material disponibilizado, assim como em relação à pessoa que disponibilizou o material.

Na literatura são encontrados trabalhos que apresentam cálculo de reputação (CAZELLA, 2006), (CERVI, 2011), (MAMANI, 2013), no entanto a maioria se concentra na avaliação de pesquisadores com uma trajetória acadêmica mais rica onde são avaliados, também, a quantidade de artigos publicados, sendo o valor resultante obtido somente a partir de dados quantitativos ou qualitativos.

É intenção deste trabalho a elaboração de um modelo para o cálculo de reputação personalizado, que possa abranger inclusive pesquisadores iniciantes, que não tenham reputação elevada, pois sua trajetória ainda é incipiente, mas que podem se destacar por possuírem grande conhecimento e interesse pela área a ser recomendada, podendo trazer grandes benefícios na comunidade científica.

Diante disso, a motivação para o desenvolvimento deste trabalho é demonstrar que a integração de reputação com técnicas de Sistemas de Recomendação em ambientes de *e-learning* já desenvolvidos podem tornar o ambiente mais personalizado, confiável e adaptado ao estilo de cada aluno, atingindo os objetivos propostos para um ambiente de *e-learning*.

Pelo exposto, considera-se que prover uma arquitetura para integração de reputação com sistemas de recomendação no contexto educacional constitui um desafio de pesquisa. Nesta perspectiva, esta tese investiga as seguintes questões de pesquisa:

- Como filtrar a informação disponibilizada, de modo que torne o ambiente de *e-learning* personalizado de acordo com as necessidades do aluno?
- Como saber se a informação recomendada provém de uma fonte realmente confiável?

1.2 Objetivos

Considerando as questões de pesquisa, entende-se como objetivo geral desta tese o desenvolvimento de uma arquitetura visando a incorporação de um mecanismo de reputação para gerar recomendações personalizadas em um ambiente de *e-learning*.

Considerando o objetivo central da tese, os seguintes objetivos específicos foram definidos:

- revisar o estado da arte nos temas relacionados a Sistemas de Recomendação, Modelos de Reputação e Ambientes de *e-learning*;
- sistematizar os trabalhos similares à arquitetura proposta;
- definir as estratégias de recomendação que serão utilizadas;
- especificar as métricas para o cálculo da reputação;
- modelar uma arquitetura para integração de reputação a técnicas de sistemas de recomendação em um ambiente de *e-learning*;
- especificar os módulos que constituirão a arquitetura;
- desenvolver um protótipo da arquitetura e-Recrrep;
- validar as funcionalidades da arquitetura através de experimentos com alunos;
- divulgar os resultados do projeto através de publicações de artigos científicos em conferências e periódicos da área.

Considerando os objetivos, entende-se como contribuições principais deste trabalho:

- integração de diferentes conceitos, modelos, técnicas e tecnologias, originárias das áreas de Sistemas de Recomendação, Sistemas de Reputação e Ambientes de *e-learning*;
- concepção de uma arquitetura para integrar modelos de reputação a sistemas de recomendação em ambientes de *e-learning*.

1.3 Organização do Texto

Esta tese está estruturada da seguinte forma:

No Capítulo 2 é apresentada uma revisão bibliográfica, incluindo conceitos sobre Sistemas de Recomendação; Reputação e Confiança; e Ambientes de *e-learning*.

O Capítulo 3 sintetiza a revisão de literatura que buscou identificar os trabalhos relacionados à esta tese, sendo apresentada uma discussão dos mesmos, considerando os objetivos e premissas de concepção da Arquitetura e-RecRep.

No Capítulo 4 é descrita a arquitetura proposta neste trabalho, que visa recomendar OAs em um ambiente de *e-learning*, usando o mecanismo de reputação para personalizar e melhorar a precisão das recomendações de materiais didáticos úteis aos alunos em seus ensinamentos e aprendizado.

A avaliação das funcionalidades da Arquitetura e-RecRep é apresentada no Capítulo 5. Por fim, no Capítulo 6 são apresentadas as conclusões da tese, sendo destacadas as principais contribuições, as limitações, bem como os trabalhos futuros que podem ser desenvolvidos na continuidade desta pesquisa.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo serão apresentados os conceitos que compõem a pesquisa que foi realizada para fundamentar esta tese. Nesse sentido, são apresentados os ambientes de *e-learning*, focando no ambiente MOODLE que foi escolhido para implementação do protótipo. Ainda, as principais técnicas de Sistemas de Recomendação e o conceito sobre Sistemas de Reputação e Confiança em ambientes de *e-learning* são apresentadas neste capítulo.

2.1 Ambientes de *e-learning*

Com o crescimento no emprego da tecnologia computacional nos mais diversos campos de estudo são viáveis os benefícios trazidos para a área de educação. O uso dos chamados Ambientes Virtuais de Aprendizagem (AVAs) ou Virtual Learning Environments (VLEs) aumentaram significativamente a quantidade de recursos educacionais disponíveis para os estudantes e professores, tornando cada vez mais difícil a tarefa de escolha de conteúdos dentre as diversas opções disponíveis.

A principal finalidade dos AVAs é gerenciar a aprendizagem via Internet, agregando interfaces que permitam a geração de conteúdos com base nos mais variados meios de comunicação, possibilitando a utilização de recursos pedagógicos e administrativos, tentando reproduzir a sala de aula presencial (física) para o meio virtual, utilizando vários tipos de ferramentas que facilitem a aprendizagem.

Britain e Liber (1999) definem um AVA como a combinação de um software de comunicação mediado por computador e de um método de entrega *online* de materiais dentro de um único ambiente de software, permitindo o processo de ensino e de aprendizagem.

Já Behar, Oliveira e Schneider (2004), consideram um AVA como um todo constituído pela plataforma e por todas as relações estabelecidas (ou seja, as trocas emocionais, cognitivas e simbólicas) pelos atores participantes (aluno, professor, tutor e coordenador), tendo como foco principal a aprendizagem.

Segundo Piccoli, Ahmad e Ives (2001), os Ambientes Virtuais de Aprendizagem são sistemas baseados em computador que permitem a interação entre os participantes. O aluno usa material de estudo de forma independente, aprendendo em seu próprio tempo e possibilita interações de forma síncrona ou assíncrona. Os Ambientes Virtuais mudam o processo de aprendizagem da experiência de aprendizagem individual para a experiência mais coletiva, onde os alunos podem se comunicar com outros alunos e professores.

Nesse sentido, os AVAs podem ser considerados ferramentas de gestão do conhecimento que são utilizadas para incentivar a aprendizagem do aluno, permitindo maior flexibilidade para o acesso do material de didático, possibilitando que as discussões entre os atores envolvidos ultrapassem o limite de tempo e espaço. Sendo assim, os AVAs podem ser considerados ferramentas fundamentais para que o processo de Educação a Distância ocorra.

Atualmente, um dos recursos digitais bastante utilizados dentro dos Ambientes Virtuais de Aprendizagem são os Objetos de Aprendizagem (OA).

2.1.1 Objetos de Aprendizagem

O conceito de Objetos de Aprendizagem é muito amplo e são encontradas várias definições na literatura, mas todas remetem ao mesmo objetivo: localizar conteúdos educacionais na Web, para serem reutilizados em diferentes cursos e plataformas e, assim, possibilitar a redução do custo de produção dos materiais.

Para Audino e Nascimento (2010, p. 135), Objetos de Aprendizagem:

"são recursos digitais dinâmicos, interativos e reutilizáveis em diferentes ambientes de aprendizagem elaborados a partir de uma base tecnológica. Desenvolvidos com fins educacionais, eles cobrem diversas modalidades de ensino: presencial, híbrida ou a distância; diversos campos de atuação: educação formal, corporativa ou informal; e, devem reunir várias características, como durabilidade, facilidade para atualização, flexibilidade, interoperabilidade, modularidade, portabilidade, entre outras. Eles ainda apresentam-se como unidades auto-consistentes de pequena extensão e fácil manipulação, passíveis de combinação com outros objetos educacionais ou qualquer outra mídia digital (vídeos, imagens, áudios, textos, gráficos, tabelas, tutoriais, aplicações, mapas, jogos educacionais, animações, infográficos, páginas web) por meio da hiperligação. Além disso, um Objeto de Aprendizagem pode ter usos

variados, seu conteúdo pode ser alterado ou reagregado, e ainda ter sua interface e seu *layout* modificado para ser adaptado a outros módulos ou cursos. No âmbito técnico, eles são estruturas autocontidas em sua grande maioria, mas também contidas, que, armazenados em repositórios, estão marcadas por identificadores denominados *metadados*".

De acordo com o *Learning Objects Metadata Workgroup*, Objetos de Aprendizagem (*Learning Objects*) podem ser definidos como qualquer entidade, digital ou não digital, que possa ser utilizada, reutilizada ou referenciada durante o aprendizado suportado por tecnologias (IEEE, 2002).

Um Objeto de Aprendizagem pode ser usado em diferentes contextos e em diferentes Ambientes Virtuais de Aprendizagem, para atender a esta característica, cada objeto tem sua parte visual, que interage com o aprendiz separada dos dados sobre o conteúdo e os dados instrucionais do mesmo.

O Objeto de Aprendizagem pode ser dividido em três partes distintas: o objetivo, em que o aprendiz busca as informações a respeito do campo em que o seu Objeto de Aprendizagem vai intervir; o conteúdo instrucional, no qual serão previstas as ferramentas de criação de um Objeto de Aprendizagem; a prática, ou *feedback*, que é quando o aprendiz irá fazer os testes necessários no Objeto de Aprendizagem para verificar se o objeto supriu as expectativas propostas na primeira parte do projeto. Caso isso ocorra, o aprendiz poderá voltar ao seu objeto e atualizá-lo sempre que precisar.

A principal característica de um OA é permitir a reusabilidade do material instrucional, ou seja, permitir que este material seja reaproveitado em diversos cursos, diversas vezes. Tal característica pode ser alcançada se um objeto de aprendizagem apresentar algumas propriedades. A literatura provê um grande número delas. As mais citadas são: modularidade; interoperabilidade e recuperação (FRIESEN, 2001). A modularidade descreve o grau de separação, e conseqüente recombinação, dos componentes; a interoperabilidade é a capacidade de operar em plataformas heterogêneas; e por fim, a recuperação está relacionada à capacidade de poder ser encontrado conforme sua descrição de propriedades e funcionalidades.

Para que um Objeto de Aprendizagem possa ser recuperado e reutilizado, é preciso que esse objeto seja devidamente indexado (preenchimento dos metadados) e armazenado em um repositório.

Os metadados permitem a descrição e posterior recuperação para reutilização dos Objetos de Aprendizagem nos repositórios desenvolvidos para esse fim, ou seja, os metadados tornam os objetos de aprendizagem acessíveis. Segundo Silva e Silva (2006), representam a informação estruturada que descreve, explica e torna possível localizar e recuperar os OA. A função dos metadados seria a de promover a identificação e possibilitar o compartilhamento, a integração, a utilização, a reutilização, o gerenciamento e a recuperação dos OA de maneira mais eficiente. Os metadados atuam como organizadores e facilitadores na recuperação dos OA.

Alguns organismos têm investido esforços no sentido de estabelecer padrões de metadados para descrever os Objetos de Aprendizagem. Como exemplos pode-se indicar o *Dublin Core Metadata Initiative* (DCMI)², *Institute of Electrical and Electronics Engineers* (IEEE)³ e *International Standards Organisation* (ISO)⁴.

Os Repositórios de Objetos de Aprendizagem (ROA) são bancos de dados que armazenam informações sobre os objetos, os metadados, e os objetos propriamente ditos. Dentre alguns exemplos citamos o CAREO⁵ (*Campus Alberta Repository of Educational Objects*), o CESTA⁶ (*Coletânea de Entidades de Suporte ao uso de Tecnologia na Aprendizagem*), o MERLOT⁷ (*Multimedia Educational Repository for Learning and On-line Teaching*), o RIVED⁸, (*Red Internacional Virtual de Educación*) e o PROEDU⁹ (Acervo de Recursos Educacionais para Educação Profissional e Tecnológica).

2.1.2 Principais projetos de *E-learning*

Atualmente existe uma grande diversidade de AVAs, que são desenvolvidos utilizando tecnologias proprietárias e sendo distribuídas através

² <http://www.dublincore.org>

³ <http://www.ieeeeltsc.org/standards/1484-12-1-2002>

⁴ <http://www.iso.org/>

⁵ <http://www.ucalgary.ca/commons/careo/>

⁶ <http://www.cinted.ufrgs.br/CESTA/>

⁷ <http://www.merlot.org/Home.po>

⁸ <http://rived.proinfo.mec.gov.br>

⁹ <http://proedu.ifce.edu.br>

de licenças pagas ou gratuitas, bem como utilizando tecnologias baseada na filosofia do software livre.

Dentre os principais projetos relacionados aos ambientes de *e-learning*, Kemczinski (2005) cita: TelEduc, AulaNet, Eureka, Academusnet, Web Ensino, HyCLASS, JavaCAP, AlgoArena, SMILE. Além destes temos também o Adaptweb (GASPARINI, 2003), o Amadeus (GOMES et al. 2010), o Polvo (SCHULTZ, 2007) e o MOODLE (FERREIRA, 2009), (FILHO, 2004).

Dentre os citados, detalharemos o TelEduc, o AulaNet, o Adaptweb e o MOODLE por serem amplamente citados na literatura e utilizados em Instituições de Ensino.

a) TelEduc

O TelEduc é um Ambiente Virtual de Aprendizagem (AVA) para criação, realização, participação e administração de cursos a distância, semi-presenciais e também utilizados como apoio as aulas presenciais de várias disciplinas. Ele foi concebido tendo como alvo o processo de formação de professores para informática educativa, baseado na metodologia de formação contextualizada desenvolvida, desde 1997, por pesquisadores do Núcleo de Informática Aplicada à Educação (Nied) do Instituto de Computação da Universidade Estadual de Campinas (Unicamp), sob a orientação da professora Dra. Heloísa Viera Rocha,

Segundo ROCHA (2006), o AVA TelEduc é uma ferramenta que foi desenvolvida segundo pedido dos próprios usuários e, por isso é uma ferramenta participativa, cujo objetivo é criar um ambiente para a criação, participação e administração de cursos na Web.

O AVA TelEduc é um software livre sob *GNU Public License* versão 2, desenvolvido com as linguagens *PHP* e *JavaScript* e associado a um gerenciador de bancos de dados *MySQL*, o que proporciona ao usuário a implementação de funcionalidades adicionais. O TelEduc está na versão 4.3.2 e funciona em ambientes *UNIX* e *Linux*.

Atualmente, o TelEduc é utilizado por algumas Instituições de Ensino brasileiras e também na Inecom Ingenieros do Chile. Esse AVA está disponível em três línguas (português, inglês e espanhol).

O TelEduc foi concebido tendo como elemento central a ferramenta que disponibiliza Atividades, dentre elas Material de Apoio, Leituras, Perguntas Frequentes, etc.. Além disso, a intensa comunicação entre os participantes do curso e ampla visibilidade dos trabalhos desenvolvidos também são pontos importantes, por isso foi desenvolvido um amplo conjunto de ferramentas de comunicação como o Correio Eletrônico, Grupos de Discussão, Mural, Portfólio, Diário de Bordo, Bate-Papo etc.

Os desenvolvedores dessa ferramenta educacional se preocupam com a transparência e com a facilidade de uso. Por isso, o ambiente possui uma interface bastante simples e amigável ao usuário, conforme mostra a Figura 2.1.

Figura 2.1 - Interface do Ambiente Virtual de Aprendizagem TelEduc.



Fonte: Autoria própria.

b) AulaNet

O AulaNet é um ambiente de aprendizagem cooperativo baseado na Web, cujo projeto iniciou em 1997. Foi desenvolvido no Laboratório de Engenharia de Software (LES) do Departamento de Informática da Pontifícia Universidade Católica do Rio de Janeiro (PUC - Rio), sob a coordenação dos professores Carlos José Pereira e Hugo Fuks. Tem como objetivo a criação, administração, manutenção e participação em cursos à distância baseados na web.

O AulaNet é um software *freeware* e disponível em três línguas (inglês, português e espanhol). Atualmente, o AulaNet é desenvolvido em linguagem JAVA, mas as suas primeiras versões foram desenvolvidas utilizando a

linguagem LUA¹⁰. A Figura 2.2 mostra a tela principal do ambiente virtual TelEduc.

Figura 2.2 - Interface do Ambiente Virtual de Aprendizagem TelEduc.



Fonte: Autoria própria.

Segundo Cunha et al. (2003), o AulaNet baseia-se nas relações de trabalho cooperativo que se manifestam nas dos aprendizes (alunos) com seus instrutores (professores), ou com outros aprendizes (demais alunos de um curso) e com os conteúdos didáticos, possibilitando suporte ao trabalho em grupo.

Ainda para Cunha et al. (2003) o modelo adotado no AulaNet foi o de colaboração 3C, o qual é baseado na ideia de que para colaborar, um grupo tem que exercer três atividades fundamentais (conforme Figura 2.3): comunicar-se, coordenar-se e cooperar, envolvendo a negociação de compromissos e conhecimentos, onde a: interações


- coordenação: o grupo lida com conflitos e se organiza de maneira a evitar que os esforços de comunicação e de cooperação sejam perdidos. Exemplos de atividades são: tarefas, avaliação, avisos e notícias do curso, planos de aula, exercícios e atividades e relatórios de acompanhamento da participação;

¹⁰ Fonte: www.lua.org

- **cooperação:** é a operação conjunta dos membros do grupo em espaços compartilhados. Exemplos de atividades são: bibliografia, webliografia, documentação, download, transparência, apresentação gravada, texto de aula, livro texto, co-autoria de conteúdo.
- **comunicação:** negocia tarefas relacionadas aos compromissos e conhecimentos. Exemplos de atividades são: grupo de discussão, grupo de interesse, debates, conferências (fóruns) e mensagens para participantes;

Ao utilizar os serviços do AulaNet, as pessoas nele cadastradas assumem uma função, sendo por isso chamadas de atores do ambiente. Um mesmo ator pode ter vários papéis. Os papéis que os atores podem ter são de aprendiz, docente, administrador de ambientes e mentor. Em cursos do AulaNet, os docentes podem assumir outras três responsabilidades: coordenador do curso, docente co-autor e mediador.

Figura 2.3 - Arquitetura do ambiente AulaNet baseado no modelo de colaboração 3C.



Fonte: Cunha et al. (2003)

c) AdaptWeb (Ambiente de Ensino-Aprendizagem Adaptativo na Web)


O AdaptWeb é um Sistema de Hiperímia Adaptativa de EaD baseado na *Web* desenvolvido inicialmente através de uma parceria da UFRGS (Universidade Federal do Rio Grande do Sul) e UEL (Universidade Estadual de Londrina), com colaboração do CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico). Atualmente a UDESC (Universidade do Estado de Santa Catarina) participa ativamente no desenvolvimento e melhorias do ambiente. É um ambiente *opensource*, gratuito, disponível no *Sourceforge* e operacional em algumas instituições.

A finalidade do ambiente é adaptar o conteúdo, a apresentação e a navegação de acordo com o perfil do usuário. Seu grande diferencial é o ambiente para a autoria e apresentação de cursos na *web*, com condições de adaptabilidade. A sua adaptabilidade é suportada pela criação de um modelo flexível do usuário, onde, para cada aluno, são armazenadas informações sobre o curso, conhecimento, preferências e histórico navegacional (GASPARINI, 2003).

O ambiente AdaptWeb é baseado em um conjunto de ferramentas que suportam as fases de pré-autoria, adaptação de conteúdo e de navegação. A implementação utiliza primordialmente a linguagem de programação PHP (*Hypertext Preprocessor*), o gerenciador de banco de dados MySQL e a linguagem XML para a organizar e disponibilizar as disciplinas.

O AdaptWeb é composto por quatro módulos distintos denominados: (1) módulo de autoria; (2) módulo de armazenamento em XML; (3) módulo de adaptação de conteúdo baseado no modelo do aluno e; (4) módulo de interface adaptativa. A arquitetura do AdaptWeb é apresentada na Figura 2.4.

Figura 2.4 - Arquitetura do Ambiente AdaptWeb.



Fonte: Gasparini (2003)

d) MOODLE (MOODLE - *Modular Object-Oriented Dynamic Learning Environment*)

O MOODLE é um Ambiente Virtual de Aprendizagem que começou a ser desenvolvido na década de 90 por Martin Dougiamas, na Universidade Tecnológica de Curtin, na Austrália.

O MOODLE é um software livre sob a *GNU Public License*, desenvolvido na linguagem PHP (*Hypertext Preprocessor*) que armazena a maioria dos objetos de aprendizagem e informações em uma base de dados SQL (*Structured Query Language* ou *Linguagem de Consulta Estruturada*), onde normalmente recomenda-se a utilização do *MySQL*.

Atualmente o AVA MOODLE está na versão 3.5.1 e já foi traduzido para 80 línguas, incluindo o português, e utilizado em mais de 200 países.


O principal objetivo do MOODLE é permitir a gestão de cursos executados de forma *on-line*. Franciscato et al. (2008) define o MOODLE como uma plataforma *open source*, ou seja, que pode ser instalada, modificada e distribuída entre os usuários, onde o seu desenvolvimento objetiva no

gerenciamento de aprendizagens e trabalhos colaborativos, permitindo a criação e administração de cursos *on-line*.

Uma das principais vantagens do MOODLE sobre outras plataformas é um forte embasamento na Pedagogia Construcionista, que significa que as pessoas constroem ativamente novos conhecimentos na medida em que interagem com seu ambiente (FILHO, 2004).

Por ser uma ferramenta de software livre, o MOODLE trabalha com uma estrutura modular de fácil desenvolvimento que permite que a comunidade ajude em suas melhorias e adaptações. Além disso, o MOODLE disponibiliza uma comunidade virtual, onde usuários podem interagir através dos sites da comunidade para compartilhar ideias, códigos, informações e suporte gratuito, conforme Figura 2.5.

Figura 2.5 – Participação da Comunidade Virtual do MOODLE



Fonte: <https://lang.moodle.org/>

Além disso, esse Ambiente Virtual de Aprendizagem possui características importantes, como: escalabilidade, facilidade de uso, estabilidade, segurança, roda em multiplataformas (*Windows, Linux, Unix, MAC*), possui uma interface simples e interativa com o usuário que pode ser personalizada de acordo com a Instituição de Ensino (conforme Figura 2.6 e Figura 2.7) e interoperabilidade, visto que utiliza o padrão SCORM (*Sharable Content Object Reference Model*), garantindo a importação e exportação de conteúdos e a migração dos dados para outros Ambientes Virtuais de Aprendizagem que utilizem o mesmo padrão.

Figura 2.6 - Interface do Ambiente Virtual de Aprendizagem MOODLE do Instituto Federal Sul-rio-grandense/Campus Pelotas - Visconde da Graça – Tela principal.



Fonte: Autoria própria

Figura 2.7 – Instituto Federal Sul-rio-grandense/Câmpus Pelotas - Visconde da Graça – Tela dos Cursos.




Fonte: Autoria própria

Segundo Dougiamas e Taylor (2003), o MOODLE pode ser ligado a outros sistemas, tais como servidores de e-mail ou diretórios de pesquisa, isto porque a arquitetura desse ambiente separa a interface do código (usando transformações XML com XSL), o que permite que a interface seja definida quase de forma independente da lógica e do armazenamento.

Dentre os principais recursos disponíveis no MOODLE estão os materiais estáticos, como por exemplo, páginas de texto, páginas *Web*, conteúdos de pastas, dentre outros. Os materiais dinâmicos (atividades), como fóruns (locais de debate, partilha de ideias e esclarecimento de dúvidas), gestão de conteúdos (recursos), questionários e pesquisas com diversos formatos. *Blogs*, *wikis*, *chats*, glossários, etc., conforme visualizado na Figura 2.8

Figura 2.8 - Atividades e recursos do MOODLE.



Fonte: Autoria própria

Uma das ferramentas disponíveis no MOODLE são os relatórios, que são de aspecto quantitativo, servindo para questões estatísticas, onde auxiliam na gestão dos cursos ou disciplinas. Os relatórios disponibilizados pela plataforma são:

- Relatório de Acesso (*logs*): Gerenciamento de acesso de todos os participantes inscritos no curso, podendo ser de forma geral ou individual.

Neste relatório é apresentado: dia e horário que o aluno acessou a plataforma, a ação realizada e IP de acesso.

- Relatório de *Logs Ativos*: Mostra os usuários logados no momento da consulta com os mesmos dados apresentados no relatório citado anteriormente.

- Relatório de Atividades do Curso: contém todas as atividades da disciplina ou curso, mostrando o número de visualizações de cada atividade e o último acesso da mesma.

- Relatório de Participação do Curso: Permite visualizar cada uma das atividades do curso e saber como e o quanto esta atividade foi acessada na disciplina.

O MOODLE também proporciona a integração com *plugins*, ou seja, com ferramentas que podem ser integradas ao Ambiente Virtual, criados voluntariamente pela comunidade de usuários desta plataforma.

2.1.3 Síntese dos ambientes de *e-learning*

Concluindo, pode-se observar que a maioria dos projetos citados acima, estão focados, principalmente, na disponibilização de conteúdo e na comunicação entre os alunos, utilizando somente alguma ou nenhuma técnica de recomendação associada.

Além disso, fazendo-se uma comparação entre os ambientes de *e-learning* abordados nesse trabalho, a utilização do MOODLE, como AVA, vem crescendo rapidamente. Segundo dados extraídos do site oficial do ambiente, até julho de 2018, 232 países e 100,673 sites usam a plataforma.

A Tabela 2.1 mostra dados sobre a utilização do MOODLE até julho de 2018.

Tabela 2.1 - Dados sobre utilização do MOODLE

INDICADOR	QUANTITATIVO
Sites registrados	100,673
Números de Países	232
Números de Cursos	15,035,625
Números de Usuários	131,120,410
Inscrições	569,820,396
Postagens no fórum	285,805,003
Recursos utilizados	133,571,020
Questões do quiz	851,688,693

Fonte: <http://MOODLE.org/stats/>, acesso em: 29 de julho de 2018.

2.2 Técnicas de Recomendação

Os Sistemas de Recomendação visam identificar itens que interessam aos usuários. Eles aprendem com a história dos usuários de interações passadas sobre suas preferências, interesse e uso juntamente com informações demográficas e características de produtos, a fim de fazer recomendações personalizadas aos usuários (BURKE, 2007). Eles são mais comumente encontrados em sites de comércio eletrônico (Amazon) e sites de filmes *online* (Netflix). Mais recentemente, eles têm sido utilizados na aprendizagem com tecnologia avançada (TEL) para recomendar materiais de aprendizagem (DRACHSLER et al., 2015).

Para que ocorra uma personalização das recomendações, os Sistemas de Recomendação necessitam utilizar os padrões de comportamento dos usuários para fundamentar suas recomendações. Portanto, o Sistema de Recomendação utiliza técnicas de filtragem de informação para identificar esses padrões de comportamento, sendo as mais conhecidas como: Filtragem Baseada em Conteúdo (FBC) e Filtragem Colaborativa (FC).

Além dessas técnicas mais conhecidas, Burke (2002) define também a baseada em conhecimento e baseada em utilidade. Na primeira delas, intitulada de filtragem baseada em conhecimento, a recomendação dos itens é feita baseada nas inferências das preferências do usuário e suas necessidades através de conhecimento estruturado de forma funcional. Alguns exemplos clássicos dessa abordagem são: Google e *The Entreé* (BURKE, 2002). Na segunda técnica, intitulada de filtragem baseada em utilidade, a recomendação é realizada considerando a utilidade dos itens para um determinado usuário,

alguns exemplos clássicos são Tetê-a-Tête e *PersonaLogic*. (GUTTMAN; MOUKAS; MAES, 1998)

Alguns autores, como Montaner et al. (2003), destacam que existe um terceiro tipo de filtragem de informação denominada de filtragem demográfica. A filtragem demográfica utiliza a descrição de um indivíduo para aprender o relacionamento entre um item em particular e o tipo de indivíduo que poderia vir a se interessar. Este tipo de abordagem utiliza as descrições das pessoas para conseguir aprender o relacionamento entre um item e o tipo de pessoa que gostaria deste. O perfil do usuário é criado pela classificação dos usuários em estereótipos que representam as características de uma classe de usuários. Dados pessoais são requisitados ao usuário, geralmente em formulários de registro, e usados como caracterização dos usuários e seus interesses.

Segundo Adomavicius e Tuhilin (2005) e Burke (2002) existem pesquisadores que muitas vezes utilizam mais de uma técnica de filtragem para melhorar a resposta da recomendação. Essa técnica denomina-se de filtragem híbrida.

Além das técnicas de filtragem de informação, outras também já foram usadas no contexto dos Sistemas de Recomendação, como: Mineração de Dados (AGRAWAL; IMIELINSKI; SWAMI, 1993), Raciocínio baseado em casos (AKTAS et al., 2004) e ontologias (GRUBER, 1996).

A seguir, detalharemos as abordagens mais tradicionais, como filtragem baseada em conteúdo e filtragem colaborativa.

2.2.1 Filtragem Baseada em Conteúdo

A filtragem baseada em conteúdo emprega a comparação entre o conteúdo dos itens, de forma a recomendar itens parecidos aos que o usuário gostou no passado. Por exemplo, se no perfil do usuário contém as palavras "*e-learning*", "aprendizagem" e "MOODLE", em um novo estudo sobre Educação à Distância é muito provável que este seja recomendado a ele, porque o artigo e o perfil de usuário têm palavras em comuns. A ideia desta técnica é que se o usuário gostou de um item no passado, ele tende a gostar de outros itens com conteúdo similar no futuro. Essa abordagem tem suas

origens nas técnicas empregadas em Sistemas de Recuperação de Informação (TORRES, 2004).

Nesta técnica, a recomendação é feita de forma automática, então não necessita que uma pessoa avalie o produto primeiramente para gerar novas recomendações. As informações sobre o perfil do usuário podem ser obtidas pelo próprio usuário, como uma consulta realizada por ele, ou coletadas através do conteúdo dos itens que o usuário consome normalmente.

Uma técnica muito comum neste tipo de abordagem é a indexação de frequência de termos (*term frequency indexing*) (HERLOCKER, 2000). Neste tipo de indexação, informações dos documentos e necessidades dos usuários são descritas por vetores com uma dimensão para cada palavra que ocorre na base de dados. Cada componente do vetor é a frequência que a respectiva palavra ocorre em um documento ou na consulta do usuário. Sendo assim, os vetores dos documentos que estão próximos aos vetores de consulta são considerados os mais relevantes para ele.

No entanto, um problema verificado através dessa técnica é que deve ser verificada não somente a frequência que esta palavra aparece no texto, mas a importância que esta palavra tem no texto, por exemplo, a palavra “tecnologia” pode aparecer várias vezes em um texto de informática mas pode não ser considerada uma palavra relevante para esse texto, enquanto que a palavra “saúde” pode nem aparecer em um texto de medicina, mas ser extremamente importante (TORRES, 2004).

Outros exemplos de filtragem baseada em conteúdo são sistemas de recuperação booleanos, onde a consulta é um conjunto de palavras-chave combinadas com operadores booleanos; sistemas de filtragem probabilística, onde o raciocínio probabilístico é utilizado para determinar a probabilidade que um documento possui de atender as necessidades de informação de um usuário; e interfaces de consultas com linguagem natural, onde segundo o autor as consultas são colocadas em sentenças naturais (HERLOCKER, 2000).

Desta forma, a filtragem baseada em conteúdo parte do princípio de que os usuários tendem a interessar-se por itens similares aos que demonstraram interesse no passado, definindo então, a similaridade entre os itens (HERLOCKER, 2000).

No entanto, em alguns casos, pode haver maior dificuldade para estabelecer a similaridade entre textos, as palavras “casa” e “moradia”, por exemplo, são sinônimas, mas para que a recomendação consiga identificar que os dois termos possuem o mesmo significado seria necessária a identificação dos atributos nos itens a serem comparados (tipo, localização, etc.). No caso dos itens serem artigos (ou documentos), este processo de comparação pode ser facilitado, pois documentos podem ser considerados similares se compartilharem termos em comum, ou seja, palavras-chave.

Para o cálculo da similaridade entre textos, o algoritmo TF-IDF (inglês para *Term Frequency – Inverse Document Frequency*) é bastante utilizado (ROBERTSON, 2004). A semelhança TF-IDF combina a frequência dos termos em documentos com a distribuição dos termos em toda a coleção de documentos. Teoricamente, os documentos com alto número de palavras similares e também com palavras distintas deve ser o mais semelhante à consulta.

Proposto como forma de avaliar similaridade entre textos, o que o TF-IDF mede é a importância de um certo termo de um documento levando em consideração uma coleção ou corpo de documentos. Para tanto, o algoritmo se vale de dois coeficientes, um sendo a frequência de aparições do termo no documento específico (TF), ou seja, uma medida do quão importante o termo é para o documento em questão, e o outro uma medida da raridade do termo no corpo de todos os documentos (IDF), ou seja, o quão característico o termo é para os documentos nos quais aparece. O peso TF-IDF de um termo de um documento é obtido então multiplicando-se estes dois coeficientes.

Segundo Torres (2004) esta técnica não realiza a avaliação qualitativa dos itens que são recomendados, pois basta que haja similaridade entre os atributos que são comparados para que o item seja recomendado para o usuário. Desta forma, a descrição dos itens deve ser bem elaborada, pois até mesmo a utilização de sinônimos pode gerar recomendações erradas.

Outra desvantagem dessa técnica é que a tecnologia atual não é capaz de analisar com êxito vídeo e áudio. Alternativamente, as revisões dos itens (como filmes) têm sido utilizadas, mas tem o problema das análises e das opiniões dos revisores que nem sempre estão disponíveis em formato digital.

A fim de propiciar um melhor entendimento da Técnica de Filtragem Baseada em Conteúdo, foi elaborada a Tabela 2.2.

Pode-se observar que apesar dessa técnica poder ser aplicada a qualquer domínio, é mais indicada em domínios cujos itens tenham quantidade considerável de informação armazenada em forma textual, onde o conteúdo é geralmente descrito com palavras-chave (SALTON; MCGILL, 1983).

Além desta limitação, a Filtragem Baseada em Conteúdo também sofre com outros problemas, como a super-especialização, ou seja, itens que podem ser do interesse do usuário, mas não são similares aos que ele já consumiu provavelmente nunca serão recomendados, limitando a abrangência das recomendações.

Tabela 2.2: Resumo da Filtragem Baseada em Conteúdo

Filtragem baseada em conteúdo	
Objetivo	<ul style="list-style-type: none"> • Gerar automaticamente descrições dos conteúdos dos itens e compará-los a descrição de cada item com a descrição do interesse do usuário, verificando se o item é ou não relevante para esse usuário.
Vantagens	<ul style="list-style-type: none"> • Não possui o problema do primeiro avaliador. • Recomenda todos os itens. • Redução da esparsidade.
Desvantagens	<ul style="list-style-type: none"> • Superespecialização (Impossibilidade de recomendar novos produtos) • Não avalia aspectos como a qualidade dos itens a serem recomendados (estrutura, escrita, autoria, etc.) • Palavras sinônimas não são recomendadas. • Impossibilidade de análise de conteúdo em domínios não textuais (imagem, vídeo e áudio).
Técnicas utilizadas	<ul style="list-style-type: none"> • Técnica de indexação de frequência de termos (algoritmo TF-IDF) • Índices de busca booleana. • Sistemas de filtragem probabilística

Fonte: Autoria própria.

2.2.2 Filtragem Colaborativa

A filtragem colaborativa tem por objetivo recomendar um item para um usuário se usuários semelhantes gostaram desse item. A intuição por trás disso é que se os usuários concordaram com seus gostos no passado, eles tendem a concordar novamente no futuro (TORRES, 2004).

Essa técnica é utilizada no dia-a-dia das pessoas, o famoso “boca-a-boca” (TORRES, 2004; HERLOCKER et al., 1999), onde uma pessoa recomenda para outra um restaurante que frequenta ou um livro que leu, por exemplo.

Segundo Herlocker (2000), os primeiros sistemas de filtragem colaborativa exigiam que o usuário informasse ao sistema quais eram seus interesses. Com o avanço das pesquisas os sistemas passaram a automatizar este processo, associando os interesses em comum dos usuários partindo da avaliação que eles atribuem aos itens.

Um dos primeiros sistemas de recomendação, o Tapestry (TORRES, 2004), da Xerox Palo Alto., tinha a finalidade de recomendar emails que vinham de diversas listas e utilizavam uma filtragem colaborativa para organizar os emails de interesse ao usuário-alvo.

Após esse trabalho foi desenvolvido o sistema GroupLens (TORRES, 2004) que impulsionou a pesquisa dessa área sendo citado por diversos outros trabalhos. Esse sistema recomendava notícias avaliadas quantitativamente por notas de 1 a 5 pelos usuários relacionando o quanto o usuário gostou daquela notícia e utilizando a técnica de filtragem colaborativa para apresentar notícias personalizadas.

O sistema Ringo é um sistema desenvolvido para recomendação personalizada de música e foi desenvolvido no *Massachusetts Institute of Technology* (TORRES, 2004), tinha a mesma abordagem de GroupLens mas usava uma escala de 1 a 7, sendo 4 um limiar neutro. Neste sistema os usuários descreviam suas preferências musicais através da avaliação de algumas canções. Estas avaliações constituem o perfil dos indivíduos. O sistema usa então estes perfis para gerar recomendações para usuários individuais. Para o seu funcionamento, primeiramente usuários similares eram identificados, a partir desta identificação e comparação de perfis o sistema poderia prever o quanto o usuário gostaria de um álbum/artista que ainda não tivesse sido avaliado pelo mesmo.

Outro exemplo clássico da técnica de filtragem colaborativa é o sistema de recomendação de filmes *MovieLens* (RIEDL et al., 1999). Nele o usuário insere pontuações para filmes que tenha visto e o sistema utiliza estas

pontuações para encontrar pessoas com gostos similares. Desta forma o sistema pode recomendar filmes nos quais indivíduos com gostos semelhantes se interessariam, mas não assistiram ainda. A Figura 2.9 mostra a página do *MovieLens*, onde os usuários avaliam os filmes em uma escala de 0,5 a 5 estrelas, assim como se ainda não o assistiram.

Figura 2.9 - Página de avaliação do *MovieLens*



Fonte: Autoria própria.

Diante da avaliação feita pelos usuários, o sistema retorna uma página contendo uma lista de sugestão de filmes recomendados à este usuário, baseado nas avaliações de outros usuários com gostos semelhantes, conforme demonstrado na Figura 2.10.

Figura 2.10 - Página de recomendação do *MovieLens*



Fonte: Autoria própria.

Para a implementação da filtragem colaborativa, podem ser utilizados vários métodos sendo os mais utilizados os baseados na formação de uma vizinhança entre os usuários (SARWAR et al., 2001; HERLOCKER et al. 1999; TORRES, 2004) e na geração das previsões (SARWAR et al. 2000; MILLER, 2003).

Na abordagem de formação de vizinhos o objetivo é encontrar os usuários mais semelhantes ao usuário ativo com base em suas últimas avaliações (HERLOCKER, 2000). Segundo Torres (2004) usuário ativo é o usuário para o qual as recomendações estão sendo geradas e usuário semelhante ao usuário ativo é aquele que tem as mesmas opiniões sobre os itens que este avaliou no passado.

O funcionamento se baseia, primeiramente, em fazer uma correlação entre usuários, ou seja, a construção da vizinhança propriamente dita. Em seguida, é feita uma predição do valor que o usuário alvo da recomendação daria a cada item candidato à recomendação. Esta predição baseia-se nos valores das avaliações que os usuários vizinhos do usuário alvo deram ao respectivo item. Predições são então usadas para fazer a recomendação dos itens propriamente dita. Há muitas maneiras de formalizar este "acordo" das avaliações, como métricas de similaridade de cosseno e correlação de Pearson (MILLER, 2003; HERLOCKER, 2000).

A métrica de similaridade do cosseno considera as avaliações de cada usuário como um vetor e a proximidade entre os usuários é medida pelo cosseno do ângulo entre os dois vetores, que é dada pela Equação 1. (TORRES, 2004)

$$\cos\left(\vec{u}, \vec{v}\right) = \frac{\vec{u}}{\|\vec{u}\|_2} \cdot \frac{\vec{v}}{\|\vec{v}\|_2} \quad (1)$$

Nesta equação u e v são os vetores que representam as avaliações dadas pelos usuários u e v .

A métrica de correlação de Pearson mede o grau da correlação entre os usuários com base nas suas avaliações, conforme a (TORRES, 2004, SHARDANAND; MAES, 1995, HERLOCKER et al., 1999, SARWAR et al., 2000).

$$w_{a,u} = \frac{\sum_{i=1}^m (r_{a,i} - \bar{r}_a)(r_{u,i} - \bar{r}_u)}{\sqrt{\sum_{i=1}^m (r_{a,i} - \bar{r}_a)^2} \sqrt{\sum_{i=1}^m (r_{u,i} - \bar{r}_u)^2}} \quad (2)$$

Na equação 2, $w_{a,u}$ representa a similaridade entre o usuário ativo a e um vizinho u ; $r_{a,i}$ é a avaliação dada pelo usuário a para o item i ; $r_{u,i}$ é conjunto de avaliações do usuário similar a u . O resultado de $w_{a,u}$ indica a similaridade dos usuários. Todos os somatórios e médias da fórmula são calculados apenas sobre os itens que, ambos, o usuário e o usuário u tem avaliado.

O coeficiente de correlação de Pearson retorna um número no intervalo $[-1; 1]$, que indica o quanto um usuário concorda ou discorda de outros usuários, onde -1 indica que discorda completamente, 1 indica que concorda completamente e 0 indica que os usuários não estão correlacionadas.

A geração da predição é feita independentemente do coeficiente utilizado no cálculo da similaridade, pois ela será gerada através de uma média ponderada das avaliações dos vizinhos que obtiveram um coeficiente de similaridade aceitável, ou seja, com limiar igual ou superior, por exemplo, a $0,3$. A equação 3 é utilizada para o cálculo da predição (REATEGUI; CAZELLA, 2005, TORRES, 2004).

$$P_{a,i} = \bar{r}_a + \frac{\sum_{u=1}^n (r_{u,i} - \bar{r}_u) \cdot w_{a,u}}{\sum_{u=1}^n |w_{a,u}|} \quad (3)$$

Sendo que $P_{a,i}$ a predição de um item i para um usuário alvo a ; \bar{r}_a é a média de todas as avaliações do usuário alvo a aos itens que foram pontuados por todos os seus usuários similares; $r_{u,i}$ é a avaliação que o usuário alvo u atribuiu para o item i ; \bar{r}_u é a média de todas as avaliações do usuário u em comum com o usuário a .

Um outro caminho para um sistema gerar recomendações é o sistema gerar previsões para todos os itens vazios e, em seguida, só filtrar os itens que não são relevantes para a busca do usuário e retornar uma lista classificada como um resultado (CAZELLA et al., 2000).

Existem vários tipos de abordagem de filtragem colaborativa que utilizam estes métodos, como: a) usuário-usuário (HERLOCKER et al., 1999; SARWAR et al., 2000), b) item-item (MILLER, 2003) e c) co-ocorrências (MCNEE et al., 2002).

a) Filtragem Colaborativa Usuário-Usuário

A filtragem colaborativa usuário-usuário utiliza o algoritmo de formação de vizinhos como padrão (TORRES, 2004). Neste algoritmo, o espaço do problema pode ser modelado como uma matriz onde as linhas representam os "usuários", as colunas representam os "itens" e as células representam as classificações que os usuários deram a itens. Se uma célula estiver vazia, isso significa que o usuário não avaliou esse item. Um exemplo de uma matriz de avaliações é mostrado na Tabela 2.3.

Tabela 2.3 - Exemplo de uma matriz de avaliação usuário-usuário

Lista de Livros Clássicos Infantis					
	Pinóquio	Cinderela	Os Três Porquinhos	Chapeuzinho Vermelho	Rapunzel
Eduardo	5	3	4	5	2
Erick	?	2	?	5	-
Larissa	2	5	-	-	4
Murilo	4	3	5	5	1
Victória	3	5	-	-	4

Fonte: Autoria própria.

Neste exemplo, se quisermos recomendar livros ao usuário Erick procuraremos outros usuários com hábitos de consumo semelhantes. Por análise verificamos que Eduardo e Murilo são os melhores vizinhos de Erick, pois eles possuem avaliações semelhantes aos livros que leram no passado e avaliaram o que influenciará fortemente na recomendação para Erick. Por outro lado, Victoria e Larissa não concordam com Erick em vários livros, logo não são considerados bons vizinhos e influenciarão menos que Eduardo e Murilo no cálculo da predição. Seriam, então, recomendados à Erick livros que estes dois outros usuários avaliaram, mas que Erick ainda não avaliou, como "Pinóquio" e "Os Três Porquinhos". O livro da "Rapunzel" também foi avaliado pelos usuários Eduardo e Murilo, no entanto, como a nota dada foi 2 e 1, o

mesmo não seria recomendado à Erick, por se considerar uma avaliação muito baixa dada por estes usuários. A decisão sobre a recomendação destes livros baseia-se no histórico de avaliações comuns (formação de vizinhos) e o valor de predição calculado (SARWAR et al., 2000, MILLER 2003).

b) Filtragem Colaborativa Item-Item

Existem também sistemas colaborativos que fazem correlação item-a-item, ao invés de usuário-a-usuário, como vimos acima. Nestes sistemas, a proposta é que se dois itens têm distribuições semelhantes de avaliações sobre a dimensão dos usuários, isto indica uma similaridade entre estes dois itens. Se um usuário possuir um item que seja bastante similar a outro com base nesta medida, este segundo item possivelmente representaria uma boa recomendação (MILLER, 2003).

Um exemplo prático da filtragem colaborativa item-a-item é o site da loja *Amazon*, que utiliza a estratégia de recomendação por associação, onde para cada item comprado e avaliado pelo usuário, o sistema tenta encontrar itens similares e recomendá-los ao usuário (pessoas que compraram x também compraram y).

c) Filtragem Colaborativa de Co-ocorrências

Segundo MCNee et al. (2002) esta abordagem funciona contando as co-ocorrências de um item, ou seja, o algoritmo conta o número de vezes que um determinado item foi avaliado por diferentes usuários para, posteriormente, realizar a recomendação.

Uma das vantagens da Filtragem Colaborativa, especificamente em relação à Filtragem Baseada em Conteúdo, é que não apresenta restrições em relação aos tipos de dados que compõem o conteúdo dos itens, uma vez que a Filtragem Colaborativa não leva em consideração o conteúdo dos mesmos.

Outra vantagem é a ausência do problema de super-especialização das recomendações, ou seja, itens que não estejam diretamente relacionados com o perfil do usuário-alvo das recomendações podem ainda assim ser recomendados. Também temos que a Filtragem Colaborativa leva em conta

fatores como qualidade dos itens e o gosto do usuário, por basear-se na avaliação dos itens por parte dos usuários mais próximos ao usuário alvo.

No entanto se os usuários tiverem gostos que variam do normal, o Sistema de Recomendação terá dificuldades para encontrar outros usuários com gostos similares, sendo assim as recomendações podem tornar-se pobres ou inviáveis.

Segundo Torres (2004) as limitações da Filtragem Colaborativa são identificadas em três itens, conhecidos na literatura como *first-rater problem*, *startup problem* e *sparsity problem*.

O *first-rater problem*, ou problema do primeiro avaliador, consiste no fato de que enquanto um item não receber avaliações por nenhum usuário, ele não pode ser recomendado, pois não estará relacionado a nenhum perfil.

O *cold start* diz respeito ao estado inicial do sistema, quando existem ainda poucos usuários. Com menos usuários, a dificuldade em encontrar similaridades entre os perfis é bem maior e, conseqüentemente, a geração de recomendações perde em qualidade ou é até mesmo inviabilizada.

O *sparsity problem* consiste na dispersão dos itens avaliados pelo usuário em relação a todos os itens pertencentes ao domínio do sistema de recomendação. A proporção de itens avaliados por um usuário específico em relação a itens não avaliados por ele tende a ser muito pequena, resultando na redução do tamanho médio da vizinhança dos usuários. Isso é devido à própria natureza dos sistemas de recomendação, que leva sua aplicação a ser feita em domínios com quantidade de informação muito grande, ou seja, grande número de itens, o que torna impraticável a avaliação de uma parcela significativa de itens por parte dos usuários.

A Tabela 2.4 que apresenta um resumo dessa técnica, a fim de propiciar um melhor entendimento da mesma.

Desta forma, ressaltamos que apesar das limitações apresentadas por esta técnica, segundo Burke (2002), é a técnica mais conhecida, mais implementada e mais madura de todas. Ela reúne as notas ou recomendações atribuídas pelos usuários aos itens, identifica as similaridades entre os usuários baseado em suas avaliações e gera novas recomendações com base em comparações entre os usuários.

Segundo Herlocker (2000), a abordagem da filtragem colaborativa foi desenvolvida para atender pontos que estavam em aberto na filtragem baseada em conteúdo, exatamente por não exigir a compreensão ou reconhecimento do conteúdo dos itens.

Tabela 2.4 - Resumo da Filtragem Colaborativa

Filtragem Colaborativa	
Objetivo	<ul style="list-style-type: none"> • Reconhecer usuários comuns de acordo com as suas avaliações e gerar novas recomendações com base nessa correlação.
Vantagens	<ul style="list-style-type: none"> • Independência de conteúdo, foca na avaliação do usuário. • Ausência do problema de super-especialização das recomendações. • Geração de recomendações baseadas em preferências dos usuários; • Possibilidade de produzir recomendações inesperadas e de alta qualidade.
Desvantagens	<ul style="list-style-type: none"> • Possui o problema do primeiro avaliador. • Estado inicial do sistema quando existem poucos usuários. • Problema de dispersão de dados, quando aplicado em grandes domínios. • Pode gerar problema caso os usuários tenham gostos muito inconstantes.
Técnicas utilizadas	<ul style="list-style-type: none"> • Formação de vizinhos (métricas de similaridade de cosseno e correlação de Pearson) • Geração da predição

Fonte: Autoria própria.

2.3 Reputação e Confiança

O estudo dos conceitos de confiança e reputação na *web* não é algo novo. O sistema de avaliação do *eBay*, por exemplo, usa as avaliações positivas e negativas dos clientes como uma medida de reputação do vendedor. O algoritmo *PageRank* (PAGE, 1999) usado pelo motor de busca do Google, também é baseado em uma métrica de confiança para a ordenação dos *sites web*, por meio do número de ligações/*hiperlinks* a uma página específica.

Segundo Costa (2005), um dos aspectos essenciais que deve existir para a consolidação de comunidades é o sentimento de confiança entre as pessoas. A formação dessa confiança depende da capacidade de uma pessoa de se relacionar com outras, e de incluí-las em sua rede de referência. Esse

tipo de inclusão está ligado ao reconhecimento das habilidades dos outros, suas competências e conhecimentos. Quando um indivíduo interage com os outros tem oportunidade de reconhecer os comportamentos, intenções e valores do seu meio.

A reputação de uma entidade usualmente é estimada com base em um histórico de relacionamentos com outras entidades (GOMES, 2009), (CRUZ et al., 2007). A reputação representa a opinião geral de um grupo sobre alguém. Normalmente, uma entidade com boa reputação tem influência em outras entidades, e induz a ter uma alta confiança nas interações com essa entidade.

Para Josang et al. (2007) o conceito de reputação e confiança estão intimamente ligados, no entanto os sistemas de confiança oferecem uma visão particular, enquanto os sistemas de reputação oferecem uma visão do grupo.

Dasgupta (2000) afirma que a confiança é baseada na reputação e que esta deve ser adquirida com base no comportamento através do tempo. Da mesma forma, a reputação também é adquirida com o tempo, porém ela deve ser pública. Para Oliveira Albuquerque (2008), a reputação pode ser definida em um cenário em que não há informação suficiente para realizar a inferência sobre a confiança de um membro, e para descobrir se a entidade é confiável, outros membros da rede são questionados.

Sabater and Sierra (2001, p. 44), definem reputação como “opinião ou visão de alguém sobre algo” e apresenta três noções de reputação: individual, social e ontológica. Reputação individual refere-se a como as impressões de um único indivíduo são julgadas por outros. Reputação social refere-se a impressão sobre indivíduos baseado na reputação do grupo social a que pertencem. Reputação ontológica depende do contexto em que se encontra a reputação, onde a reputação de um indivíduo pode ter diferentes classificações em comunidades distintas.

Segundo Ferris et al. (2003) a reputação é formada dentro de um contexto específico, que inclui o conjunto de papéis do indivíduo, as normas sociais e o ambiente. As questões sobre os relacionamentos entre esses fatores e as formas pelas quais eles afetam a formação da reputação são subjetivas e complexas, pois dependem da percepção que as pessoas tem de uma dada situação.

Portanto, um sistema com modelo de reputação tem o objetivo de coletar, distribuir e agregar informações sobre o comportamento passado de seus membros, de maneira a ajudá-los a decidir em quem confiar, encorajando comportamentos leais e dissuadindo comportamentos desonestos (Resnick et al., 2000).

Sistemas de reputação foram projetados para uso em diversos ambientes e tem se tornado um componente principal no âmbito computacional, principalmente em comunidades eletrônicas, mais precisamente em redes sociais, visto que estas comunidades precisam das noções de confiança e credibilidade a fim de fortalecer o comprometimento e a responsabilidade entre os parceiros.

Segundo Cervi et al. (2011), a utilização de métodos de reputação pode-se dar na (i) detecção de clientes em sites de vendas on-line; (ii) recomendação de produtos; (iii) recomendação de especialistas para a participação de bancas; (iv) detecção de pesquisadores para a formação de rede de colaboração científica; (v) organização de comitê de programas científicos; (vi) organização de corpo editorial e também em sites de compartilhamento de notícias, sites de redes sociais e fóruns de mensagens.


Além dessas aplicações, o uso de modelos de reputação em ambientes de aprendizagem também é algo importante, visto que envolve o intercâmbio de informação e conhecimento entre membros da uma comunidade, e há uma grande necessidade de classificar a informação, distinguindo-a entre útil e não útil ou fidedigna e duvidosa. O cálculo da reputação dá uma ideia da confiança que um membro pode ter em outro e serve para guiar a procura por especialistas (PUJOL et al., 2002).

2.3.1 Componentes de Sistemas de Reputação

Segundo Friedman et al. (2007), os Sistemas de Reputação podem ser divididos em diferentes componentes de acordo com aspectos do comportamento da rede social ou do usuário, entretanto, todos eles compartilham alguns componentes básicos.

De acordo com Liu et al. (2010), um sistema de reputação é composto pelos componentes exibidos na Figura 2.11.

Figura 2.11 - Estrutura de sistemas de reputação.



Fonte: Traduzido de Liu et al. (2010).

1. **Entrada** - refere-se a coleta de informações utilizadas no cálculo da reputação e outros dados relacionados.

2. **Processamento** - o objetivo do processamento é aplicar a métrica de cálculo. A métrica define como os parâmetros referentes às transações são reunidos em um único valor indicando a reputação da entidade avaliada, assim como quais parâmetros são avaliados. Na maioria dos casos, sistemas usam métricas simples, como o somatório ou média dos valores da reputação.

3. **Armazenamento** - as informações de reputação podem ser armazenadas de diferentes formas, ou seja, no nó avaliado ou no nó que fez a avaliação ou em algum repositório centralizado. Quando o armazenamento é feito em cada nó, torna-se mais difícil a identificação de uma determinada reputação, visto que é necessária uma busca na rede.


4. **Saída** - é o processo de se tornar público o valor da reputação.

5. **Retorno** - garante a acurácia do valor da reputação. Alguns sistemas de reputação permitem que os usuários opinem sobre o cálculo da reputação, e.g, a *Amazon* solicita aos usuários que avaliem sobre a reputação calculada e pede para classificá-la quanto a sua utilidade.

2.3.2 Tipologia

Baseado na revisão da literatura e em várias noções de reputação, Mui (2002) propôs uma tipologia de reputação, a qual é apresentada na Figura 2.12.

Figura 2.12 - Tipologia de reputação



Fonte: Traduzido de Mui (2002).

a) Individual e Grupo - a reputação pode indicar um indivíduo ou um grupo de indivíduos. Sistemas de reputação utilizados pelos sites *eBay*, *Amazon*, *Free Haven*, baseiam-se na reputação dos indivíduos. A reputação de grupo pode ser calculada como a média das reputações de seus membros. Sabater e Sierra (2001), em sua pesquisa, tem estudado este tipo de reputação que é inferida de um grupo de reputações individuais.

b) Direta e Indireta - pode-se considerar que a reputação individual pode ser obtida a partir de informações obtidas diretamente, ou à partir de inferências de informações obtidas indiretamente. A reputação direta refere-se às estimativas realizadas por um avaliador com base em experiências diretas, ou seja, experiências obtidas pelo avaliador. Reputação indireta refere-se às estimativas obtidas de terceiros, ou seja, experiências que não foram realizadas pelo avaliador.

c) Observada - esta reputação corresponde a *feedbacks* de usuários sobre os outros membros, os quais eles interagem diretamente.

d) Interação - reputação “observada” difere da “interação” pelo fato que esta última baseia-se em interações atuais entre o avaliador e o membro avaliado. O fator de impacto *Journal Impact Factor* determinado pela análise de citações é uma reputação “observada”. Entretanto, pesquisadores podem não concordar com o fator de impacto. Neste caso, cada pesquisador pode revisar a reputação com base no conhecimento que possui de cada publicação.

e) Derivada-anterior - esta reputação considera o conhecimento prévio que um indivíduo possui sobre outro. Quando não possui conhecimento, o avaliador distribui um valor de forma uniforme a todos os avaliados, de forma que nenhum membro fique com baixa reputação por falta de conhecimento do agente avaliador.

f) Derivada-grupo - este modelo de reputação provê estimativas de reputação para um indivíduo baseada na reputação do grupo o qual ele pertence. Sabater e Sierra (2001) pesquisaram diferentes mapeamentos entre a reputação individual de um membro desconhecido e o grupo do qual ele é proveniente.

g) Propagada - neste tipo, a reputação de um indivíduo é calculada com base em informações transmitidas por outros indivíduos do mesmo grupo. Neste caso, a reputação pode ser transmitida de membro a membro.

Além da tipologia, os sistemas de reputação se diferenciam a partir de alguns critérios. De acordo com Casare and Sichman (2005), são descritos:

h) Natureza da reputação - identifica que tipo de entidade a reputação se aplica, e.g., indivíduo, grupo, produto, serviço, organização;

i) Papel - identifica quais os papéis que as entidades envolvidas na formação da reputação assumem, e.g., papel de alvo, de avaliador ou de transmissor da reputação;

j) Tipo da reputação - classifica a reputação a partir da origem da informação utilizada na sua formação, podendo ser individual ou de grupo, e direta ou indireta;

k) Valor da reputação - identifica o tipo do valor da reputação, podendo ser um valor consolidado ou um valor detalhado por meio de atributos;

l) Fator de avaliação - identifica quais os fatores considerados na avaliação da reputação, e.g., a informação fornecida por uma entidade ou as relações existentes entre elas;

m) Manutenção da reputação - identifica o método utilizado para a propagação ou cálculo da reputação, e.g., uma entidade é responsável pela coleta e distribuição da informação ou esta pode ser realizada por qualquer nó.

Os tipos de reputação apresentados têm sido estudados e aplicados por diversos pesquisadores em sistemas atuais. Na Seção 2.3.3 são mostrados como estes tipos podem ser utilizados em modelos de cálculo de reputação.

2.3.3 Modelos de Cálculo

Diante da diversidade de aplicações e contextos, diferentes técnicas de cálculo de reputação têm sido implementadas, com resultados diversos. Segundo Pujol et al. (2002), o mecanismo usual de medida de reputação baseia-se no fornecimento de informações pelos usuários ou membros da rede. Estas informações indicam a autoridade ou reputação que um usuário pode ter, onde a cada membro da rede é associado um grau de autoridade que indica a sua importância na rede. Para o autor, esta autoridade pode ser propagada de um membro para outro, e a autoridade de um nó ou membro depende da autoridade dos nós relacionados a ele.

Este mecanismo permite que os membros avaliem a atuação dos indivíduos e identifiquem as reputações avaliadas perante a opinião da comunidade, criando assim suas redes de confiança.

A desvantagem deste mecanismo de mensuração é a necessidade do envolvimento explícito e frequente dos usuários na rede. Isto implica que uma boa medição da reputação depende criticamente do envolvimento dos usuários e de sua contínua contribuição na mensuração.

Neste contexto, Cruz et al. (2007) descrevem três formas de calcular a reputação em serviços oferecidos na Web:

- a) **Comércio eletrônico** - em sites de comércio eletrônico (e.g., Amazon), os usuários avaliam produtos através de notas e comentários. Essas avaliações são utilizadas para recomendar produtos similares para os próprios usuários ou para outros clientes com preferências similares às deles. Para garantir a credibilidade das recomendações, o sistema de reputação coleta a opinião dos usuários sobre as avaliações de produtos, onde eles indicam se uma avaliação foi útil ou não na sua decisão de compra. Com base nessas avaliações, os clientes podem adicionar avaliadores às suas redes de confiança ou bloquear avaliadores cujas opiniões eles não confiam.

- b) **Leilão** - os sites de leilão *ebay* e MercadoLivre coletam informações (*feedback*) dos usuários sobre as negociações realizadas. O usuário avalia sua transação de forma positiva (+1), negativa (-1), ou neutra (0). A reputação de um comprador ou vendedor é representada pelo saldo de avaliações positivas e negativas que ele recebe de diferentes usuários com quem negociou. Se um vendedor recebe várias avaliações repetidas de um mesmo comprador, o sistema só contabiliza uma dessas avaliações. Isso garante que a reputação do vendedor seja um reflexo da opinião de diferentes compradores que negociaram com ele e não de apenas um.

- c) **Notícias** - em sites de notícia (e.g. *Slashdot*), os usuários postam e comentam notícias. Os comentários podem ser avaliados por todos os outros usuários (moderadores) através de notas que contam pontos positivos ou negativos para o autor do comentário. As avaliações dos moderadores são julgadas por usuários mais antigos (meta-moderadores), para minimizar a ação de moderadores injustos ou desonestos. Assim, usuários com maus

comportamentos perdem pontos de reputação e privilégio de moderação.

Outro método alternativo de medir a reputação baseia-se na localização de cada membro em sua comunidade da rede social. A localização de um dado membro na rede social pode ser usada para inferir alguma propriedade sobre seu grau de experiência, por exemplo, reputação. Membros que são bem conhecidos e respeitados pela maioria dos outros membros da comunidade, tendem a ser facilmente identificados como os nós mais conectados em um grafo de rede social da sua comunidade. Esta informação pode ser uma base para o mecanismo de reputação usado ao invés de capturar graus de autoridade distribuídas por cada usuário. Alguns algoritmos usados na classificação de páginas na *Web* baseiam-se neste método de reputação, podemos citar o HITS (KLEINBERG, 1999), o Page Ranking (PAGE et al., 1999) e o NodeRanking (PUJOL et al., 2002).

Independente do método de reputação, segundo Resnick et al. (2000) um sistema de reputação deve possuir algumas características básicas:

- Cada membro deve ter um tempo mínimo de vida, a fim de que as interações entre eles sirvam de instrumento para expectativas futuras;
- Deve-se levar em conta a disposição dos usuários em informarem dados para o cálculo da reputação, atividade para a qual certas vezes é necessário oferecer incentivo;
- O histórico da reputação de um membro deve influenciar decisões atuais.

Baseado no que foi exposto, conclui-se que não existe uma fórmula única para que sejam construídos sistemas de reputação. O fato de um modelo se adaptar a uma rede não significa que possa servir a outras. Basta considerar que os propósitos de cada rede nem sempre são iguais, assim como o tipo de relação que se estabelece entre os membros de uma rede.

2.3.4 Modelos de Classificação

Para facilitar a identificação da reputação do usuário ou membro em uma comunidade, pode-se atribuí-la a uma hierarquia de níveis, onde a reputação pode ser classificada de diferentes maneiras. De acordo com Lima (2010) a reputação pode ser classificada como:

- a) Baseada em Perfil** - este modelo de classificação é baseado na existência de perfis de usuário, onde cada usuário pertence a um perfil que pode ser alterado conforme a participação do mesmo na comunidade. Este modelo estimula encontros na rede e a cooperação entre os usuários devido à união de usuários com perfis semelhantes. É recomendado para modelos de reputação que dependem da interação do usuário. O site de vendas MercadoLivre classifica a reputação de seus usuários em perfis conforme é exibida na Figura 2.13.

Figura 2.13 - Classificação baseada em perfis.

	Programa de MercadoLíderes					Mercadolivre	Mercadolivre Duel	Mercadolivre Platinum
	6 ou mais	6 ou mais	8 ou mais	5 ou mais	25 ou mais	60 ou mais	280 ou mais	871 ou mais
Negociações realizadas	6 ou mais	6 ou mais	8 ou mais	5 ou mais	25 ou mais	60 ou mais	280 ou mais	871 ou mais
Vendas concretizadas	0% ou mais	43% ou mais	60% ou mais	73% ou mais	84% ou mais	84% ou mais		
Percentual de qualificações positivas	0% ou mais	75% ou mais	83% ou mais	89% ou mais	99% ou mais	99% ou mais		

Fonte: www.mercadolivre.com

- b) Baseada em níveis numéricos** - este modelo é utilizado para visualizar a reputação do usuário e dar a idéia de sua evolução na comunidade. Esse tipo de classificação se adapta melhor à comunidades mais competitivas que a modalidade anterior devido ao fato de a comparação entre números ser mais intuitiva que a comparação entre nomes de categorias. A Figura 2.14 exibe uma classificação baseada em níveis numéricos.

Figura 2.14 - Classificação baseada em níveis.

Nível	Pontuação
1	1 até 500
2	501 até 1000
3	1001 até 5000
4	5001 até 10000
5	10001 até 20000

Fonte: Autoria própria

- c) **Baseada em identificação de membros** - utilizado em comunidades que fazem uso de rótulos, ao invés de números ou perfis, para identificação de membros a fim de legitimar os usuários como confiáveis ou portadores de certos papéis dentro daquele contexto. Dessa forma, ao invés de um usuário pertencer a um perfil denominado “Gold” ou a um nível numérico “Nível 5”, é atribuído a ele um ou mais rótulos que claramente o distingue dos demais usuários, e.g., “Contribuidor Top” ou “Membro da elite”. Este modelo é muito utilizado para distinguir representantes de uma comunidade e usuários de um sistema conforme é apresentado na Figura 2.15.

Figura 2.15 - Classificação baseada em membros.

Tipos de usuário
Convidado
Usuário
Programador
Gerente
Administrador

Fonte: Autoria própria

- d) **Baseada em pontos** - este modelo geralmente é usado em conjunto com outros modelos de classificação como “Baseado em Perfil” e “Baseado em níveis numéricos”, e é indicada a comunidades bastante competitivas, e.g., jogos de esportes. A Figura 2.16 apresenta uma classificação dos clubes de futebol brasileiro baseada na pontuação obtida pelos clubes no Campeonato Brasileiro Série A 2018.

Figura 2.16 - Classificação baseada em pontos.

Clube	Pts	PJ	VIT	E	D	GP	GC	SG
1  São Paulo	35	17	10	5	2	27	15	12
2  Flamengo	34	17	10	4	3	28	12	16
3  Internacional	32	17	9	5	3	23	12	11
4  Grêmio	30	17	8	6	3	18	8	10
5  Atlético	27	17	8	3	6	30	25	5
6  Palmeiras	27	17	7	6	4	25	15	10
7  Corinthians	26	17	7	5	5	21	13	8
8  Cruzeiro	25	17	7	4	6	14	14	0

Fonte: globoesporte.globo.com/futebol/brasileirao-serie-a/

e) **Baseada em ranking** - é indicado a comunidades altamente competitivas, onde os membros se interessam basicamente em saber sua posição em relação aos outros membros, ou se pertencem a um grupo diferenciado de membros. Este tipo de classificação é utilizado em conjunto ao sistema baseado em pontos e diferencia-se dos demais, pois sempre destaca os primeiros classificados no ranking, conforme apresentado na Figura 2.17.

Figura 2.17 - Classificação baseada em ranking.

1º	USP	 SP
2º	UFMG	 MG
3º	UFRJ	 RJ
4º	UFRGS	 RS
5º	Unicamp	 SP
6º	Unesp	 SP
7º	UFPR	 PR
8º	UnB	 DF
9º	UFSC	 SC
10º	UFPE	 PE

Fonte: ead.faccat.br/portal/blog

2.3.5 Limitações

Apesar de cada vez mais utilizado em sites *web*, de acordo com RESNICK et al. (2000) existem basicamente três limitações inerentes à eficácia dos sistemas de reputação.

A primeira é que as pessoas podem não se preocupar em fornecer um *feedback* completo de um usuário. Por exemplo, quando uma compra é concluído com sucesso no *eBay*, por exemplo, há pouco incentivo para gastar mais algumas minutos preenchendo um formulário. Nesse caso, seria interessante o avaliador receber um incentivo financeiro, onde o mesmo acumularia pontos e ganharia descontos em novas compras, caso o *feedback* do usuário fosse totalmente preenchido.

A segunda questão é em relação a criação do *feedback* negativo, que é algo bem difícil, pois apenas performances muito ruins são relatadas, há um certo medo do *feedback* negativo, fazendo com que o descontentamento em relação a um usuário permaneça invisível e, portanto, os compradores podem evitar que os vendedores promovam tal descontentamento. Nesse caso, os usuários devem ser conscientizados da importância de um real *feedback* para futuras compras, os quais eles mesmos poderão realizar.

E a terceira é garantir relatórios realmente honestos. Uma parte poderia chantagear outro, isto é, ameaçar postar *feedback* negativo sem relação com real desempenho. No outro extremo, a fim de acumular uma realimentação positiva um grupo de pessoas pode colaborar e avaliar-se mutuamente de forma positiva, inflando artificialmente suas reputações. Um exemplo desta limitação ocorre quando as pessoas usam pseudônimos ao invés de informarem seu nome real, fazendo com que possam efetuar novos registros com outros pseudônimos apagando efetivamente seu registro anterior. Uma alternativa para esse caso seria impedir o sistema de criar pseudônimos, permitindo somente o cadastro com nomes reais, evitando a duplicidade de registros, uma técnica chamada de *once-in-a-lifetime* (FRIEDMAN; RESNICK, 1999).

2.3.6 Considerações do capítulo

Existem várias pesquisas que procuram trabalhar com conceitos ligados à confiança e reputação. Estas pesquisas concentram seus esforços na definição de confiança e reputação do indivíduo frente a percepção dos demais membros de uma comunidade de usuários, ou seja, a reputação ou o nível de confiança de um usuário não se refere a algo próprio do indivíduo, mas sim a algo que lhe é atribuído pela comunidade.

Um exemplo amplamente conhecido refere-se ao *site* de compras *e-bay*, onde o usuário tem sua reputação (representada em uma escala de valores) definida pela opinião dos demais membros do sistema que tiveram a oportunidade de negociar com um determinado indivíduo. Golbeck (2005), apresenta um trabalho focado em comunidades virtuais baseadas em confiança, sendo esta confiança explicitada pelos membros da comunidade.

No *e-bay* depois de uma transação ser concluída, o comprador e o vendedor têm a oportunidade de avaliar-se mutuamente (1, 0 ou -1) e deixar comentários (*"Boa transação. Pessoa agradável para fazer negócios! Recomendo."*). Cada participante tem sua execução total de pontos de *feedback* ligado visivelmente a seu nome de tela, possivelmente um pseudônimo. *Yahoo! Leilão*, *Amazon* e outros sites de leilões possuem sistemas de reputação, como *ebay*, com variações, como uma escala de classificação de 1-5, ou usar várias medidas (uso, pronta resposta, qualidade do produto, etc.), ou uma média de mais do que num total de realimentação pontuações resposta, qualidade do produto, etc.), ou uma média de mais do que num total de realimentação pontuações.

Além disso, a popularização do *PageRank* fez com que diversos trabalhos no âmbito acadêmico utilizassem este algoritmo para a análise da reputação de pesquisadores (Page et al., 1999). O algoritmo *PageRank* tem o objetivo de estimar a importância de uma página na Web baseado na reputação das páginas que fazem referência a ela. Dessa forma páginas na Web que são referenciadas por várias páginas de alta reputação tornam-se mais importantes. Trabalhos como os de Singh et al. (2011) e Tang et al. (2008), aplicam versões adaptadas do *PageRank* a conjuntos de dados

provenientes de bibliotecas digitais a fim de ordenar autores, artigos e conferências.

A ferramenta ArnetMiner (TANG et al., 2008), utiliza um método baseado na avaliação do candidato pelo usuário, na propagação da reputação e nos relacionamentos existentes entre os pesquisadores da rede para encontrar especialistas em um determinado assunto, onde para calcular a reputação são utilizadas informações obtidas do perfil do pesquisador. No ArnetMiner, se uma pessoa tem co-autoria em vários documentos ou se o nome dessa pessoa ocorre várias vezes em um determinado tópico de pesquisa, essa pessoa tem potencial para ser especialista neste tópico. Ou ainda, se uma pessoa conhece várias pessoas em um tópico de pesquisa ou se o nome dessa pessoa co-ocorre várias vezes em publicações de especialistas nesta área, então esta pessoa pode ser uma especialista.

O método definido por Singh et al. (2011) é utilizado para classificar as publicações de várias áreas de pesquisa em diversas conferências. Esta classificação é utilizada também para ordenar as conferências e autores. Singh et al. (2011) consideram que a importância da publicação é diretamente proporcional ao número de trabalhos que a referenciam, além da qualidade da conferência depender da qualidade de suas publicações e não apenas da quantidade. Neste método, a reputação do autor depende não somente da qualidade de suas publicações, mas também das conferências em que são publicadas.

No próximo capítulo é apresentada a revisão de literatura realizada, onde foram escolhidos os trabalhos mais próximos à proposta da Arquitetura e-RecRep, dentre os diversos trabalhos identificados como relacionados.

3 TRABALHOS RELACIONADOS

Neste capítulo serão discutidos os trabalhos relacionados que trataram problemas similares a essa pesquisa. Por se tratar de dois assuntos diferentes, serão, inicialmente, apresentados os que focam nos sistemas de recomendação e após, os que utilizam modelos de reputação. Ao final alguns trabalhos que abrangem as duas áreas em comum.

3.1 Sistemas de Recomendação

Dentre os trabalhos pesquisados que utilizam técnicas de Sistemas de Recomendação no contexto educacional destacamos os seguintes trabalhos: Aloise (2016) propôs um modelo de Sistema de Recomendação Educacional (SRE) para professores e coordenadores de curso que utiliza a predição de reprovação de aprendizes em disciplinas na modalidade de Educação a distância; Imran et al. (2016), apresentam o P-LORS, que tem como objetivo permitir que os LMSs forneçam recomendações aos leitores, considerando o objetivo de aprendizagem, bem como os objetos de aprendizagem visitados por outros alunos com perfis semelhantes, fornecendo-lhes recomendações sobre quais objetos de aprendizagem dentro do curso são mais úteis para eles; Müller e Silveira (2013), apresentaram uma pesquisa com o objetivo de integrar as técnicas usadas por sistemas de recomendação aos sistemas de ajuda em pares; Muniz et al. (2013) desenvolveram um sistema multiagente com objetivo de recomendar Objetos de Aprendizagem para TVs digitais de acordo com o contexto dos usuários; Cazella et al. (2012) propôs o RECoaComp, que é um sistema para recomendação de objetos de aprendizagem (OA) baseado em competências para a Educação; Santos (2012) propôs o desenvolvimento de um sistema de software, denominado Delta, para a recomendação de pessoas (monitores) no AVA MOODLE.

ALOISE (ALOISE, 2016)

O objetivo deste trabalho é propor o modelo M-SRECP, um modelo de Sistema de Recomendação Educacional que tem como público-alvo

professores e coordenadores de curso, os quais recebem dados estatísticos de possibilidade de reprovação de aprendizes em uma disciplina a partir de um sistema de predição e faz recomendações a este público-alvo, a fim de que os mesmos efetuem ações pedagógicas visando reduzir o número de aprendizes reprovados.

Técnicas como classificação de perfis de usuários, para delinear a entrega de recomendação, sensibilidade a contextos e Customer Relationship Management (CRM) foram utilizadas neste trabalho, com o intuito de viabilizar um diferencial quanto à recomendação ao público-alvo (professor e coordenador de curso), colocando-o como principal foco do processo (CRM), ao longo de uma disciplina (sensibilidade a contextos).

A atuação do público-alvo visa atenuar o quantitativo de aprendizes reprovados em disciplinas na modalidade EaD, oferecendo a estes uma oportunidade de melhorar o seu coeficiente de rendimento, reduzir o tempo matriculado no curso e, conseqüentemente, acelerar sua certificação.

Um protótipo do modelo foi elaborado para a realização do experimento no Instituto Federal de Educação, Ciência e Tecnologia do Amazonas, no programa Universidade Aberta do Brasil, curso de Filosofia da educação, disciplina de Linguagem Brasileira de Sinais, em 2015/2. Coletou-se através de um questionário, os perfis de 30 professores, o que permitiu a classificação do perfil de professor utilizando árvore de decisão com a ferramenta RapidMiner. O perfil do professor da disciplina de Libras também foi coletado, no entanto o mesmo foi submetido à classificação para definir se, além dele, haveria a necessidade da coordenação do curso de Filosofia da Educação receber também a recomendação semanal dos aprendizes com risco de reprovação na disciplina.

O protótipo também foi apresentado a um conjunto de 12 professores para que os mesmos realizassem uma avaliação de facilidade de uso percebida e de percepção de utilidade através do *Technology Acceptance Model* (TAM). Chegou-se à conclusão que o M-SRECP é uma ferramenta computacional que pode auxiliar o professor e o coordenador do curso a resgatar os aprendizes antes que a reprovação ocorra, auxiliando na melhora do desempenho do aprendiz na disciplina ainda em andamento.

IMRAN (*IMRAN, 2016*)

Este trabalho tem por objetivo apresentar o PLORS, que integra uma abordagem de sistema de recomendação em sistemas de gerenciamento de aprendizagem. Os PLORS fornecem recomendações sobre quais objetos de aprendizagem dentro de um curso são mais úteis para os alunos, considerando o objeto de aprendizagem que ele / ela está visitando, bem como os objetos de aprendizagem visitados por outros alunos com perfis semelhantes. O mecanismo de recomendação usa a mineração de regras de associação para encontrar a associação entre OAs e um algoritmo de vizinhança.

As principais contribuições do trabalho são: primeiro, para encontrar aprendentes semelhantes, o sistema não considera as classificações dadas pelos alunos como feitas na maioria dos sistemas recomendadores tradicionais. Em vez disso, ele usa diferentes características / atributos de alunos como estilos de aprendizado, conhecimentos prévios, nível de experiência e desempenho para identificar alunos altamente semelhantes. Em segundo lugar, a utilidade de um objeto de aprendizado não se baseia na classificação dos alunos conforme feito na maioria dos sistemas recomendadores. Em vez disso, o PLORS examina o histórico de navegação de outros alunos e encontra o conjunto de OAs que foram frequentemente visitados por outros alunos similares no curso. Em terceiro lugar, enquanto na maioria dos trabalhos anteriores, aprendentes semelhantes são encontrados usando uma abordagem de *cluster*, neste trabalho, os algoritmos de cluster geralmente visam atribuir cada aluno a um grupo / cluster.

Isso leva a várias desvantagens relevantes, como o risco de criar *clusters* que incluem pontos de dados (ou aprendentes) que na verdade não são muito próximos, o risco de obter clusters diferentes ao executar o mesmo algoritmo de agrupamento novamente, o que significa que o algoritmo de agrupamento nem sempre agrupe os pontos de dados mais próximos (ou aprendentes), ou a necessidade de um número predefinido de clusters. Uma vez que nosso objetivo é encontrar aprendizes próximos de um aluno particular, uma abordagem de vizinhança é mais precisa e livre das desvantagens acima mencionadas. Ao usar essa abordagem de vizinhança,

esperamos colocar apenas um aluno junto com alunos que aprendam de forma muito semelhante e use a experiência de alunos semelhantes para fornecer recomendações precisas.

Em quarto lugar, enquanto a maioria dos outros trabalhos se concentra no uso do sistema de recomendação em sistemas de *e-learning* particulares, o objetivo deste trabalho é integrar um sistema de recomendação em qualquer LMS. Os LMSs são comumente usados por instituições educacionais e ao aprimorar os LMSs com funcionalidades personalizadas para fornecer recomendações individuais, os professores podem continuar usando os sistemas que eles já estão usando para aprender on-line e os alunos estão recebendo adicionalmente algum suporte personalizado. As recomendações fornecidas podem ajudar os alunos a navegarem melhor o curso e, portanto, podem melhorar seu desempenho e satisfação de aprendizagem.

MULLER; SILVEIRA (*MULLER; SILVEIRA, 2013*)

Müller e Silveira (2013) apresentaram uma pesquisa com o objetivo de integrar as técnicas usadas por sistemas de recomendação aos sistemas de ajuda em pares, visando apoiar a formação destes pares usando recomendação de pessoas (combinação social), e tentando, dessa forma, auxiliar os usuários para que estes consigam sanar suas dúvidas. O processo proposto para formação de pares foi implementado em um protótipo de sistema de ajuda focado em ambientes colaborativos de ensino, permitindo analisar a formação dos pares e assim obter informações sobre a efetividade de seu uso.

CAZELLA (*CAZELLA, 2012*)

Neste trabalho é descrito um relato de experiência de desenvolvimento e validação de um Sistema para Recomendação de Objetos de Aprendizagem baseado em competências, denominado de RECoaComp (CAZELLA et al., 2012). O trabalho levou em consideração o avanço tecnológico, que trouxe novas concepções de ensino e aprendizagem, assim como diferentes possibilidades de desenvolver conteúdos por meio de OAs. Identificou que,

assim como outros trabalhos, os repositórios que são construídos para os OAs acabam apresentar muitos conteúdos sem relevância.

O trabalho tem o objetivo de filtrar os objetos de aprendizagem de acordo com as competências a serem construídas e que foram sinalizadas nos perfis dos usuários. Usou o entendimento de que a competência é composta de Conhecimentos, Habilidades e Atitudes, conhecido como CHA, que podem ser construídos com o apoio de tecnologias digitais. Para verificação e avaliação do protótipo do sistema de recomendação desenvolvido a partir do modelo RECoaComp, o mesmo foi aplicado a uma turma composta por alunos de dois Programas de Pós-Graduação durante o 2º semestre de 2011. O grupo formado por 25 alunos foi convidado a participar do primeiro experimento que teve como objetivo validar e avaliar o sistema, enquanto no segundo experimento 32 alunos foram convidados.

SANTOS (SANTOS, 2012)

Em seu trabalho, Santos (2012) propôs o desenvolvimento de um sistema de software, denominado *Delta*, desenvolvido através da linguagem PHP (*Personal Home Page*), para a recomendação de pessoas (monitores) no AVA MOODLE. A recomendação de monitores levava em consideração o contexto do usuário que realiza a busca, i.e., o aluno que estava em dificuldades em um determinado momento.

O sistema Delta tem como embasamento o software ICARE, que consiste num sistema de recomendação de especialistas estudado e desenvolvido por Petry (2007), utilizando o contexto do especialista, isto é, do monitor que está sendo recomendado e do usuário que está realizando a pesquisa. Santos justificou, através do estudo de Brézillon (1999), que o contexto do usuário é um conjunto de condições e influências únicas na escolha ou tomada de decisão.

O contexto pode ser compreendido como o conhecimento que assegura ao usuário quando e como definir a importância no momento da escolha. As informações extraídas das pessoas que estão inseridas no Delta são transformadas em um ranking para que o sistema ordene os monitores de acordo com a prioridade do contexto escolhido.

O funcionamento do sistema Delta ocorre da seguinte maneira: quando um usuário necessita de ajuda para um determinado assunto, ele informa no campo de pesquisa o que deseja pesquisar e define as prioridades dos contextos antes de efetivar a pesquisa. Então, o sistema exibirá as recomendações de monitores de acordo com os contextos escolhidos pelo usuário no momento da pesquisa.

3.2 Modelos de reputação

E em relação aos trabalhos que incorporam modelos de reputação podemos destacar os seguintes: Yan, Chen e Shen (2014) propõem o sistema de reputação de conteúdo difundido (PerContRep), que é um modelo de confiança híbrida e de gerenciamento de reputação; De Meo et al. (2017) propõe um modelo destinado a gerenciar a formação e a evolução das aulas de *e-learning*, utilizando as habilidades e as informações de confiança já disponíveis em Redes Sociais *Online*; Mamani (2013) tem por objetivo elaborar um modelo para o cálculo de reputação em comunidades *on-line*; o Rep-Index, modelo proposto por Cervi et al. (2011), considera toda a trajetória acadêmica do pesquisador para aferir a sua reputação, utilizando um modelo de perfil adaptativo formado por elementos obtidos de seu currículo Lattes.

DE MEO (DE MEO et al., 2017)

Neste trabalho a formação de turmas do *e-learning* será beneficiada se as necessidades dos alunos comuns forem levadas em conta. Por exemplo, a disponibilidade de relações de confiança entre os usuários pode representar uma motivação adicional para os colegas envolverem atividades. A experiência comum também sugere que existem muitas semelhanças dentro da dinâmica de formação para grupos de redes sociais temáticas e salas de aula de *e-learning*. Como as Redes Sociais *on-line* fornecem dados relativos às interações dos usuários (por exemplo, relações de confiança), os autores propõe um modelo voltado para o gerenciamento da formação e a evolução das aulas de *e-learning* com base nas informações disponíveis nas redes sociais *on-line* - habilidades, interações e relações de confiança - que estão

devidamente combinados em uma medida única. O objetivo é sugerir tanto a um usuário as melhores turmas para se unir como às próprias turmas os melhores alunos para aceitar. A abordagem proposta foi testada simulando um cenário de *e-learning* dentro de uma grande rede social. Experimentos mostram que esta proposta é capaz de apoiar estudantes e gerentes de classe a fim de satisfazer suas expectativas de forma escalável.

YAN; CHEN; SHEN (*I; CHEN; SHEN, 2014*)

Yan, Chen e Shen (2014) propõem o sistema de reputação de conteúdo difundido (PerContRep), que é um modelo de confiança híbrida e de gerenciamento de reputação. Os autores apresentam pesos para os votos, coletados de nós, que dependem dos valores de confiança calculados para cada nó e um fator de comunidade. Os valores de confiança são atualizados com base na experiência local do nó avaliado. Em geral, a pontuação de confiança é diminuída se o desvio entre o voto de avaliador e reputação de conteúdo é maior do que a metade do desvio de voto máximo, e aumentou de outra forma.

Para avaliação do protótipo foi realizada uma entrevista em dez pós-graduados da universidade (50% mulheres) com idades entre 21 e 27 e foi projetada com base no *Technology Acceptance Model* (TAM). Os resultados mostraram que PerContRep é um aplicativo muito útil e interessante, com boa usabilidade que pode ajudar na decisão do usuário em serviços de conteúdo abrangentes. Sua interface do usuário (por exemplo, consulta e resposta de recomendação de conteúdo) obtiveram um bom *feedback* dos participantes sendo bem aceito pelos pelos participantes.

MAMANI (*MAMANI, 2013*)

O trabalho proposto por Mamani (2013), tem por objetivo elaborar um modelo para o cálculo de reputação em comunidades *on-line*, baseando-se em dados qualitativos e quantitativos provenientes da interação dos próprios participantes da rede, a fim de potencializar a colaboração entre os membros e fornecer um meio de cálculo resistente a algumas das vulnerabilidades comuns em sistemas de reputação, como tolerância a ruídos e ataques *Sybil*. Para

atingir esse objetivo é realizada uma adaptação do algoritmo *PageRank*, definida como CR (Collaborative Reputation) para obter uma ordenação dos usuários a partir de suas interações.

Para avaliação, foi adotado um conjunto de dados do sítio *Epinions.com*, com o qual foi realizada uma análise comparativa dos resultados obtidos a partir do modelo proposto com outros três algoritmos correlatos ao trabalho apresentado. Dentre as técnicas usadas na análise estão: diversidade de valores, comparação da ordenação, estudo comparativo de cenários, tolerância a ruídos e robustez contra ataques tipo Sybil. Os algoritmos usados na avaliação são: o *PageRank* original e o algoritmo *ReCop*, usados para a identificação de usuários relevantes, e o algoritmo *LeaderRank* usado para a identificação dos usuários com maior prestígio na rede. Os resultados indicam que o modelo proposto é mais sensível às interações dos usuários em comparação aos outros modelos usados na avaliação, mas é mais eficiente a ataques Sybil.

CERVI (CERVI, 2011)

O modelo proposto por Cervi et al. (2011), considera toda a trajetória acadêmica do pesquisador para aferir a sua reputação, utilizando um modelo de perfil adaptativo formado por elementos obtidos de seu currículo Lattes.

A Tabela 3.1 apresenta as categorias definidas, seus elementos e as siglas de cada um deles entre parênteses.

Tabela 3.1 - Categorias e elementos definidos no modelo de Cervi et al. (2011).

Categoria	Elemento
1. Identification (ID)	Education Degree (ED)
2. Advisory (ADV)	Postdoctoral Advisor (PA) Phd Thesis Advisor (PTA) Master Dissertation Advisor (MDA)
3. Examining Board (EB)	Participation in Examination Boards Phd Thesis (PEBPT) Participation in Examination Boards Master Dissertation (PEBMD)
4. Membership (MS)	Conference Committee Coordinator (CCC) Conference Committee Member (CCM) Editorial Board Member (EBM) Reviewer of Journals (RJ)
5. Production (PROD)	Articles in Scientific Journals (ASJ) Books Published (BP) Book Chapter Published (BCP) Complete Work Published in Conference Proceedings (CWPCP) H-Index (HI) Network Co-authorship (NC) Research Projects (RP) Software With Register (SWR) Software Without Register (SWOR)

Fonte: Cervi (2011)

Para auxiliar na identificação de tais elementos e representar o perfil do pesquisador, o modelo proposto por Cervi et al. (2011) faz uso de uma ontologia, que por sua vez é dividida em cinco categorias:

1. *Identification* - representa a titulação (*Education Degree*) do pesquisador, cujas opções são mestrado, doutorado ou pós-doutorado;

2. *Advisory* - representa as orientações do pesquisador, onde o elemento *Master Dissertation Advisor* representa as orientações de mestrado e o elemento *Phd Thesis Advisor* representa as orientações de doutorado. E as orientações de pós-doutorado são representadas pelo elemento *Postdoctoral Advisor*;

3. *Examining Board* - indica a participação em bancas examinadoras pelo pesquisador, onde os elementos *Participation in Examination Boards Master Dissertation* e *Participation in Examination Boards Phd Thesis* representam a participação em bancas de mestrado e de doutorado, respectivamente;

4. *Membership* - representa as conferências onde o pesquisador foi coordenador (*Conference Committee Coordinator*) ou membro de comitê de

programa (*Conference Committee Member*), bem como se foi ou ainda é revisor de periódico (*Reviewer of Journals*) ou membro de corpo editorial (*Editorial Board Member*);

5. *Production* - representa a produção científica e outros elementos relacionados a produção do pesquisador. O elemento *Articles in Scientific Journals* representa os artigos publicados em periódicos. Capítulos e livros publicados são representados pelos elementos *Book Chapter Published* e *Books Published*, respectivamente. Artigos publicados em conferências são representados pelo elemento *Complete Work Published in Conference Proceedings*. Os elementos *H-Index* e *Network Co-authorship* dizem respeito às citações dos artigos do pesquisador por outros pesquisadores e ao número de pesquisadores que possuem trabalhos publicados em conjunto com o pesquisador avaliado. O elemento *Research Projects* representa o número de projetos de pesquisa que o pesquisador é membro. E os elementos *Software With Register* e *Software Without Register* representam os softwares com e sem registro em que o pesquisador teve participação.

A partir das categorias e elementos da Tabela 3.1, Cervi et al. (2011) propõe uma métrica para calcular a reputação do pesquisador. A métrica é definida por meio de um somatório entre os vários elementos que compõem o modelo, sendo que para isso são atribuídos pesos às categorias e elementos, cujo somatório dos pesos equivale a 100. Além dos pesos, a métrica faz uso do valor máximo obtido de cada elemento da Tabela 3.2 para cada pesquisador.

Ao final do cálculo da reputação, o pesquisador é classificado em uma tabela de níveis de reputação que varia de 1 a 5 conforme apresenta a Tabela 3.2, os quais são utilizados na métrica proposta por Cervi et al. (2011).

Tabela 3.2: Classificação da reputação definida no modelo de Cervi et al. (2011).

Nível	Reputação
1	≥ 0 e < 20
2	≥ 20 e < 40
3	≥ 40 e < 60
4	≥ 60 e < 80
5	≥ 80 e < 100

Fonte: Cervi (2011)

CAZELLA (CAZELLA, 2006)

O Mo-Drop (CAZELLA, 2006), constitui-se em uma proposta para modelar e incluir a relevância da opinião do usuário no processo de recomendação colaborativa, ou seja, apresenta uma abordagem de Sistemas de Recomendação para recomendar itens baseando-se em informação adicional definida como relevância da opinião do usuário além das típicas informações utilizadas na grande maioria dos Sistemas de Recomendação. Esta inclusão da relevância da opinião constitui-se em uma alternativa para que o usuário alvo da recomendação consiga identificar qual a importância de um determinado item recomendado frente à relevância de opinião dos recomendadores. A idéia apresentada é a de que pessoas com maior relevância de opinião poderiam melhor avaliar e recomendar itens.

3.3 Sistemas de recomendação e modelos de reputação

Realizada uma pesquisa sobre os trabalhos que utilizam sistemas de recomendação e modelos de reputação integrados, foram encontrados trabalhos como os dos seguintes autores:

Kerkiri et al. (2007), desenvolveram um sistema que explora metadados de reputação e descrição para aumentar a personalização em sistemas de *e-learning* através de métodos de recomendação. A reputação é usada como uma escala acumulativa sobre a opinião dos usuários sobre pessoas, produtos, ideias e é usada principalmente em sistemas de comércio eletrônico como um método para construir a confiança e em colaboração redes (como as redes sociais *online* e blogs) para fornecer colaboração.

Além deste, o trabalho de O'Donovan e Smyth (2005) considera o papel da reputação em sistemas recomendadores. Neste caso, um algoritmo de filtragem colaborativo padrão é modificado para adicionar uma pontuação de confiança para complementar o perfil normal ou baseado em itens com pontuação de similaridade, de modo que os parceiros de recomendação sejam escolhidos entre esses usuários que não são apenas semelhantes ao usuário alvo, mas que também tiveram sucesso no histórico de recomendações com esse usuário. É postulado que essa informação de confiança pode ser estimado medindo a precisão de um perfil ao fazer previsões ao longo do tempo, e usando essa abordagem, o erro médio de previsão é significativamente melhorado comparação com abordagens colaborativas de filtragem convencionais.

3.4 Síntese dos trabalhos relacionados

A Tabela 3.3 apresenta um comparativo entre os trabalhos relacionados que utilizam alguma técnica de Sistemas de Recomendação e a Tabela 3.4 apresenta os trabalhos que possuem Modelos de Reputação. Na sequência, a Tabela 3.4 apresenta um comparativo entre os trabalhos relacionados, com o intuito de identificar os principais diferenciais da arquitetura e-RecRep, caracterizando sua contribuição científica.

Tabela 3.3 - Tabela comparativa entre alguns sistemas de recomendação aplicados em ambientes de *e-learning*

Título	Escopo	Técnica de SR utilizada
ALOISE (2016)	Sistema de recomendação educacional.	Classificação de perfis de usuários, sensibilidade a contextos e Customer Relationship Management (CRM).
IMRAN (2016)	Sistemas de gerenciamento de aprendizagem.	Mineração de regras de associação.
MULLER; SILVEIRA (2013)	Sistema de recomendação de pessoas em ambientes colaborativos.	Filtragem colaborativa.
CAZELLA (2012)	Sistema para recomendação de objetos de aprendizagem (RECoaComp).	Filtragem colaborativa.
SANTOS (2012)	Sistema de recomendação de pessoas (monitores) no AVA MOODLE.	Filtragem colaborativa.

Fonte: Autoria própria

Tabela 3.4: Tabela comparativa dos trabalhos relacionados à reputação

Trabalho relacionado	Entrada (coleta de informações)	Processamento (métrica utilizada)	Armazenamento	Saída (como é mostrada a informação)	Retorno (avaliação)
DE MEO et al., (2017)	informações disponíveis nas redes sociais <i>on-line</i>	As informações (habilidades, interações e relações de confiança) estão devidamente combinados em uma medida única	banco de dados	sugere tanto a um usuário as melhores turmas para se unir como às próprias turmas os melhores alunos para aceitar.	sistema prático de reputação para serviços de conteúdo denominado de PerContRep
YAN; CHEN; SHEN (2014)	pesos para os votos, coletados de nós	os pesos dependem dos valores de confiança calculados e um fator de comunidade para gerar a recomendação	banco de dados	Os valores de confiança são atualizados com base na experiência local do nó avaliado.	retorna uma reputação de conteúdo.
MAMANI (2013)	dados fornecidos de forma explícita através da interação dos usuários	média das reputações obtidas nas suas avaliações mais recentes	banco de dados	mostra de usuários mais relevantes e os com mais prestígio na rede.	conjunto de dados do site Epinions.com
CERVI (2011)	perfil adaptativo formado por elementos obtidos de seu currículo Lattes.	escala numérica: somatório atribuindo pesos às categorias e elementos, sendo o máximo 100	ontologias	coeficiente de correlação (fraca, muito fraca, moderada, forte e muito forte), a partir disso classifica o pesquisador em 5 níveis diferentes.	métrica para medir reputação acadêmica denominada Rep-Index
CAZELLA (2006)	perfil adaptativo formado por elementos obtidos de seu currículo Lattes.	escala numérica: métrica denominada Ranqueamento do Recomendador (RR)	banco de dados	mostra os usuários que possuem maior relevância de opinião.	os usuários fazem avaliações sobre artigos que lhes foram recomendados previamente.

Fonte: Autoria própria

Tabela 3.5: Tabela comparativa

CRITÉRIOS	<i>ALOISE</i> (2016)	<i>IMRAN</i> (2016)	<i>DE MEO et al.</i> (2017)	<i>YAN; CHEN; SHEN</i> (2014)	<i>CERVI</i> (2011)	<i>CAZELLA</i> (2006)	<i>KERKIRI</i> et al. (2007),	<i>O'DONO- VAN; SMYTH(2005)</i>	e-RecRep
A	sim	sim	sim	sim	sim	sim	não	não	sim
B	sim	sim	não	não	não	sim	sim	sim	sim
C	não	não	sim	sim	sim	sim	sim	sim	sim
D	não	não	não	não	não	não	sim	sim	sim

Fonte: Autoria própria

- A) Uso na área educacional
- B) Utiliza alguma técnica de sistemas de recomendação
- C) Utiliza um modelo para o cálculo de reputação
- D) Utiliza integração de sistemas de recomendação e reputação

3.5 Considerações do capítulo

Neste capítulo foram apresentados estudos relacionados às áreas consideradas pelos autores deste trabalho, como diretamente relacionadas a Sistemas de Recomendação e Modelos de reputação.

Ressalta-se que grande parte das pesquisas em Sistemas de Recomendação tangem áreas de comércio eletrônico e entretenimento, sendo reduzido o número de pesquisas para a área educacional. Assim como, percebeu-se que a utilização de modelos de reputação é muito utilizada em redes sociais e também sites de comércio eletrônico, no entanto, ambas ainda pouco exploradas na área de *e-learning*.

Diante disso, a revisão de literatura apresentada neste capítulo apontou uma necessidade de integração entre os Sistemas de Recomendação e os Modelos de Reputação na área educacional, o qual ainda encontra-se deficiente, especialmente em ambientes de *e-learning* como o MOODLE que é amplamente utilizada na comunidade acadêmica, conforme já mencionado neste trabalho.

A comparação da Arquitetura e-RecRep proposta com os projetos relacionados caracterizou sua contribuição científica, demonstrando seu principal diferencial em relação a estes projetos, o qual corresponde à integração entre essas áreas, proporcionando um ambiente mais personalizado e confiável.

O próximo capítulo apresenta uma visão geral da arquitetura proposta, cenários de uso e implementação do modelo.

4 ARQUITETURA PROPOSTA


Este capítulo descreve a arquitetura proposta neste trabalho, que visa recomendar OAs em um ambiente de *e-learning*, usando o mecanismo de reputação para personalizar e melhorar a precisão das recomendações de materiais didáticos úteis aos alunos em seus ensinamentos e aprendizado.

A arquitetura proposta chamada de e-RecRep foi baseada na revisão da literatura, vide seção 3.

4.1 Visão Geral da Arquitetura

Esta seção descreve o e-RecRep, a arquitetura proposta que visa propor a integração de reputação às técnicas de SR para recomendar OAs em um ambiente de *e-learning* (conforme a Figura 4.1).

Figura 4.1 - Arquitetura do e-RecRep



Fonte: Autoria própria.

Os principais componentes da arquitetura são o ambiente de *e-learning*, o componente de recomendações e o mecanismo de reputação. Nesta seção, explicamos em detalhes o funcionamento destes componentes.

A) Ambiente de *E-learning*: é formado pelo modelo de estudante e pelo modelo de domínio:

- O modelo do aluno utilizado neste trabalho foi proposto em Eyharabide (2009) e fornece informações pessoais do aluno, suas preferências, o seu perfil de aprendizagem que está diretamente relacionado às preferências do usuário e às características tecnológicas relacionadas ao acesso dos alunos. Deve-se notar que as recomendações, que são responsáveis por sugerir OAs aos alunos, usam o mesmo modelo de estudante, uma vez que os próprios alunos podem recomendar material.
- O modelo de domínio está estruturado em quatro itens no ambiente: conceitos, exercícios, exemplos e materiais complementares. Entre estas quatro categorias, estamos interessados em materiais complementares, onde os objetos de aprendizagem são organizados em seus diferentes tipos (vídeos, imagens, sons, texto, etc.).

B) Módulo de recomendação: o módulo de recomendação tem a função de recomendar os OAs mais apropriadas para o perfil do aluno, usando técnicas de recomendação. Neste trabalho foi adotada a recomendação híbrida, pois busca encontrar usuários mais parecidos com o usuário ativo com base em suas últimas avaliações. Para gerar as recomendações, utilizamos o coeficiente de *Pearson* (Equação 4) para avaliar a similaridade de um usuário em relação aos demais.

$$C_p(A, B) = \frac{\sum_{i=0}^n (A_i \times B_i) - \frac{\sum_{i=0}^n (A_i) \times \sum_{i=0}^n (B_i)}{n}}{\sqrt{\left(\sum_{i=0}^n (A_i^2) - \frac{(\sum_{i=0}^n A_i)^2}{n} \right) \times \left(\sum_{i=0}^n (B_i^2) - \frac{(\sum_{i=0}^n B_i)^2}{n} \right)}} \quad (4)$$

onde $C_p(A, B)$ se refere ao Coeficiente de *Pearson* entre Usuário A e Usuário B , A_i representa uma nota específica de um usuário A , B_i uma nota

específica de um usuário B e o total de notas que ambos os usuários têm em comum. O resultado da equação é um valor variando de -1 a +1 onde -1 indica ausência de correlação e +1 forte correlação.

Vale ressaltar que outras técnicas poderiam ter sido utilizadas para gerar as recomendações, foi utilizada a filtragem híbrida por ser amplamente utilizada na literatura.

C) Mecanismo de Reputação: O mecanismo de reputação visa avaliar a reputação dos usuários que recomendarão o material, a fim de melhorar a confiança das informações recomendadas. Neste mecanismo, todas as informações recomendadas serão avaliadas por quem recebe a recomendação e, portanto, esta avaliação é usada para calcular a reputação de cada membro. Assim, se uma recomendação tem uma boa reputação, entende-se que pode-se confiar em suas sugestões, caso contrário, podemos suspeitar.

D) No mecanismo de reputação existem três repositórios:

1) Repositório Estudante: contendo informações sobre o aluno como informações pessoais, preferências e perfil de aprendizagem do aluno.

2) Repositório OA: contendo informações sobre os materiais de aprendizagem, como formatos que podem ser texto, imagem, áudio ou vídeo.

3) Regras de Repositório: contendo os parâmetros que são usados para calcular a reputação de um recomendador.

A reputação do usuário (R) é calculada através de uma métrica (equação 5), esta equação é usada para calcular a soma dos atributos (sa) (a_1, a_2, \dots, p_{an}) selecionada para calcular a reputação. Esta equação traduz todas as informações em um único valor quantitativo dentro de um intervalo específico e é utilizada para calcular a reputação inicial de um usuário que recomenda OAs, sendo que à medida que o recomendador interage com o sistema, essa reputação é atualizada.

$$R = \sum sa \quad (5)$$

Assim, como (CERVI, 2013) e (CAZELLA, 2006), que consideram os elementos da carreira acadêmica do pesquisador, como: o nível de formação, a área de formação e a área de interesse, neste trabalho foram utilizados estes e

acrescentados outros atributos como: Avaliação recebida do recomendador/AR, devido ao fato de abranger também pesquisadores iniciantes; e a Quantidade de recomendações dadas pelo recomendador/QR, para que o ambiente esteja sempre em constante atualização pois é avaliado dentro do período de 1 ano. Esses dados foram divididos em categorias, conforme pode ser visualizado na Tabela 4.1.

Tabela 4.1 - Atributos dos usuários e seus valores

Atributos	Valores
Nível de Formação/FO	Para cada valor de FO foi atribuído um peso específico em uma escala de [1-10]: Pós-doutorado (PD) = 10 Doutorado (DOU) = 7 Mestrado (MES) = 5 Especialista (ESP) = 3 Graduação (GRA) = 2 Não graduado (NGRA) = 1
Áreas de formação/AF	Para cada área de formação foi atribuído um peso específico em uma escala de [1-3]: Mesma área do curso proposto (AS): 3 Áreas afins (AF): 2 Área diferente (AD): 1
Áreas de interesse/AI	Para cada área de interesse foi atribuído um peso específico em uma escala de [1-3]: Mesma área do curso proposto (AS): 3 Áreas afins (AF): 2 Área diferente (AD): 1
Avaliação recebida do recomendador/AR	A cada material recomendado o avaliador recebe uma pontuação específica em uma escala de [0 - 5]: Muito Relevante (MR) = 5 Relevância média (RM) = 4 Relevante (RR) = 3 Pouco relevante (PR) = 1 Não relevante (NR) = 0
Quantidade de recomendações dadas pelo recomendador/QR	No período de 1 ano, são avaliadas a quantidade de recomendações que são dadas pelo recomendador, em uma escala de [1– 5]: 1 à 19 = 1 20 à 39 = 2 40 à 69 = 3 70 à 99 = 4 Maior ou igual a 100 = 5

Fonte: Autoria própria.

Ao final do cálculo da reputação, o recomendador é classificado em uma tabela de níveis de reputação, que foi baseada em níveis numéricos, Lima (2010), variando de 1 a 5 conforme apresenta a Tabela 4.2.

Tabela 4.2 - Classificação da reputação em baseada em níveis numéricos

Nível	Reputação	Classificação
1	≥ 0 e < 20	Muito baixa
2	≥ 20 e < 40	Baixa
3	≥ 40 e < 60	Média
4	≥ 50 e < 99	Alta
5	≥ 100	Muito Alta

Fonte: Autoria própria.

É importante ressaltar que esses dados serão atualizados à medida que o usuário (autor) interage e recomenda material aos demais usuários no sistema, tornando o processo cada vez mais consolidado.

4.2 Observações

Deve-se atentar, no entanto, para as limitações que os sistemas de recomendação possuem, principalmente na filtragem colaborativa, como por exemplo, o problema do novo usuário, pois quando um usuário é cadastrado no sistema, ainda não existem avaliações realizadas por ele, portanto, seu perfil de avaliações está vazio, não sendo possível encontrar os vizinhos mais próximos do usuário. A este problema é dado o nome de “Problema do Novo Usuário”. Também é referenciado na literatura como “*Cold Start User*”.

A esparsialidade é outra importante limitação de sistemas baseados em FC, pois na medida em que o número de itens na base de dados vai aumentando, serão reduzidas as chances dos usuários possuírem itens em comum, resultando na redução do tamanho médio da vizinhança dos usuários.

Na literatura, são encontradas algumas alternativas de solução, que poderão ser aplicadas neste trabalho, no *MovieLens*, por exemplo, é solicitado ao usuário que avalie uma certa quantidade de filmes durante a etapa de cadastramento no sistema, desta forma, quando iniciar o uso do sistema provavelmente terá vizinhos e estará apto a receber recomendações. Neste trabalho será feito de forma similar ao *MovieLens*, ou seja, só serão recomendados OAs depois que tiverem sido avaliados alguns OAs.

Além do módulo de recomendação, nesta proposta, a idéia é que todo material recomendado seja avaliado pelo aluno para posteriormente ser calculada a sua reputação.

A relevância científica de um pesquisador tem sido comumente mensurada através de métricas de produção e impacto. As medidas de produção consideram o número de artigos publicados por um pesquisador durante sua carreira acadêmica, enquanto as métricas de impacto avaliam o quanto a produção do cientista teve importância para sua área de pesquisa (Wainer e Vieira, 2013).

Desta forma, há uma crescente tendência em se avaliar pesquisadores por esses indicadores bibliométricos. O índice mais utilizado para essa finalidade, o *h-index*, foi proposto por Hirsch em 2005, e é definido da seguinte forma: “um pesquisador possui um índice h se h dos seus N_p artigos tem pelo menos h citações cada e os outros (N_p-h) não tem mais do que h citações cada.” Em outras palavras, um cientista tem um índice $h = 10$, se tiver 10 artigos publicados e cada um deles tiver sido citado pelo menos 10 vezes por outros trabalhos.

Essa métrica é a mais utilizada por serviços de contagem de citações, como o *Google Scholar*², para medir a relevância acadêmica de pesquisadores. Através dela tenta-se identificar tanto o volume de publicação como o impacto da produção de um pesquisador na sua área de atuação.

Além do *h-index*, existem outras métricas, a exemplo do *g-index* (Egghe, 2006), *RP-index* e *CP-index* (Altmann et al., 2009), que também avaliam o desempenho de um pesquisador de forma análoga, porém acrescentando novos parâmetros que buscam aperfeiçoar os valores estimados pelo *h-index*.

Vale ressaltar que na arquitetura proposta não foram utilizadas essas métricas para o cálculo da reputação pois a intenção é abranger também pesquisadores júnior, que não têm grande reputação. Uma vez que a trajetória acadêmica desses pesquisadores ainda é incipiente, mesmo tendo um grande conhecimento e interesse na área, achamos que suas recomendações podem trazer grandes benefícios para seus colegas.

4.3 Implementação da arquitetura

Dentre os ambientes virtuais de aprendizagem, o MOODLE (*Modular Object-Oriented Dynamic Learning Environment*), foi escolhido como ambiente para implementação da arquitetura proposta, justifica-se a escolha deste ambiente, por se tratar de um LMS de código aberto, o que facilita a customização desde a interface até criação de novos recursos.


Além disso, o MOODLE é amplamente utilizado na comunidade acadêmica, inclusive no Instituto Federal Sul-rio-grandense – Campus Visconde da Graça (Campus em que atua a autora deste trabalho), local onde é utilizado tanto para os cursos à distância, como para suporte para às aulas presenciais.

Existem diversas formas de desenvolver novos recursos no MOODLE, entre elas na forma de um bloco, atividade ou *plugin*.

- f) Um bloco para o MOODLE é um recurso que pode ser adicionado tanto na página principal do ambiente quanto em uma disciplina específica, podendo ser utilizado um bloco já desenvolvido para o MOODLE, como o bloco “Calendário”, por exemplo, assim como ser criado um novo bloco.
- g) Uma atividade serve para adicionar novas tarefas que servem para complementar o curso, como por exemplo, criar um fórum de discussão.
- h) Os *plugins* são softwares desenvolvidos para uma necessidade específica, no MOODLE um exemplo é o *plugin* para cadastro/autenticação de usuário.

A comunidade MOODLE¹¹ disponibiliza uma área de *download* para uma série de *plugins* que podem ser usados e reusados em cada ambiente. Neste trabalho, foram desenvolvidos *plugins*, para as necessidades especificadas do protótipo criado, sendo que os mesmos também poderão ser reutilizados neste ou em outro ambiente. A Figura 4.2 mostra uma visão geral de todos os *plugins* que estão instalados no ambiente MOODLE utilizado neste trabalho.

¹¹ <https://MOODLE.org/plugins/>

Figura 4.2 - Visão geral dos *plugins* instalados no MOODLE.

Fonte: Autoria própria.

Na tela principal do ambiente utilizado neste trabalho, foi desenvolvido um *plugin* que possui a finalidade de recomendar material complementar aos alunos que possuem dificuldades em realizar uma determinada tarefa. O *plugin* foi desenvolvido em linguagem *PHP* e instalado como ferramenta externa, possibilitando o reuso em caso de necessidade de implantação em outro ambiente, conforme visualizado na Figura 4.3.

Figura 4.3 - *Plugin* instalado como ferramenta externa no MOODLE.

Fonte: Autoria própria.

Após a instalação do *plugin* como ferramenta externa é necessário realizar o cadastro deste *plugin*, onde devem ser informados dados como nome, descrição, tipo de ferramenta externa, assim como o seu endereço URL, conforme a Figura 4.4.

Figura 4.4 - *Plugin* implementado no MOODLE.

The screenshot displays the Moodle configuration interface for an external tool. The page title is "Atualizando um Ferramenta externa em Unidade I - Internet e Redes de Computadores". The configuration is organized into several sections:

- Nome da atividade:** Campo de texto com o valor "Preço de material complementar".
- Descrição da atividade:** Área de texto com o conteúdo "Preço de Material Complementar".
- Características:** Seção com opções de visibilidade:
 - Exibir descrição na página do curso
 - Exibir nome da atividade quando lançado
 - Exibir descrição da atividade quando lançado
- Tipo de ferramenta externa:** Menu suspenso com o valor "Automático baseado na URL acessada".
- Lançamento de URL:** Campo de texto com o valor "localhost/moodle/recprlista_olavac.php". Uma mensagem de alerta indica: "Configuração da ferramenta não encontrada para esta URL".
- URL de lançamento segura:** Campo de texto vazio.
- Lançamento do Container:** Menu suspenso com o valor "Padrão".
- Chave do consumidor:** Campo de texto vazio.
- Segredo compartilhado:** Campo de texto com o valor "Mosbar".
- Parâmetros customizados:** Área de texto para parâmetros adicionais.
- URL do ícone:** Campo de texto com o valor "http://localhost/moodle/recprlista.png".
- URL de ícone seguro:** Campo de texto vazio.

Fonte: Autoria própria.

O *plugin* criado foi utilizado na tela principal do curso, mais especificamente nas unidades correspondentes onde estão localizados o material de aula e as tarefas a serem realizadas pelos alunos, tendo a finalidade de mostrar a lista de material complementar recomendado aos alunos, conforme Figura 4.5.

Além deste *plugin*, foram desenvolvidos outros como: (i) Ver os itens mais recomendados e; (ii) Ver todas as recomendações, conforme visualizado na Figura 4.6.

- i) Mostra um *ranking* dos 5 itens que foram mais recomendados no ambiente recentemente.
- ii) Mostra uma lista com todas as recomendações geradas no ambiente.

Figura 4.5 - Tela principal do ambiente com o *plugin* criado.



Fonte: Autoria própria.

Figura 4.6 - *Plugins* desenvolvidos.



Fonte: Autoria própria.

4.4 Cenários de uso

Nesta seção são descritos dois cenários de aplicação de dois alunos com perfis de aprendizagem diferentes, no entanto ambos estão matriculados no mesmo curso, oferecido na modalidade de EaD.

Cenário 1: A aluna Ana, trabalha como agricultora e está matriculada no Curso Técnico de Agroindústria. Ao acessar a disciplina de Informática Aplicada e tentar realizar a tarefa relacionada à “Internet e Redes de Computadores”, encontra certa dificuldade para realizá-la e considera que os objetos de aprendizagem disponibilizados pelo professor não foram suficientes

para ela conseguir realizar a tarefa, necessitando de material complementar para a sua realização. Então, ao invés de enviar uma mensagem ao fórum solicitando ajuda (o que poderia ocasionar certa demora na resposta) ou utilizar sites de busca, que disponibilizariam muita informação (a aluna não possui experiência para selecionar e procurar a informação desejada, assim como não sabe reconhecer se o conteúdo provém de fonte confiável), Ana utiliza o botão “Preciso de material complementar”, que ao ser clicado, automaticamente, faz uma busca no “Repositório de Recomendações” e sugere os objetos de aprendizagem mais adequado para ela, conforme Figura 4.7.

Figura 4.7 - Tela do ambiente com o botão de preciso de material complementar



Fonte: Autoria própria.

Na sequência, o sistema mostra uma tela com o tipo de OA recomendado (vídeo, artigo, site, ...), assim como o autor que recomendou este OA, conforme é apresentado na Figura 4.8.

Figura 4.8 - Listagem de OAS recomendados

Preciso de material complementar	
Listagem de OAS Recomendados	
Material Recomendado:	Avaliação:
Título: Redes de Computadores Autor: Gabriel Torres Tipo: artigo Recomendado por: Maria Isabel <input type="button" value="Ver reputação"/> <input type="button" value="Download"/>	O que você achou desta recomendação? <input type="radio"/> Relevante: <input type="radio"/> Não relevante Que nota você daria para esta recomendação? <input type="button" value="Confirmar"/>
Título: Segurança de Computadores: Princípios e Práticas Autor: Paulo Serrano Tipo: Livro Recomendado por: Fernando <input type="button" value="Ver reputação"/> <input type="button" value="Download"/>	O que você achou desta recomendação? <input type="radio"/> Relevante: <input type="radio"/> Não relevante Que nota você daria para esta recomendação? <input type="button" value="Confirmar"/>
Título: Internet e seus serviços Autor: Fernando de Castro Velloso Tipo: artigo Recomendado por: João <input type="button" value="Ver reputação"/> <input type="button" value="Download"/>	O que você achou desta recomendação? <input type="radio"/> Relevante: <input type="radio"/> Não relevante Que nota você daria para esta recomendação? <input type="button" value="Confirmar"/>

Fonte: Autoria própria.

Ana analisa o material que foi recomendado e, como não conhece os autores de alguns materiais recomendados, resolve pesquisar sobre a reputação deles, pois fica em dúvida se o material provém de uma fonte realmente confiável ou não, a partir disso avalia o material como “Relevante” ou “Não-relevante”. Caso o material seja “Relevante” aparece uma lista com notas de 1 a 5, esta nota é automaticamente incrementada na nota do autor da recomendação. Caso o material seja marcado como “Não-relevante”, não será atribuída nenhuma nota ao autor, ou seja, será considerada como zero. A nota do autor só será decrementada caso este autor não seja avaliado no período de tempo de 1 ano.

Vale ressaltar que a reputação inicial do recomendador é igual a zero, sendo incrementada a cada nova avaliação feita por um aluno. A Figura 4.9

mostra a tela onde é realizado o cadastro dos autores e armazenada a nota do autor.

Figura 4.9 - Tela de cadastro de autores



Fonte: Autoria própria.

A Figura 4.10 mostra um exemplo de tela com o perfil dos autores que pode ser consultada pelos usuários que recebem a recomendação.

Figura 4.10 - Tela mostrando o perfil de autor



Fonte: Autoria própria.

Cenário 2: A aluna Marina (que é colega de Ana), já possui em seu currículo um curso Técnico em Informática e, atualmente, trabalha na área de suporte de TI, possuindo vasto conhecimento na área de informática. Ao tentar realizar a mesma tarefa que a colega Ana, sobre “Internet e Redes de Computadores”, não necessita de ajuda extra, pois os OAs disponibilizados pelo professor são suficientes para a realização da mesma. Além disso, como

possui bastante conhecimento e material extra sobre esse conteúdo, resolve recomendar material complementar para ajudar seus colegas nesta área.

Para isso, ela possui duas opções: i) pode recomendar diretamente na Unidade I (vide Figura 4.11); ii) pode utilizar a opção disponível ao lado (vide Figura 4.12).

Deve-se salientar que as duas opções tem por objetivo recomendar material ao ambiente, sendo que na primeira a recomendação será vinculada diretamente à Unidade correspondente e na segunda deve-se escolher, no mínimo uma Unidade à ser vinculada, sendo que cada material a ser recomendado pode estar vinculado a uma ou mais Unidades.

Figura 4.11 – Tela principal com opção de recomendação na Unidade.



Fonte: Autoria própria

Figura 4.12 - Tela principal com opção de recomendação no curso.



Fonte: Autoria própria

Marina optou por escolher a opção 1 e recomendou uma apostila sobre “Redes de Computadores e Internet”, do autor Sergio Cantu, para Ana e seus colegas que estão matriculados no curso, conforme mostra a Figura 4.13.

Figura 4.13 - Tela de Recomendação de material

Recomendação de Material

Título: *

Tipo:

Autor:

Unidade:

Tags: *

Link:

Descrição:

Este artigo tem por objetivo dar uma introdução às redes de computadores e a internet, assim como as principais aplicações e protocolos de rede que serão estudados

Arquivo: Apostila Rede...o Kurose.pdf

Obs.: Campos com * são obrigatórios!

Fonte: Autoria própria.

Este material (OA) recomendado é armazenado no Repositório de OA, assim como o artigo que foi recomendado. A listagem de material a ser recomendado é atualizada e a colega Ana, recebe a recomendação da colega Marina (Figura 4.14). Antes de avaliar o material (OA) como “Relevante” ou “Não relevante”, Ana tem a opção de visualizar a reputação de Marina (conforme é exibido na Figura 4.17), para verificar se esse material recomendado provém de uma fonte confiável ou não. No entanto, nesse caso, como Ana e Marina são colegas e Ana confia em Marina ela não achou necessário verificar sua reputação antes de fazer o *download* do material e avaliá-lo.

Figura 4.14 – Lista de material recomendado atualizada.

Preciso de material complementar	
Material Recomendado:	Avaliação:
Título: Redes de Computadores Autor: Gabriel Torres Tipo: artigo Recomendado por: Maria Isabel <input type="button" value="Ver reputação"/> <input type="button" value="Download"/>	O que você achou desta recomendação? <input type="radio"/> Relevante: <input type="radio"/> Não relevante Que nota você daria para esta recomendação? <input type="button" value="▼"/> <input type="button" value="Confirmar"/>
Título: Segurança de Computadores: Princípios e Práticas Autor: Paulo Serrano Tipo: Livro Recomendado por: Fernando <input type="button" value="Ver reputação"/> <input type="button" value="Download"/>	O que você achou desta recomendação? <input type="radio"/> Relevante: <input type="radio"/> Não relevante Que nota você daria para esta recomendação? <input type="button" value="▼"/> <input type="button" value="Confirmar"/>
Título: Internet e seus serviços Autor: Fernando de Castro Velloso Tipo: artigo Recomendado por: João <input type="button" value="Ver reputação"/> <input type="button" value="Download"/>	O que você achou desta recomendação? <input type="radio"/> Relevante: <input type="radio"/> Não relevante Que nota você daria para esta recomendação? <input type="button" value="▼"/> <input type="button" value="Confirmar"/>
Título: Redes de Computadores e Internet Autor: Sérgio Cantu Tipo: apostila Recomendado por: Marina <input type="button" value="Ver reputação"/> <input type="button" value="Download"/>	O que você achou desta recomendação? <input checked="" type="radio"/> Relevante: <input type="radio"/> Não relevante Que nota você daria para esta recomendação? <input type="button" value="▼"/> <input type="button" value="Confirmar"/>

Fonte: Autoria própria.

Ana considerou esse material recomendado por Marina como relevante para realização da tarefa e aperfeiçoamento do seu aprendizado, pontuando-o com nota 5, conforme visualizado na Figura 4.15.

Figura 4.15 – Avaliação do material recomendado

Título: Redes de Computadores e Internet Autor: Sergio Cantu Tipo: apostila Recomendado por: Marina <input type="button" value="Ver reputação"/> <input type="button" value="Download"/>	O que você achou desta recomendação? <input checked="" type="radio"/> Relevante: <input type="radio"/> Não relevante Que nota você daria para esta recomendação? <input type="button" value="5 ▼"/> <input type="button" value="Confirmar"/>
---	---

Fonte: Autoria própria.

No momento que o material de Marina é avaliado, sua reputação é atualizada, sendo incrementado o valor 5 no cálculo da reputação. Deste modo, a reputação de Marina que era 38 foi atualizada, ficando com nota 43. Da mesma forma, a quantidade de recomendações dadas por Marina também foi incrementada, passando de 11 para 12 recomendações, conforme mostra a Figura 4.16.

Figura 4.16 – Dados da reputação de Marina

id_recom	nome	formacao	areaformacao	areainteresse	email	data_nasc	reputa	data_cad	quantrec
1	Marina	Técnico	Informática	Agroindústria, Informática, Ma	marina@gmail.com	2000-05-15	38	2018-03-02	11
1	Marina	Técnico	Informática	Agroindústria, Informática, Ma	marina@gmail.com	2000-05-15	43	2018-03-02	12

Fonte: Autoria própria.

No entanto, apesar do amplo conhecimento que possui sobre o assunto, Marina ainda possui uma trajetória acadêmica incipiente, com poucas publicações em seu currículo. Por outro lado, ela possui uma boa avaliação nas recomendações feitas no sistema, estando no nível de reputação 3, sendo classificada no nível Médio (vide Tabela 4.2).

A Figura 4.17 mostra o perfil da aluna Marina, onde é possível visualizar o nível de reputação, assim como outros dados de cadastro que também são utilizados para formar sua reputação como, por exemplo: seu nível de formação, sua área de formação, sua área de interesse, a data da primeira recomendação, a data da última recomendação, assim como os cursos em que ela está inscrita.

Os dados como: nível de formação (FO), área de formação (AF), área de interesse (AI), avaliação recebida do recomendador (AR) e quantidade de recomendações dadas pelo recomendador (QR), servem de base para o cálculo da reputação que inicialmente é zero e no momento que Marina efetua a primeira recomendação é incrementada.

As datas de recomendação servem para que seja possível verificar a frequência que Marina recomenda material, sendo que no período de 1 ano,


são avaliadas a quantidade de recomendações que são dadas pelo recomendador, conforme consta na Tabela 4.1.

Os cursos em que o aluno está inscrito é importante para estabelecer uma relação com os colegas que estão matriculados no mesmo curso, isso é automaticamente gerado pelo MOODLE.

Ainda, cabe ressaltar que se não houver alteração nos dados FO, AF e AI, esses dados não serão novamente computados no próximo cálculo da reputação.

Dessa forma, de acordo com a Tabela 4.3 e aplicando-se a métrica da equação 5, Marina terá no momento da sua primeira recomendação o valor 3 de reputação, conforme a equação 6.

Figura 4.17 – Tela mostrando o perfil da a aluna Marina



Nome	Marina
Cidade/Município	Canguçu
Endereço de e...	marinas@gmail.com
Tipo de usuário	Aluno
Nível de formaç...	Não graduado
Área de formação	Curso Técnico em Informática
Área de interesse	Informática, Agroindústria, Meio Ambiente
Primeira recom...	1 janeiro 2016
Última recom...	1 janeiro 2016
Nível de reputa...	3
Cursos inscritos	Informática Aplicada

Fonte: Autoria própria.

$$R = \sum a = FO + AF + AI + AR + QR \quad (6)$$

$$\Downarrow$$

$$R = \sum a = 1 + 1 + 1 + 0 + 0$$

Tabela 4.3 – Atributos de Marina

Atributos	Valores
Nível de Formação/FO	Para cada valor de FO foi atribuído um peso específico em uma escala de [1-10]: Doutorado (DOU) = 10 Mestrado (MES) = 7 Especialista (ESP) = 5 Graduação (GRA) = 3 Não graduado (NGRA) = 1
Áreas de formação/AF	Para cada área de formação foi atribuído um peso específico em uma escala de [1-3]: Mesma área do curso proposto (AS): 3 Áreas afins (AF): 2 Área diferente (AD): 1
Áreas de interesse/AI	Para cada área de interesse foi atribuído um peso específico em uma escala de [1-3]: Mesma área do curso proposto (AS): 3 Áreas afins (AF): 2 Área diferente (AD): 1
Avaliação recebida do recomendador/AR	A cada material recomendado o avaliador recebe uma pontuação específica em uma escala de [0 - 5]: Muito Relevante (MR) = 5 Relevância alta (RM) = 4 Relevante média (RR) = 3 Relevância baixa (RB) = 2 Pouco relevante (PR) = 1 Não relevante (NR) = 0
Quantidade de recomendações dadas pelo recomendador/QR	No período de 1 ano, são avaliadas a quantidade de recomendações que são dadas pelo recomendador, em uma escala de [1– 5]: Nenhuma = 0 1 à 19 = 1 20 à 39 = 2 40 à 69 = 3 70 à 99 = 4 Maior ou igual a 100 = 5

Além destes cenários apresentados outros poderão ser explorados, pois há uma quantidade e diversidade muito grande de alunos existentes nos ambientes de *e-learning*, cada um com necessidades e interesses específicos, assim como níveis de experiências diferentes, desde estudantes inexperientes ou usuários com anos de experiência.

5 AVALIAÇÃO DA ARQUITETURA E-RECREP

Este Capítulo apresenta a avaliação das funcionalidades da Arquitetura e-RecRep, com base em cenários de uso na área educacional. Ainda, é destacada neste Capítulo a avaliação com método TAM de uma das aplicações prototipadas com o emprego da Arquitetura e-RecRep.

A escolha desta área e dos correspondentes cenários de uso decorre de projetos que vem sendo desenvolvidos no Campus Pelotas – Visconde da Graça na área da educação a distância e presencial.

Segundo (SATYANARAYANAN, 2010), cenários de uso têm sido uma das formas de avaliação mais utilizadas pela comunidade científica. Particularmente, (KNAPPMAYER et al., 2013) considera que a prototipação tem se mostrado uma escolha adequada para avaliação de arquiteturas, pois permite a identificação de não conformidades a partir da experiência dos usuários com aplicações que utilizam as mesmas.

Assim, na continuidade deste Capítulo, são apresentadas a avaliação com método TAM (*Technology Acceptance Model*), os participantes envolvidos, os instrumentos e métodos utilizados, assim como os resultados obtidos.

5.1 Avaliação com Método TAM

Esta seção apresenta a avaliação das funcionalidades concebidas para a Arquitetura e-RecRep, considerando a aplicação prototipada para o cenário de uso da área educacional.

A experiência do usuário com a aplicação pode ser avaliada de forma explícita, com o emprego de entrevistas e questionários, ou implicitamente através de observações. Essa estratégia pode refletir diretamente a usabilidade das aplicações, indicando a capacidade da arquitetura em atender os requisitos das mesmas, bem como possibilitando verificar o correto funcionamento de seus módulos (KNAPPMAYER et al., 2013).

Neste trabalho foram adotadas as duas formas: i) foi aplicado um questionário de avaliação da aplicação prototipada com a Arquitetura e-RecRep empregando o Modelo de Aceitação de Tecnologia (TAM –

Technology Acceptance Model) proposto por (DAVIS, 1989); ii) foram observados os logs de acesso dos usuários no ambiente.

O TAM foi projetado para compreender a relação causal entre variáveis externas de aceitação dos usuários e o uso real de uma tecnologia da informação, buscando entender o comportamento deste usuário através do conhecimento da utilidade e da facilidade de utilização percebida por ele (YOON; KIM, 2007).

Para Davis (1989) as pessoas tendem a usar uma tecnologia com o objetivo de melhorar o desenvolvimento de suas atividades, esse aspecto corresponde a “utilidade percebida”. Porém, mesmo que uma pessoa entenda que uma determinada tecnologia é útil, a utilização da mesma poderá ser prejudicada em função de sua complexidade. Nesse caso, a “facilidade percebida” traduz o esforço de uso de uma tecnologia.

Desta forma, as pessoas usarão a tecnologia se acreditarem que este uso fornecerá resultados positivos, tendo em vista a facilidade de uso percebida e a utilidade percebida.

Assim, o TAM normalmente é utilizado para entender os motivos que levam os usuários a aceitar ou rejeitar uma tecnologia de informação e como melhorar a aceitação, oferecendo, desse modo, um suporte para prever e explicar a aceitação (RAITOHARJU, 2007).

5.1.1 Participantes

A avaliação da Arquitetura e-RecRep foi realizada através de um estudo de caso abrangendo, inicialmente, 10 alunos de diferentes níveis de graduação e, posteriormente, uma turma da disciplina de Informática Aplicada, com aproximadamente 30 alunos. Vale salientar que estes alunos já utilizavam o ambiente virtual MOODLE sem a incorporação da Arquitetura e-RecRep, para realização das tarefas na disciplina.

A Figura 5.1 mostra uma das turmas que utilizou o ambiente virtual para realização das atividades no AVA e testou a arquitetura proposta.

Figura 5.1 - Participantes de uma turma que utilizou o ambiente virtual para realização das atividades do ambiente virtual.



Fonte: Autoria própria.

Nos experimentos realizados, os 5 professores das disciplinas de Informática Aplicada do Campus cadastraram o material a ser recomendado aos alunos, uma média de 20 a 30 recomendações por professor totalizando, para esse experimento, 145 materiais recomendados.

5.1.2 Instrumentos e Métodos

Para a avaliação da arquitetura e-RecRep, foram realizados 2 experimentos, que serão descritos a seguir:

A) Experimento 1

Foi realizado um primeiro experimento, com 10 estudantes de diferentes níveis de graduação (6 de nível técnico, 2 de nível superior e 2 de pós-graduação) que foram selecionados para verificar a análise feita por cada um desses alunos.

Cada participante foi instruído a usar a arquitetura no ambiente virtual MOODLE, sendo que esses alunos já possuíam cadastro assim como já utilizavam o ambiente virtual nas suas aulas presenciais e à distância.

Desta forma, neste experimento cada participante foi orientado a utilizar o ambiente virtual MOODLE em dois momentos diferentes:

- i) inicialmente, sem a incorporação da Arquitetura e-RecRep;
- iii) com a integração da e-RecRep.

Posteriormente, os participantes responderam um questionário de avaliação, considerando a experiência de uso. As questões foram elaboradas

com base no TAM, considerando: (i) Facilidade de uso: grau em que o participante do experimento avalia que o aplicativo pode reduzir seu esforço; e (ii) Percepção de Utilidade: O grau em que o participante da experiência avalia que o aplicativo pode melhorar sua experiência.

As alternativas para responder as questões foram estruturadas de acordo com a escala *Likert*, composta por cinco opções que avaliam a experiência do participante com a aplicação. A escala *Likert* fornece cinco alternativas em um intervalo que começa em 1 (discordo totalmente) a 5 (concordo totalmente).

A Tabela 5.1 contém o formulário de avaliação aplicado aos participantes, sendo que as cinco primeiras questões correspondem à facilidade de uso e as demais dizem respeito à percepção de utilidade.

Tabela 5.1 - Formulário de avaliação aplicado


Nro.	Categoria	Questão
01	Facilidade de uso	A aplicação é fácil de entender.
02	Facilidade de uso	A aplicação é fácil de usar.
03	Facilidade de uso	As opções são claras e objetivas.
04	Facilidade de uso	Com pouco esforço consigo acessar uma recomendação.
05	Facilidade de uso	Com pouco esforço consigo visualizar a reputação de um recomendador.
06	Utilidade	As recomendações geradas foram relevantes para o aperfeiçoamento do meu aprendizado.
07	Utilidade	A quantidade de recomendações geradas foram suficientes.
08	Utilidade	A ordem das recomendações recebidas foi adequada.
09	Utilidade	A possibilidade de visualização da reputação do recomendador contribuiu na escolha do material recomendado.
10	Utilidade	Eu usaria essa aplicação como ferramenta no processo de aprendizagem.

Fonte: Autoria própria.

A Figura 5.2 mostra um exemplo de aplicação da escala de *Likert* no formulário de avaliação utilizado no experimento.

questões relacionadas à quantidade de recomendações geradas e à ordem de sua apresentação.

Figura 5.3 - Avaliação de Facilidade de Uso e Percepção de Utilidade



Fonte: Autoria própria

Além da avaliação explícita realizada através dos formulários sobre o uso da arquitetura e-RecRep, foi realizada, também, uma avaliação implícita onde foram observados os *logs* de acesso dos usuários no ambiente. A finalidade principal dessa análise foi verificar se os alunos acessaram a opção “Preciso de material complementar”. A Figura 5.4 ilustra um exemplo de *log* de acesso de um aluno no ambiente.

Figura 5.4 – Exemplo de log de acesso no ambiente

Hora	endereço IP	Nome completo	Ação	Informação
sex 4 agosto 2017, 22:58	0:0:0:0:0:0:1	Marina Silveira	course view	Informática Aplicada
sex 4 agosto 2017, 22:43	0:0:0:0:0:0:1	Marina Silveira	course view	Informática Aplicada
sex 4 agosto 2017, 22:43	0:0:0:0:0:0:1	Marina Silveira	lti launch	Preciso de material complementar
sex 4 agosto 2017, 22:43	0:0:0:0:0:0:1	Marina Silveira	lti view	Preciso de material complementar
sex 4 agosto 2017, 22:25	0:0:0:0:0:0:1	Marina Silveira	course view	Informática Aplicada
sex 4 agosto 2017, 22:18	0:0:0:0:0:0:1	Marina Silveira	url view	Questionário de avaliação

Fonte: Autoria própria

B) Experimento 2

Este experimento foi realizado com uma turma de nível técnico, da disciplina de Informática Aplicada, abrangendo aproximadamente 30 alunos. Da mesma forma que no primeiro experimento, cada participante foi orientado a utilizar o ambiente virtual MOODLE, no entanto, foram em três momentos diferentes:

- i) inicialmente, sem a incorporação da Arquitetura e-RecRep;
- ii) com a integração da e-RecRep, somente com recomendação, sem a disponibilização da reputação.
- iii) com a integração da e-RecRep, sendo disponibilizadas as funcionalidades de recomendação e reputação.

Então, diferente do primeiro experimento, neste os alunos tiveram, também, a oportunidade de testar o uso da arquitetura sem a incorporação do mecanismo de reputação, sendo este um dos objetivos a serem atingidos na pesquisa deste trabalho.

Na sequência, os participantes também responderam um formulário de avaliação, que foi elaborado da mesma forma que no primeiro experimento. No entanto, foram utilizadas somente as 5 questões relacionadas a percepção de utilidade, ou seja, grau em que o participante do experimento avalia que a aplicação pode melhorar a sua experiência.

Justifica-se o fato de ter-se utilizado, neste experimento, somente as questões relacionadas a percepção de utilidade devido ao foco deste trabalho ser a avaliação da utilidade do material recomendado, assim como as recomendações e reputação geradas e não o quão fácil é o uso desta arquitetura.

A Tabela 5.3 contém o formulário aplicado aos participantes, sendo que as afirmações correspondem à percepção de utilidade dos mesmos em relação à arquitetura e-RecRep.

Tabela 5.3 - Formulário de Avaliação

Nro.	Categoria	Questão
01	Utilidade	As recomendações geradas foram relevantes para o aperfeiçoamento do meu aprendizado.
02	Utilidade	A quantidade de recomendações geradas foram suficientes.
03	Utilidade	A ordem das recomendações recebidas foi adequada.
04	Utilidade	O ambiente virtual MOODLE com a possibilidade de visualização da reputação do recomendador contribuiu na escolha do material recomendado.
05	Utilidade	Eu usaria o MOODLE com a integração dos recursos de recomendação e reputação, providos pela Arquitetura e-RecRep.

Fonte: Autoria própria.

As respostas obtidas são mostradas na Tabela 5.4. Nesta tabela, a primeira coluna corresponde às afirmações, as seguintes cinco colunas apresentam os resultados obtidos em cada escala, em graus relativos e absolutos, e a última coluna mostra a média consolidada da percentagem, variando de 0 a 5. As colunas tem peso que variam de 1 a 5, sendo a primeira com 1 até a última com peso 5. A Tabela 5.4 mostra a média obtida nas 5 afirmações avaliadas pelos 30 alunos da turma.


Tabela 5.4 - Avaliação da Percepção de Utilidade

Afirmações	Discordo Totalmente	Discordo parcialmente	Indiferente	Concordo Parcialmente	Concordo Totalmente	Média
1	0%	0%	0%	24%	76%	4,4
2	0%	3%	10%	29%	58%	4,1
3	0%	2%	13%	29%	54%	4,0
4	0%	3%	12%	33%	52%	4,0
5	0%	4%	17%	18%	60%	4,0

Fonte: Autoria própria.

Os resultados obtidos demonstram que a proposta obteve, novamente, boa aprovação, no que diz respeito a percepção de utilidade, sendo que a alternativa “Concordo totalmente” possui o maior percentual obtido em todas as afirmações, conforme mostra os dados da Figura 5.5.


Figura 5.5 – Avaliação da Percepção da Utilidade



Fonte: Autoria própria.

Na análise realizada encontramos alguns resultados na escala "Discordo parcialmente" e "Indiferente", especialmente, nas afirmações relacionadas ao número de recomendações geradas e à ordem de apresentação, conforme mostra os dados da Figura 5.6.


Figura 5.6 - Avaliação da Percepção de utilidade das afirmações 2 e 3.



Fonte: Autoria própria.

Em relação à afirmação 4 que diz respeito à contribuição da possibilidade de visualização da reputação do recomendador na escolha do material recomendado, verificou-se nenhum aluno “discorda totalmente”, mas há alunos que são “indiferentes” e “discordam parcialmente” mesmo sendo um percentual baixo, conforme mostra os dados da Figura 5.7.

Figura 5.7 - Avaliação da Percepção de utilidade das afirmação 4.




Fonte: Autoria própria.

É importante destacar que, conforme já foi mencionado, este experimento foi aplicado à um mesmo grupo de alunos, tanto com a possibilidade de visualização da reputação do recomendador como sem esta opção, sendo, justamente, a finalidade constatar a utilidade dessa opção no ambiente.

Na afirmação 5, onde o usuário avalia o uso do MOODLE com a integração dos recursos de recomendação e reputação providos pela Arquitetura e-RecRep, há um percentual elevado que “Concorda totalmente” com a incorporação desses 2 módulos. No entanto, verifica-se, também, que há um número de participantes que é indiferente, assim como há alguns que discordam parcialmente, conforme mostra os dados da Figura 5.8.

Figura 5.8 - Avaliação da Percepção de utilidade da afirmação 5.



Fonte: Autoria própria.

No que diz respeito às respostas “Discordo parcialmente”, isso pode ser atribuído a vários fatores a serem investigados, sendo um deles, o fato deste ser apenas um experimento inicial, com uma pequena base de dados, o qual dificulta a recomendação de uma maior quantidade de OAs. Outro fator que também pode ser atribuído é a falta de experiência do usuário no uso da Arquitetura, pois o mesmo já está habituado a utilizar o ambiente virtual tradicional.


5.1.3 Análise e Discussão dos resultados

Os experimentos realizados tiveram, então, o objetivo principal de validar a proposta deste trabalho, onde foram analisadas a importância de se incorporar um mecanismo de reputação às técnicas de recomendação em um ambiente de *e-learning*, tornando a recomendação de materiais mais confiáveis e de melhor qualidade, para os alunos inscritos nos cursos disponíveis no ambiente MOODLE.

Diante disso, foi traçado um comparativo entre os 2 experimentos aplicados e verificou-se que a média mais baixa foi em relação às questões

correspondentes à quantidade de recomendações assim como a ordem das recomendações recebida, conforme já mencionado, isso pode ser explicado devido ao número reduzido de recomendações feitas no ambiente, o qual poderá ser melhorado com a realização de novos experimentos. A Figura 5.9 mostra o comparativo entre as médias das afirmações dos dois experimentos realizados

Figura 5.9 – Comparativo de média dos dois experimentos



Fonte: Autoria própria.

Por outro lado, a questão da visualização do reputador teve uma boa aceitação, especialmente no segundo experimento onde os alunos, na sua maioria, concordaram que a opção de poder visualizar a reputação do recomendador antes de fazer o *download* do material contribuiu na escolha do material recomendado.

Feita uma análise nos *logs* de acesso verificou-se que todos os alunos que testaram este experimento “clikaram” na opção de visualização da reputação do recomendador, mas não se tem a certeza se foi por uma questão apenas de curiosidade ou se isso realmente influenciou na escolha do material recomendado. No entanto, verificou-se que todos os alunos realizaram as tarefas propostas, assim como obtiveram um bom rendimento na realização das mesmas.

6 CONSIDERAÇÕES FINAIS

Hoje em dia, o uso de sistemas de recomendação e modelos de reputação em áreas como o comércio eletrônico tornou-se comum, acredita-se que seu uso em sistemas de *e-learning* também é interessante: nos sistemas de *e-learning*, o uso de sistemas recomendadores torna-se cada vez mais necessário. Os alunos têm disponível uma quantidade enorme de OAs e materiais, exigindo mecanismos que servem para filtrar os OAs mais apropriadas para seu perfil. Conseqüentemente, o uso de modelos de reputação em ambientes de *e-learning* pode tornar mais confiável e personalizado o processo de escolha de material.

Analisando-se o estado da arte dos Ambientes Virtuais de Aprendizagem pôde-se observar que todos trabalham como ferramentas de auxílio ao aprendizado de forma isolada e com recursos necessários para desenvolver o conhecimento do aluno sobre determinado assunto, porém em nenhum deles fornece opção de recomendação de material externo, assim como a opção de visualização da reputação do recomendador, fazendo com que o aluno acabe optando por utilizar outras ferramentas, como mecanismos de busca, que nem sempre são confiáveis e, muitas vezes, não oferecem material de qualidade, assim como, os alunos acabam dispendo de maior tempo para encontrarem o material adequado do qual necessitam.

Com o intuito de atender essa demanda, essa tese tem como objetivo incorporar um mecanismo de reputação às técnicas de recomendação em um ambiente de *e-learning*, afim de ajudar o aluno a obter sugestões de materiais confiáveis e de melhor qualidade em um curto período de tempo.

O experimento foi aplicado no Ambiente Virtual de Aprendizagem MOODLE do Instituto Federal Sul-rio-grandense – Campus Visconde da Graça, instituição em que a autora deste trabalho atua.

Na fase inicial do trabalho, são estudados os sistemas recomendados e as técnicas mais utilizadas na literatura, além de fazer uma seleção dos mais apropriados para o nosso trabalho. Além disso, os modelos de reputação mais citados na literatura foram estudados, assim como foram utilizadas técnicas selecionadas e algoritmos implementados neste trabalho em uma forma de

módulos, bem como nós definimos métricas para calcular a reputação dos usuários que recomendam material no meio ambiente.

Como conclusão final do trabalho destaca-se que com base nos experimentos realizados e com a participação de uma amostra de alunos foi possível evidenciar que a inclusão da reputação em um ambiente de *e-learning* apresenta-se como um diferencial, seja na interface que irá permitir a seleção de qual recomendação acessar, como nos resultados de satisfação da recomendação fornecida. Contudo deve-se observar que os resultados provem de uma amostra de pesquisadores, portando não são generalizáveis, constituindo-se em uma evidência.

6.1 Contribuições

Entende-se como contribuição central deste trabalho a concepção de uma arquitetura para integração de modelos de reputação a sistemas de recomendação. Com isso, viabiliza-se a modificação de ambientes de aprendizagem, incluindo a personalização às características dinâmicas que o ambiente Web pode propiciar.

6.2 Publicações

As principais contribuições da pesquisa foram compartilhadas com a comunidade científica através de publicações, conforme Tabela 6.1.

Tabela 6.1: Publicações realizadas

Artigo	Periódico/ Congresso	Qualis	Ano
Incorporating a reputation mechanism to generate personalized recommendations in an e-learning environment	ICALT	B1	2018
The use of recommendation systems techniques in e-learning environments considering reputation	ITS	B1	2018
Integrating Reputation to Recommendation Techniques in an e-learning Environment	ITHET	B2	2018
Explorando o Uso dos Elementos do LOM na Determinação dos Aspectos de Qualidade dos Objetos de Aprendizagem a partir de Critérios de Qualidade de Informação	SBIE	B1	2014
Em busca de recomendação de objetos de aprendizagem em um ambiente <i>e-learning</i> com uso de ontologias	LACLO	B3	2013

6.3 Limitações

A arquitetura e-RecRep foi integrada ao AVA MOODLE (<http://MOODLE.org>), como um *plugin*, para que ele possa idealmente ser usado em qualquer outro ambiente de aprendizagem. No entanto, como foi desenvolvido em linguagem *PHP* e utiliza banco de dados *MySQL*, vale salientar, que teria que sofrer adaptações de tecnologia para que essa incorporação seja possível.

6.4 Trabalhos futuros

Diversas oportunidades podem ser exploradas na continuidade da pesquisa relacionada à Arquitetura e-RecRep. Neste sentido, destacam-se os seguintes temas que podem ser considerados em trabalhos futuros:

- realizar outros experimentos visando aprimorar o protótipo, ampliando as possibilidades de utilização nas Instituições de Ensino;
- incorporar outras técnicas de sistemas de recomendação, tais como: mineração de dados, raciocínio baseado em casos, ontologias, de modo que possam ser fornecidas alternativas para executar tarefas

que podem contribuir com o processo de recomendação do OA, elevando o grau de personalização do ambiente.

- definir outras métricas para o cálculo da reputação, como a inclusão dos índices (*H-index*, *G-index* e outros indicadores) que possibilitem obter maiores informações dos recomendadores.
- especificar métricas e/ou critérios para recomendação dos OAs, tornando o ambiente ainda mais personalizado.
- adaptar a arquitetura para uso em outros ambientes de *e-learning*, tais como: TelEduc, AulaNet e Adaptweb.

7 REFERÊNCIAS

ABED. Censo EAD.BR: relatório analítico da aprendizagem a distância no Brasil 2016 = Censo EAD.BR: analytic report of distance learning in Brazil 2016 [livro eletrônico]/[organização] ABED – Associação Brasileira de Educação a Distância; [traduzido por Maria Thereza Moss de Abreu]. Curitiba: InterSaberes, 2017. Disponível em: <<http://abed.org.br/arquivos>>. Acesso em julho de 2018.

ADOMAVICIUS, G. and TUZHILIN, A. *Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions*. IEEE Transactions on Knowledge and Data Engineering, Piscataway, v. 17, n. 6, p. 734-749, 2005.

AGRAWAL, R., IMIELINSKI, T., A. SWAMI. *Mining association rules between sets of items in large databases*. Proc. of the ACM SIGMOD Conference. Washington, DC, USA, 1993, p. 207-216. Disponível em: <http://wang.ist.psu.edu/course/05/IST597/papers/Agrawal_mining.pdf>. Acesso em julho de 2018.

AKTAS, D. et al. *CYP1A1 and GSTM1 polymorphic genotypes in patients with prostate cancer in a Turkish population*. Cancer Genet. Cytogenet., 154: 81-85, 2004.

ALOISE, A. F.. *Um Sistema De Recomendação Para Professores E Coordenadores De Curso Utilizando Predição De Reprovação Na Modalidade De Educação A Distância*. Tese (Mestrado) - Universidade Do Vale do Rio dos Sinos – Unisinos. Programa Interdisciplinar de Pós-Graduação em Computação Aplicada. São Leopoldo, 2016.

AUDINO, D.F.; NASCIMENTO, R.S. *Diálogos entre conceitos e uma nova proposição aplicada à educação*. Revista Contemporânea de Educação. Rio de Janeiro: Universidade Federal do Rio de Janeiro, 2010, v.5, n.10. p.166.

BAEZA-YATES, Ricardo; RIBEIRO-NETO, Berthier. *Modern Information Retrieval*. 1st Edition. Harlow: Addison Wesley, 1999.

BEHAR, P. A.; OLIVEIRA, S. d.; SCHNEIDER, K. D. *Em busca das interações interindividuais no rooda*. Revista Educação, 2004.

BHASKARAN, S., and SANTHI, B.. *An efficient personalized trust based hybrid recommendation (TBHR) strategy for e-learning system in cloud computing*. Cluster Computing, 2017, 1-13.

BRITAIN, S.; LIBER, O. *A Framework for Pedagogical Evaluation of Virtual Learning Environments*. [S.l.], October 1999. Disponível em: <<http://www.leeds.ac.uk/educol/documents/00001237.htm/>>. Acesso em julho de 2018.

BURKE, R.. *Hybrid web recommender systems*. In *The adaptive web*, 2007, pp. 377–408.

CAZELLA, Silvio Cesar et al. *Desenvolvendo Um Sistema de Recomendação de Objetos de Aprendizagem Baseado em Competências para a Educação: Relato de Experiências*. Anais do Simpósio Brasileiro de Informática na Educação, v. 23, n. 1, 2012. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/1710>>. Acesso em agosto de 2018.

CAZELLA, S. C. *Aplicando a Relevância da Opinião de Usuários em Sistema de Recomendação para Pesquisadores*. Tese (doutorado) – Universidade Federal do Rio Grande do Sul. Programa de Pós-Graduação em Ciência da Computação, Porto Alegre, Brasil, 2006.

CAZELLA, S. C., NUNES, M. A. S. N., REATEGUI, E. *A Ciência do Palpite: Estado da Arte em Sistemas de Recomendação*. In: Jornada de Atualização de Informática-JAI 2010- CSBC2010, 2010. Ed. Rio de Janeiro: Puc RIO, 2010, v.1, p. 161-216.

CERVI, C. R., GALANTE, R., and de OLIVEIRA, J. P. M. *Identificando a reputação de pesquisadores usando um modelo de perfil adaptativo*. Anais do XXXVIII SEMISH, 2011.

CHEN, W. and MIZOGUCHI, R. *Communication Content Ontology for Learner Model Agent in Multi-agent Architecture*. In: Proceedings of the 7th International Conference on Computers in Education - ICCE99, 1999.

COSTA, R. *Por um novo conceito de comunidade: redes sociais, comunidades pessoais, inteligência coletiva*. Revista Interface - Comunicação, Saúde, Educação, 17, 2005.

CRUZ et al. *A proposal for recognizing reputation within communities of practice*. Em CSCWD (Selected Papers)'07, páginas 443_454, 2007.

DASGUPTA, P. *Trust: Making and Breaking Cooperative Relations, chapter Trust as a Commodity*. Pages 49–72. Department of Sociology, University Oxford. This was originally published in hardcopy in 1988, PDF is 2000 electronic version, 2000.

de OLIVEIRA ALBUQUERQUE, R. *Uma Proposta de um Modelo de Confiança Computacional para Grupos em Sistemas Distribuídos*. PhD thesis, Universidade de Brasília, Brasília, 2008.

DRACHSLER, H., VERBERT, K., SANTOS, O. C., & MANOUSELIS, N. *Panorama of Recommender Systems to Support Learning*. In F. Rici, L. Rokach, & B. Shapira (Eds.), 2nd Handbook on Recommender Systems (pp. 421- 451). Springer, US. 2015. Disponível em: <http://dx.doi.org/10.1007/978-1-4899-7637-6_12>. Acesso em julho de 2018.

DE MEO P., MESSINA, F., ROSACI, D., SARNÉ, G. M. L.. *Combining trust and skills evaluation to form e-learning classes in online social networks*. Information Sciences 405, 107-122, 2017.

- DOUGIAMAS, M.; TAYLOR, P. C. *Moodle: Using learning communities to create an open source course management system*. In: Proceedings of the EDMEDIA 2003 Conference, Honolulu, Hawaii. [S.l.: s.n.], 2003.
- EYHARABIDE, PV. et. al.. *Personalized e-learning environments: Considering students' contexts*. Education and Technology for a Better World, 2009, 302, 48–57, 2009.
- FERREIRA, V. H. and RAABE, A.L.A. *LORSys – Um Sistema de Recomendação de Objetos de Aprendizagem SCORM para o MOODLE*. XX Simpósio Brasileiro de Informática na Educação, 2009.
- FERRIS, G. et al. *Personal Reputation in Organizations*. Jerald Greenberg, New Jersey, USA, 2003.
- FRANCISCATO, F. T. et al. *Avaliação dos ambientes virtuais de aprendizagem moodle, teleduc e tidia-ae: um estudo comparativo*. In: RENOTE - Revista Novas Tecnologias na Educação. [S.l.: s.n.], 2008.
- FRIEDMAN, J. et al. *Pathwise coordinate optimization*. Annals of Applied Statistics, 2(1):302–332, 2007.
- FRIESEN, N. *What are Learning Objects?* Interactive Learning Environments, [S.l.], v.9, n.3, Dec. 2001. Disponível em: <<http://www.careo.org/documents/objects.html>>. Acesso em julho de 2018.
- GOLBECK, J. *Computing and Applying Trust in Web-based Social Networks*. Tese de Doutorado, Department of Computer Science, University of Maryland, USA, 2005.
- GOLDBERG, D. et al. *Using collaborative filtering to weave an information tapestry*. Communications of ACM, vol. 35, no. 12, pp. 61–70, 1992.
- GOMES, E. A. *Segurança em aplicações p2p através de reputação inferida de redes sociais*. 2009. Disponível em: <<http://edeyson.com.br/Arquivos/Doutorado/Redes%20Sociais%20e%20Aplicacoes%20Ubiquas.pdf>>. Acesso em junho de 2018.
- GUTTMAN, R. H.; MOUKAS, A. G.; MAES, P.. *Agent-mediated electronic commerce: a survey*. Knowl. Eng. Rev., 13(2):147-159, 1998. Disponível em: <<http://alumni.media.mit.edu/~guttman/research/pubs/ker98.pdf>>. Acesso em: Janeiro de 2018.
- IMRAN, H.; BELGHIS-ZADEH, M.; CHANG, T.; GRAF, K.S.: *PLORS: A Personalized Learning Object Recommender System*. Vietnam J. Comput. Sci. 3(1), 3–13, 2016.
- HERLOCKER, J. et al. *An algorithmic framework for performing collaborative filtering*. Proceedings of ACM SIGIR'99. ACM. xvi+339, 230-7, 1999.

- HERLOCKER, J.L. Herlocker. *Understanding and Improving Automated Collaborative Filtering Systems*. Ph.D. Dissertation. University of Minnesota. Advisor(s) Joseph A. Konstan. AAI9983577, 2000.
- JOSANG et al. *A Survey of Trust and Reputation Systems for Online Service Provision*. Distributed Systems Technology Centre and Information Security Research Centre, Queensland University of Technology Brisbane Qld 4001, Australia, 2006.
- KERKIRI, T., A. Manitsaris, and A. Mavridou. *Reputation Metadata for Recommending Personalized E-learning Resources*. Proceedings of the Second International Workshop on Semantic Media Adaptation and Personalization, Uxbridge, Dec 2007, pp. 110-115.
- KLEINBERG, J. M. *Authoritative sources in a hyperlinked environment*. J. ACM, 46:604–632. 21, 52, 1999.
- LIMA, D. O. *Infraestrutura para gerenciamento de reputação de usuários e sua aplicação em um caso real*. Master's thesis, Universidade Federal do Rio Grande do Sul, Porto Alegre, BRA, 2010.
- LIN, W. Y; RUIZ, C., and ALVAREZ, S.A. *A new adaptive-support algorithm for association rule mining*. Technical Report WPI-CS-TR-00-13, Department of Computer Science, Worcester Polytechnic Institute, May 2000.
- LIU, L., MUNRO, M., and SONG, W. *Evaluation of collecting reviews in centralized online reputation systems*. In WEBIST (2), pages 281–286. 17, 18, 2010.
- LOM. *LOM working draft v4.1* [On-line]. 2000. Disponível em: <<http://ltsc.ieee.org/doc/wg12/LOMv4.1.htm>>. Acesso em agosto de 2018.
- MAES, P.; SHARDANAND, U.. *Social information filtering: Algorithms for automating "word of mouth"*. In: Human Factors in Computing Systems. Proceedings..., 1995, p. 210-217. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.30.6583&rank=1>>. Acesso em: Fevereiro de 2016.
- MAMANI, E. Z. S. *Cálculo de reputação em redes sociais a partir da colaboração entre os participantes*. 2013. 93 f. Dissertação de Mestrado - Instituto de Matemática e Estatística, Universidade de São Paulo, São Paulo, 2013.
- MCNEE, S. et al. *On the recommending of citations for research papers*. Proceedings of the 2002 ACM Conference on Computer Supported Cooperative Work, New Orleans, Louisiana (pp. 116–125). New York, NY: ACM, 2002.
- MILLER, B. *Towards a Personal Recommender System*. 2003. PhD Thesis. Department of Computer Science and Engineering, University of Minnesota, Minneapolis.

MONTANER, M. *Collaborative Recommender Agents Based On Case-Based Reasoning and Trust*, 2003.

MUI, L. et al. *A Computational Model of Trust and Reputation*. In Proceedings of the 35th Hawaii International Conference on System Science (HICSS), 2002.

NASCIMENTO, L. Jr. and YONEYAMA, T. *Inteligência Artificial: em Controle e Automação*. São Paulo: Edgard Blücher, 2000.

O'DONOVAN, J., SMYTH, B.: *Trust in recommender systems*. In: Proceedings of the 10th International Conference on Intelligent User Interfaces (IUI '05), pp. 167–174. ACM, San Diego, California, USA, 2005.

PAGE, L. et al. *The pagerank citation ranking: bringing order to the web*. 1999.

PENTEADO, F.; GLUZ, J. C.; GALAFASSI, C. *Suporte Técnico/Pedagógico aos OAs pelos AVAs: uma Análise Comparativa das Pesquisas Recentes*. In: Anais do Simpósio Brasileiro de Informática na Educação. 2011.

PICCOLI, G.; AHMAD, R.; IVES, B. *Web-based virtual learning environments: A research framework and a preliminary assessment of effectiveness in basic it skills training*. MIS Q., Society for Information Management and The Management Information Systems Research Center, Minneapolis, MN, USA, v. 25, n. 4, p. 401-426, dez. 2001. ISSN 0276-7783. Disponível em: <<http://dx.doi.org/10.2307/3250989>>.

PUJOL, J. M., SANGÜESA, R., and DELGADO, J. *Extracting Reputation in Multi Agent Systems By Means of Social Network Topology*. In Proceedings of the first international joint conference on Autonomous agents and multiagent systems: part 1, AAMAS '02, pages 467–474, New York, USA. ACM. 9, 17, 20, 21, 2002.

RAITOHARJU, R. *Information Technology Acceptance in the Finnish Social and Healthcare Sector: exploring the effects of cultural factors*. [S.l.]: Turku School of Economics, 2007.

REATEGUI, E.L B.; CAZELLA, S. C.. *Sistemas de Recomendação*. In: CONGRESSO DA SOCIEDADE BRASILEIRA DE COMPUTAÇÃO. São Leopoldo, 2005. Anais. p. 306-348.

REATEGUI, E. et al. *Um Agente Animado para Ambientes de Aprendizagem Colaborativos*. Revista Brasileira de Informática na Educação, Porto Alegre, RS, v. 14, n. 3, p. 27-38, 2006.

RESNICK, P. et al. *GroupLens: An Open Architecture for Collaborative Filtering of Netnews*. In: Proceedings of the Conference on Computer Supported Cooperative Work, Chapel Hill, NC, 1994, pp. 175-186.


- RESNICK, P. et al. *Reputation Systems*. Commun. ACM, 43:45–48, 2000.
- RESNICK, P., KUWABARA, K., ZECKHAUSER, R., and FRIEDMAN, E. *Reputation Systems*. Commun. ACM, 43:45–48, 2000.
- RESNICK, P.; VARIAN, H. R.. *Recommender Systems*. *Communications of the ACM*, **40** (3), 56-58, 1997. Disponível em: <<http://portal.acm.org/citation.cfm?id=245108.245121>>. Acesso em janeiro de 2018.
- RIEDL, J. et al. *Combining Collaborative Filtering with Personal Agents for Better Recommendations*. In: Proceedings of AAAI, Proceedings..., vol. 35, pp.439-446, 1999.
- ROBERTSON, S. *Understanding inverse document frequency: On theoretical arguments for idf*. Journal of Documentation 60 (5), 503–520, 2004.
- ROCHA, H. V. *TelEduc: software livre para a educação a distância*. [S.l.]: Educação online, 2006.
- SABATER, J. and SIERRA, C. *Social regret, a reputation model based on social relations*. SIGecom Exch., 3:44–56, 2001.
- SALTON, G.; BUCKLEY, C. *Term weighting approaches in automatic text retrieval*. Information Processing and Management, [S.l.], v. 24, n. 5, p. 513-523, 1988. Disponível em: <<http://citeseer.ist.psu.edu/viewdoc/summary?doi=10.1.1.101.9086>>. Acesso em fevereiro de 2018.
- SALTON, G. and MCGILL, M.J. *Introduction to Modern Information Retrieval*. McGraw-Hill Book Co., New York, 1993.
- SANTOS, O.C.: *A recommender system to provide adaptive and inclusive standard-based support along the e-learning life cycle*. In: RecSys '08: Proceedings of the 2008 ACM conference on Recommender systems, pp. 319–322. ACM, New York, NY, USA (2008). Disponível em: <<http://doi.acm.org/10.1145/1454008.1454062>>.
- SAWAR, B. et al. *Item-based collaborative filtering recommendation algorithms*. In Proceedings of the 10th International World Wide Web Conference, Hong Kong, 2001.
- SCORM. Sharable Content Object Reference Model(SCORM). Version 1.2. ADL, 2001-11-14, 2001. Disponível em: <<http://www.adlnet.org/library/documents/scorm/software/SCORM.htm>>. Acesso em agosto de 2018.
- SILVA, Patrícia Alexandra; SILVA, Alberto Rodrigues da. *Análise funcional de plataformas de objectos de aprendizagem*. In: IBEROAMERICAN CONGRESS ON TELEMATICS, 6, 2006. Monterrey: CITA, 2006. p.1-10.

- SINGH, A. P., SHUBHANKAR, K., and PUDI, V. *An efficient algorithm for ranking research papers based on citation network*. Data Mining and Optimization (DMO), 2011. 3rd Conference on, pages 88–95. 51, 52, 2011.
- SMYTH, B. et al.. *Collaboration, reputation and recommender systems in social web search*. In Recommender Systems Handbook, pages 569–608. Springer, 2015.
- SOUTO, Maria Aparecida Martins; VERDIN, Regina; SOUZA, Karine Beschoren de; ZANELLA, Renata; NICOLAO, Mariano; MADEIRA, Milton J. P.; VICARI, Rosa Maria; OLIVEIRA, Jose Palazzo Moreirade. *Web-adaptive training system based on cognitive student style*. In: IFIP WORLD COMPUTER CONGRESS, 17., 2002, Montreal. *TelE-learning*. Boston: Kluwer Academic, 2002. p.281-288.
- TANG, J. et al. *Arnetminer: extraction and mining of academic social networks*. In Proceeding of the 14th ACM SIGKDD international conference on Knowledge discovery and data mining, KDD '08, pages 990–998, New York, USA. ACM. 47, 51, 2008.
- TARUS, J., NIU, Z., KHADIDJA, B. *E-learning Recommender System Based on Collaborative Filtering and Ontology*. World Academy of Science, Engineering and Technology International Journal of Computer and Information Engineering Vol:11, No:2, 2017.
- TORRES, R. *Combining Collaborative and Content-based Filtering to recommend Research Papers*. 2004. Dissertação (Mestrado em Ciência da Computação) — PPGC/UFRGS. Disponível em: <<http://www.lume.ufrgs.br/handle/10183/5887>>. Acesso em: Fevereiro de 2018.
- YAN, Z.; CHEN, Y.; SHEN, Y.. *PerContRep: a practical reputation system for pervasive content services*. Springer Science+Business Media New York 2014. Disponível em: < DOI 10.1007/s11227-014-1116-y>. Acesso em agosto de 2018.
- WILEY, David A. *Connecting learning objects to instructional design theory: a definition, a metaphor, and a taxonomy*. 2001. Disponível em: <<http://reusability.org/read/chapters/wiley.doc>>. Acesso em: julho de 2018.

APÊNDICE A – ARQUITETURA E-RECREP

O MOODLE tem em seu banco uma série de tabelas que são usadas para armazenar dados de cursos, disciplinas, usuários, OAs, dentre outras. Para implementação da arquitetura e-RecRep no ambiente virtual MOODLE, foram necessárias a criação de tabelas adicionais no banco de dados do MOODLE, conforme Figura A.1.

Figura A.1 – Estrutura das tabelas



Fonte: Autoria própria