

O objetivo deste trabalho é propor e avaliar um Modelo de Recomendação Social de Sessões para Eventos Científicos (MRSSEC), flexível e aplicável para qualquer tipo de evento científico. A aplicação do modelo foi avaliada por meio de questionário e análise dos dados de uso, pelos quais foi possível obter a percepção dos usuários que consideraram as recomendações de sessões relevantes. Portanto, tem-se como resultado um modelo que, por meio de elementos sociais, fornece recomendações relevantes para o usuário e pode ser utilizado em conjunto com outras abordagens para alavancar as recomendações.

Orientador: Isabela Gasparini

Coorientador: Roberto Pereira

ANO 2019

ALINE DE PAULA A. TRAMONTIN

UM MODELO DE RECOMENDAÇÃO SOCIAL DE SESSÕES DE APRESENTAÇÕES PARA EVENTOS CIENTÍFICOS



**UNIVERSIDADE DO ESTADO DE SANTA CATARINA – UDESC**  
**CENTRO DE CIÊNCIAS TECNOLÓGICAS – CCT**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO**  
**APLICADA – PPGCA**

DISSERTAÇÃO DE MESTRADO

**UM MODELO DE RECOMENDAÇÃO SOCIAL DE  
SESSÕES DE APRESENTAÇÕES PARA EVENTOS  
CIENTÍFICOS**

ALINE DE PAULA ARAÚJO TRAMONTIN

JOINVILLE, 2019

**ALINE DE PAULA ARAÚJO TRAMONTIN**

**UM MODELO DE RECOMENDAÇÃO SOCIAL DE SESSÕES DE  
APRESENTAÇÕES PARA EVENTOS CIENTÍFICOS**

Dissertação apresentada ao Programa de Pós-Graduação em Computação Aplicada da Universidade do Estado de Santa Catarina como requisito parcial para a obtenção do título de Mestre.

Orientadora: Prof<sup>ª</sup>. Dra. Isabela Gasparini  
Coorientador: Prof. Dr. Roberto Pereira

**JOINVILLE, SC  
2019**

Tramontin, Aline de Paula Araújo  
UM MODELO DE RECOMENDAÇÃO SOCIAL DE  
SESSÕES DE APRESENTAÇÕES PARA EVENTOS  
CIENTÍFICOS / Aline de Paula Araújo Tramontin. -- 2019.  
108 p.

Orientadora: Isabela Gasparini  
Coorientador: Roberto Pereira

Dissertação (mestrado) -- Universidade do Estado de Santa  
Catarina, Centro de Ciências Tecnológicas, Programa de  
Pós-Graduação em Computação Aplicada, Joinville, 2019.

1. Sistemas de Recomendações. 2. Social. 3. Eventos  
Científicos. 4. Modelo. I. Gasparini, Isabela . II. Pereira, Roberto.  
III. Universidade do Estado de Santa Catarina, Centro de Ciências  
Tecnológicas, Programa de Pós-Graduação em Computação  
Aplicada. IV. Título.

**Um Modelo de Recomendação Social de Sessões de Apresentações para  
Eventos Científicos**

por

**Aline de Paula Araujo Tramontin**

Esta dissertação foi julgada adequada para obtenção do título de

**Mestra em Computação Aplicada**

Área de concentração em "Ciência da Computação",  
e aprovada em sua forma final pelo

**CURSO DE MESTRADO ACADÊMICO EM COMPUTAÇÃO APLICADA  
DO CENTRO DE CIÊNCIAS TECNOLÓGICAS DA  
UNIVERSIDADE DO ESTADO DE SANTA CATARINA.**




Profa. Dra. Isabela Gasparini  
CCT/UDESC  
Orientadora/Presidente



Profa. Dra. Rebeca Schroeder Freitas  
CCT/UDESC  
Membro da Banca Examinadora



Prof. Dr. Roberto Pereira  
UFPR (Coorientador)  
Membro da Banca Examinadora



Prof. Dr. Daniel Lichtnow  
UFSM  
Membro da Banca Examinadora

**Joinville, SC, 11 de julho de 2019.**

Para meu amado pai e grande incentivador, Dirceu José de Paula Araújo

05/03/1962 – 13/03/2019

Em breve, na eternidade, nos reuniremos novamente em família!

Descanse em paz

## RESUMO

Eventos científicos promovem a reunião de pesquisadores para a divulgação de seus trabalhos à comunidade científica. Esses eventos são dinâmicos, as sessões podem acontecer simultaneamente e, nesses casos, os participantes podem ter dificuldade de escolher quais sessões participar. Sistemas de Recomendação podem auxiliar o participante nessa escolha, pois utilizam informações das sessões, dos participantes e informações sobre as relações sociais dos participantes. Entretanto, o domínio de eventos científicos apresenta particularidades que precisam ser consideradas ao oferecer recomendações relevantes, como a necessidade de considerar tanto questões do perfil do participante quanto dos laços sociais já estabelecidos. Nestes eventos, escolher as sessões mais relevantes se torna uma tarefa difícil devido à quantidade de sessões para escolher em um curto período de tempo. As sessões podem ocorrer simultaneamente, os participantes estão se movendo, participando de diferentes apresentações em diferentes ambientes e horários. As sessões são inéditas, portanto, não existe histórico de participações ou de avaliações e, nesse caso, abordagens tradicionais de Sistemas de Recomendação necessitam de tais dados. O objetivo deste trabalho é propor e avaliar um Modelo de Recomendação Social de Sessões para Eventos Científicos (MRSSEC), flexível e aplicável para qualquer tipo de evento científico. O modelo foi implementado e aplicado nas edições 2017 e 2018 do Simpósio Brasileiro sobre Fatores Humanos em Sistemas Computacionais (IHC), considerando relacionamentos do usuário alvo e a similaridade entre os participantes do evento. A aplicação do modelo foi avaliada por meio de questionário e análise dos dados de uso, pelos quais foi possível obter a percepção dos usuários que consideraram as recomendações de sessões relevantes. Portanto, tem-se como resultado um modelo que, por meio de elementos sociais, fornece recomendações relevantes para o usuário e pode ser utilizado em conjunto com outras abordagens para alavancar as recomendações.

**Palavras-chave:** Sistemas de Recomendações, Social, Eventos Científicos, Modelo.

## ABSTRACT

Scientific events promote the meeting of researchers for the dissemination of their work to the scientific community. These events are dynamic, sessions can happen simultaneously and participants may have difficulty choosing which sessions to attend. Recommender Systems can assist the participant to select sessions because they use information from the sessions, from the participants and as well as information about the participants' social relationships. However, the domain of scientific events presents particularities that need to be considered when offering relevant recommendations, such as the need to consider both participants profile and their established social ties. In these events, choosing the most relevant sessions becomes a difficult task due to the amount of sessions to select in a period of interval. Sessions can occur simultaneously, participants are moving, participating in different presentations in different environments and schedules. Papers are unpublished, so there is no history of participation or evaluation, and in this case, traditional approaches to Recommender Systems require this data. The purpose of this work is to propose and evaluate a Social Recommendations Session Model for Scientific Events (MRSSEC), flexible and applicable to any type of scientific event. The model was implemented and applied in the 2017 and 2018 editions of the Brazilian Symposium on Human Factors in Computing Systems (IHC), considering target user relationships and similarity among the participants of the event. The application of the model was evaluated by means of a survey and analysis of the use data, through which it was possible to obtain the perception of the users who considered the recommendations of relevant sessions. The result is a model that, through social elements, provides recommendations relevant to the user and can be used together with other approaches to leverage recommendations.

**Keywords:** Recommender Systems, Scientific Events, Social, Model.

## LISTA DE FIGURAS

Figura 1 – O MRSSEC .....	50
Figura 2 - Processo de Busca por Sessões dos Relacionamentos do Usuário Alvo .....	54
Figura 3 - Representação da Força do Laço na Rede de Coautoria .....	66
Figura 4 – Dados de Coautoria do Participante no formato JSON .....	67
Figura 5 - Identificação do Usuário no AppIHC .....	68
Figura 6 - Ícone Social e Recomendação Social .....	69
Figura 7 – Tela de Autores para seguir no AppIHC 2018 .....	72
Figura 8 – Dados de Coautoria Armazenados ao Perfil do Usuário no <i>Firebase</i> .....	73
Figura 9 – Tópicos de Interesse no APPIHC 2018 .....	74
Figura 10 – Tela do Menu no AppIHC2018 .....	75
Figura 11 – Tela de Recomendados no AppIHC2018 .....	76
Figura 12 – Apresentação da Recomendação no arquivo PDF .....	77



## LISTA DE QUADROS

Quadro 1 - Processo de Seleção.....	38
Quadro 2 - Comparação dos trabalhos relacionados com MRSSEC.....	45
Quadro 3 – Lista <i>top</i> -N de Usuários Similares e Sessões favoritas.....	56
Quadro 4 – Exemplo das Listas de Sessões a serem Recomendadas .....	57
Quadro 5 – Cenário de Uso 1 .....	59
Quadro 6 – Cenário de Uso 2 .....	60
Quadro 7 – Cenário de Uso 3 .....	61
Quadro 8 – Cenário de Uso 4 .....	61
Quadro 9 – Cenário de Uso 5 .....	62
Quadro 10 – Cenário de Uso 6 .....	62
Quadro 11 – Cenário de Uso 7 .....	63
Quadro 12 – Cenário de Uso 8 .....	63
Quadro 13 – Questões Fechadas.....	70

## LISTA DE TABELAS

Tabela 1 – Prioridade dos Critérios Sociais.....	57
Tabela 2 – Possíveis Combinações do MRSSEC em Cenários de Uso.....	58
Tabela 3 – Componentes do MRSSEC IHC 2017.....	65
Tabela 4 – Componentes do MRSSEC IHC 2018.....	71
Tabela 5 – Quantidade de Respostas do Questionário.....	78
Tabela 6 – Formação Acadêmica dos Participantes .....	79
Tabela 7 – Motivos pelo qual Considera a Recomendação Relevante .....	80
Tabela 8 – Coautoria Resp. à “Você assistiu a alguma das sessões recomendadas?” ..	81
Tabela 9 - Motivos pelo qual Considera a Recomendação Relevante.....	82
Tabela 10 - Aut. Cog. Resp. à “Você assistiu a alguma das sessões recomendadas?” ..	83
Tabela 11 - Motivos pelo qual Considera a Recomendação Relevante.....	84
Tabela 12 – Fav. do Usu. Sim. Resp. à “Você assistiu das sessões recomendadas?” ..	87
Tabela 13 – Sugestões de Elementos para Rec. Sessões em Eventos Científicos .....	91

## LISTA DE GRÁFICOS

Gráfico 1 - Elementos Sociais .....	40
Gráfico 2 – Relevância das Recomendações por Coautoria .....	80
Gráfico 3 – Relevância das Recomendações por Autoridade Cognitiva .....	82
Gráfico 4 - Relevância das Recomendações por Favoritos do Usuário Similar .....	84
Gráfico 5 – Relevância de Todas as Recomendações .....	87
Gráfico 6 – Relevância das Recomendações por Tipo de Recomendação .....	88
Gráfico 7 - Relevância de cada Tipo de Recomendação por Participante .....	89
Gráfico 8 – Quantidade de Sessões Favoritadas x Favoritadas e Recomendadas .....	90

## LISTA DE ABREVIATURAS E SIGLAS

AACE	<i>Association for the Advancement of Computing in Education</i>
BPR-MF	<i>Bayesian Personalized Ranking - Matrix Factorization-Based</i>
BPR-NET	<i>Bayesian Personalized Ranking Network-Based</i>
CAMRS	<i>Context-Aware Mobile Recommender Services</i>
EBSN	<i>Event Based Social Networks</i>
EC-TEL	<i>European Conference on Technology-Enhanced Learning</i>
FC	Filtragem Colaborativa
ICWL	<i>International Conference on Web-based Learning</i>
IHC	Simpósio Brasileiro sobre Fatores Humanos em Sistemas Computacionais
JSON	<i>JavaScript Object Notation</i>
MCLRE	<i>Multi-Contextual Learning to Rank Events</i>
MRSSEC	Modelo de Recomendação Social de Sessões para Eventos Científicos
MP	<i>Most Popular</i>
PHP	<i>Hypertext Preprocessor</i>
SARVE	<i>Social Aware Recommendation of Venues and Environments</i>
SNA	<i>Social Network Analysis</i>
SR	Sistema de Recomendação
TF-IDF	<i>Term-Frequency Inverse-Document-Frequency</i>
UDESC	Universidade do Estado de Santa Catarina

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>14</b>
1.1	PROBLEMA .....	15
1.2	OBJETIVOS.....	15
1.2.1	Objetivo Geral .....	15
1.2.2	Objetivos Específicos.....	15
1.3	ESCOPO.....	16
1.4	METODOLOGIA .....	17
1.5	ESTRUTURA .....	17
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA.....</b>	<b>18</b>
2.1	EVENTOS CIENTÍFICOS .....	18
2.2	SISTEMAS DE RECOMENDAÇÃO .....	19
2.2.1	Filtragem Colaborativa.....	19
2.2.2	Abordagem Baseada em Conteúdo.....	21
2.2.3	Abordagem Baseada em Conhecimento .....	23
2.2.4	Abordagem Híbrida .....	24
2.3	SISTEMAS DE RECOMENDAÇÃO SENSÍVEIS AO CONTEXTO .....	26
2.4	SISTEMAS DE RECOMENDAÇÃO SOCIAL .....	27
2.4.1	Recomendação Social Baseada em <i>Links</i> Explícitos.....	27
2.4.2	Recomendação Social Centrada na Confiança .....	28
2.4.3	Abordagens de Recomendação Social e Elementos Sociais .....	29
2.4.4	Recomendação Social Baseada em <i>Links</i> Implícitos .....	30
2.5	AValiação DE SISTEMAS DE RECOMENDAÇÃO .....	30
2.6	ANÁLISE DE REDES SOCIAIS .....	32
2.7	AUTORIDADE COGNITIVA .....	34
2.8	CONSIDERAÇÕES DO CAPÍTULO .....	35
<b>3</b>	<b>MAPEAMENTO SISTEMÁTICO DE LITERATURA .....</b>	<b>36</b>
3.1	PROCESSO DO MAPEAMENTO.....	36
3.1.1	Definição das Questões de Pesquisa .....	36
3.1.2	Processo de Busca .....	37
3.1.3	Processo de Seleção.....	37
3.2	RESULTADOS E ANÁLISES .....	38
3.2.1	Domínio de Aplicação.....	38
3.2.2	Abordagens .....	39
3.2.3	Elementos Sociais.....	39

3.2.4	Avaliação .....	40
3.3	DISCUSSÃO.....	41
3.4	CONSIDERAÇÕES DO CAPÍTULO .....	42
<b>4</b>	<b>TRABALHOS RELACIONADOS .....</b>	<b>43</b>
4.1	CONSIDERAÇÕES DO CAPÍTULO .....	49
<b>5</b>	<b>MODELO DE RECOMENDAÇÃO SOCIAL .....</b>	<b>50</b>
5.1	MRSSEC .....	50
5.2	COMPONENTES ESSENCIAIS.....	51
5.2.1	Usuário.....	51
5.2.2	Sessões.....	52
5.2.3	Rede Social .....	52
5.3	RELACIONAMENTO.....	53
5.3.1	Força do Laço .....	53
5.3.2	Autoridade Cognitiva .....	54
5.4	FAVORITAS DO USUÁRIO SIMILAR .....	55
5.5	LOCALIZAÇÃO .....	56
5.6	COMPOSIÇÃO DOS RESULTADOS.....	56
5.7	CENÁRIOS DE USO.....	58
5.7.1	Cenário de Uso 1 .....	58
5.7.2	Cenário de Uso 2.....	60
5.7.3	Cenário de Uso 3.....	60
5.7.4	Cenário de Uso 4.....	61
5.7.5	Cenário de Uso 5.....	61
5.7.6	Cenário de Uso 6.....	62
5.7.7	Cenário de Uso 7 .....	62
5.7.8	Cenário de Uso 8.....	63
5.8	CONSIDERAÇÕES DO CAPÍTULO .....	64
<b>6</b>	<b>APLICAÇÃO DO MRSSEC .....</b>	<b>65</b>
6.1	IHC 2017 .....	65
6.1.1	Planejamento.....	65
6.1.2	Implementação.....	66
6.1.3	Teste Piloto .....	68
6.1.4	Execução .....	68
6.1.5	Análise .....	69
6.2	IHC 2018.....	71
6.2.1	Planejamento.....	71
6.2.2	Implementação.....	72

6.2.3	Apresentação da Recomendação.....	74
6.2.4	Execução.....	76
6.2.5	Análises.....	78
6.3	SUGESTÕES .....	91
6.4	DISCUSSÃO.....	91
6.5	LIMITAÇÕES E AMEAÇAS A VALIDADE DO EXPERIMENTO .....	93
7	CONSIDERAÇÕES FINAIS.....	95
	REFERÊNCIAS .....	98
	APÊNDICE – QUESTIONÁRIO DE AVALIAÇÃO DA RECOMENDAÇÃO ..	105

## 1 INTRODUÇÃO

Um evento pode ser considerado um “acontecimento”, que tem como característica proporcionar o encontro entre pessoas, com finalidade específica, a qual constitui o tema principal do evento e justifica sua realização (PASCOAL, 2014). Segundo Severino (2017) os eventos científicos podem ser definidos como uma reunião de pessoas interessadas em uma determinada área do conhecimento, ou da cultura, que se propõem a apresentar e debater ideias sobre temas específicos, durante um período de tempo determinado.

Eventos científicos reúnem pesquisadores, estudantes e outros interessados, e são compostos por diferentes tipos de sessões. Diversos temas são abordados, sendo estes um subconjunto de uma grande área de estudo, e cada sessão pode conter apresentações relacionadas a temas dessa grande área. Um dos objetivos para a participação em um evento científico é aumentar as redes de colaboração acadêmica. Nestes eventos os atores são pesquisadores, as relações são colaborações, e os organizadores são membros do comitê do programa (LICAMELE; GETOOR, 2006). Além da apresentação de trabalhos de pesquisa, eventos acadêmicos visam também conectar pesquisadores e promover potenciais colaborações (PHAM *et al.*, 2012). Recomendar sessões de um evento se torna importante devido à quantidade de opções disponíveis e a frequência em que uma pessoa tem que fazer escolhas (PASCOAL, 2014). Geralmente, em eventos científicos existem sessões ocorrendo simultaneamente, o que dificulta o processo de escolha do participante.

Sistemas de Recomendação (SRs) estão cada vez mais presentes no cotidiano das pessoas. A crescente facilidade de acesso à informação por meio de diferentes tipos de dispositivos (e.g. *smartphone*, *smarttv*, *tablet*, *desktop*, *laptop*) permite que os usuários sejam protagonistas criando seus próprios conteúdos digitais em sites de mídias sociais, além de outros tipos de sistemas que produzem dados que precisam ser tratados e processados, gerando, assim, uma sobrecarga de informação. Essa sobrecarga dificulta a escolha e o acesso à determinada informação julgada relevante pelo usuário. Nesse momento, SRs têm um papel fundamental: ajudar o usuário a encontrar itens de sua preferência rapidamente. Um dos objetivos destes sistemas é, por meio de diferentes técnicas, apresentar sugestões de itens que estão comumente relacionados ao processo de tomada de decisão como: Qual livro comprar? Qual filme assistir? Qual restaurante escolher?

No entanto, existem problemas inerentes a SRs independente de domínio: a escassez de avaliações e o *cold start*. A escassez de avaliações ocorre quando a quantidade de itens avaliados é muito menor do que a de itens disponíveis no sistema, tornando difícil identificar



as semelhanças entre as pessoas. O problema do *cold start* ocorre quando um novo usuário ou um novo item é introduzido no sistema, pois não há avaliações sobre o item ou não há itens avaliados pelo usuário e, dessa forma, não é possível recomendar itens nem encontrar usuários semelhantes. No caso de SRs para eventos científicos, os problemas acima são agravados devido ao curto período de tempo em que um evento existe e a falta de histórico de participações e avaliações. Nas redes sociais é possível obter dados do usuário alvo, com devido consentimento, por meio dos relacionamentos e das interações, que podem ser utilizados por SRs como alternativa ao processo de recomendação tradicional, minimizando os problemas existentes.

## 1.1 PROBLEMA

Em eventos científicos, independente do porte ou tamanho, novos trabalhos são apresentados à comunidade acadêmica e, pode existir pouco ou nenhum histórico de participações do usuário (*cold start*). Escolher as sessões mais relevantes se torna uma tarefa difícil devido à quantidade de sessões para escolher em um curto período de tempo. As sessões podem ocorrer simultaneamente, os participantes estão se movendo, participando de diferentes apresentações em diferentes ambientes e horários. SRs auxiliam na escolha de quais sessões assistir, pois utilizam dados sobre o participante, sobre as sessões (itens) e dados sociais também podem ser utilizados no processo de recomendação. A pergunta norteadora para o problema de pesquisa é: O uso de elementos sociais no processo de recomendação de sessões pode gerar recomendações relevantes para os participantes de um evento científico?

## 1.2 OBJETIVOS

Foram definidos objetivo geral e objetivos específicos para orientar o processo de pesquisa desta dissertação.

### 1.2.1 Objetivo Geral

O objetivo geral desta dissertação é propor um Modelo de Recomendação Social de Sessões para Eventos Científicos.

### 1.2.2 Objetivos Específicos

- Identificar na literatura abordagens de SR adequadas ao domínio de eventos científicos;

- Compreender o estado da arte de SRs Social e identificar os elementos sociais utilizados no processo de recomendação;
- Propor um modelo de recomendação social adaptável a diferentes eventos científicos;
- Desenvolver o modelo de recomendação proposto;
- Analisar a capacidade de aplicação do modelo em cenários reais no projeto de sistemas de recomendação;
- Avaliar, com o público-alvo, a relevância das recomendações geradas pela implementação do modelo proposto e seu uso em um cenário real.

### 1.3 ESCOPO

Esta dissertação propõe um Modelo de Recomendação Social de Sessões para Eventos Científicos (MRSSEC). A proposta considera relacionamentos sociais e conecta os usuários participantes do evento em uma rede social local implícita. Os relacionamentos são extraídos de redes ou base de dados sociais por meio dos dados do usuário e são indicados pelo próprio usuário. A rede social implícita, no local do evento, possibilita encontrar usuários similares a ele.

O MRSSEC busca ser um modelo flexível para recomendações sociais no contexto de eventos científicos ou acadêmicos, sendo que a validação e adaptação para outros contextos não são exploradas no escopo desta pesquisa.

O MRSSEC foi aplicado em duas edições do Simpósio Brasileiro sobre Fatores Humanos em Sistemas Computacionais (IHC), em 2017 e 2018. A recomendação foi apresentada por meio de um aplicativo desenvolvido para apoiar os participantes do evento, o AppIHC (SOHN, 2017). Em ambos os experimentos, para prover os relacionamentos sociais, a base de dados de publicações de artigos completos do IHC no Brasil foi utilizada.

As análises apresentadas têm como propósito avaliar a percepção do usuário em relação à relevância da recomendação de sessões gerada por meio da aplicação do MRSSEC em um evento científico de pequeno porte. Não foram realizadas comparações com outros modelos ou abordagens, estando o foco das análises na avaliação da aplicação do modelo em um contexto específico e bem definido. Avaliar a apresentação da recomendação ou a experiência do usuário em relação ao aplicativo não faz parte do escopo deste trabalho e constituem espaço para trabalhos futuros.

## 1.4 METODOLOGIA

Esta dissertação é classificada como pesquisa exploratória e possui natureza aplicada, sendo caracterizada como um trabalho de desenvolvimento experimental, pois busca gerar conhecimentos por meio do desenvolvimento e experimentação do MRSSEC em um ambiente real de uso. A abordagem do problema deste trabalho é qualitativa, os dados serão coletados por meio de questionários com questões abertas e fechadas e triangulados por meio de dados de uso capturados automaticamente. Os objetivos dessa pesquisa têm caráter explicativo, visando compreender os fenômenos explorados a partir da perspectiva dos participantes, identificando a percepção dos usuários sobre a relevância das recomendações.

## 1.5 ESTRUTURA

Esta dissertação está dividida em 7 capítulos. No Capítulo 2 são explorados os conceitos utilizados no desenvolvimento da pesquisa, tais como as definições de eventos Científicos, SRs, Análise de Redes Sociais e Autoridade Cognitiva. No Capítulo 3 são apresentados os resultados do mapeamento sistemático realizado com o propósito de conhecer o estado da arte e entender o uso de elementos sociais no processo de recomendação. O Capítulo 4 apresenta os trabalhos relacionados ao tema da pesquisa, assim como trabalhos em que a principal avaliação da recomendação é realizada pelo usuário. No Capítulo 5, o MRSSEC é apresentado e, no Capítulo 6 são apresentados os experimentos realizados a partir da aplicação do modelo. O Capítulo 7 traz as conclusões da pesquisa e direcionamentos para trabalhos futuros.

## 2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentados os fundamentos teóricos que embasam o modelo proposto nesta dissertação. As principais técnicas de SRs são apresentadas, seguidas de Sistemas de Recomendação Sensível ao Contexto e de Sistema de Recomendação Social. Neste capítulo também são apresentados fundamentos sobre Avaliação de SR, Análise de Redes Sociais e Autoridade Cognitiva.

### 2.1 EVENTOS CIENTÍFICOS

Os eventos científicos são formas eficientes de comunicação e divulgação de novos conhecimentos, pois permitem expor ideias já iniciadas em um projeto de pesquisa para um público maior e, assim, obter avaliação e apreciação prévia (MARCHIORI *et al.*, 2006; SCHMIDT; OHIRA, 2002). Eventos científicos “assumem um papel de grande importância no processo da comunicação científica na medida em que a transmissão de ideias e fatos novos chega ao conhecimento da comunidade científica de maneira mais rápida que aquelas veiculadas pelos meios formais de comunicação” (DE LACERDA *et al.*, 2008).

Na perspectiva social, participar de eventos é um meio de fazer novas conexões. Para Burt (2001), a sociedade pode ser vista como um mercado em que as pessoas trocam toda a variedade de bens e ideias em busca de seus interesses. Algumas pessoas, ou grupos de pessoas, melhoram no sentido de receber maiores retornos aos seus esforços, e um dos principais objetivos de uma participação em evento é aumentar o capital social de alguém, ou seja, o investimento na relação com os retornos esperados (LIN; COOK; BURT, 2001). O capital social é o complemento contextual do capital humano. A metáfora do capital social diz que as pessoas que prosperam estão de alguma forma melhor conectadas. A participação em eventos científicos também contribui para as relações sociais, pois visam conectar pesquisadores e promover potenciais colaborações, aumentando sua rede de colaboração acadêmica (PHAM *et al.*, 2012).

As sessões de apresentações em eventos científicos podem ocorrer simultaneamente e fazer a melhor escolha, dentre as diversas opções de sessões, pode não ser uma tarefa fácil. Portanto, a recomendação de sessões de um evento científico se torna importante para auxiliar o participante na decisão de qual sessão assistir (PASCOAL, 2014).

## 2.2 SISTEMAS DE RECOMENDAÇÃO

Um SR é desenvolvido para ajudar o usuário a encontrar itens de sua preferência rapidamente, filtrando itens de acordo com o perfil do usuário e evitando a sobrecarga de informação. Normalmente, um SR se concentra em um tipo específico de item e o *design*, a interface gráfica do usuário e a técnica de recomendação usada para gerar as recomendações são todas personalizadas para fornecer sugestões úteis e efetivas desse tipo de item (RICCI; ROKACH; SHAPIRA, 2015). Os itens recomendados por SRs podem ser filmes, músicas, livros, notícias, relacionamentos, conteúdos, imagens, entre outros.

A partir dos anos 90, SRs tornaram-se uma área de pesquisa importante com os primeiros trabalhos publicados na área de filtragem colaborativa. O *GroupLens*, grupo acadêmico da Universidade de Minnnesota, foi pioneiro no desenvolvimento de um sistema de recomendação de notícias e a *Amazon* foi uma das pioneiras em sistemas de recomendação no comércio eletrônico, com o objetivo principal de aumentar as vendas (ADOMAVICIUS; TUZHILIN, 2005; AGGARWAL, 2016).

A pesquisa em SR tem origem nas áreas de Recuperação da Informação e Filtragem de Informação. Nestas áreas, no entanto, o foco reside principalmente no problema de discriminação entre documentos relevantes e irrelevantes (ADOMAVICIUS; TUZHILIN, 2005).

Os modelos básicos de SRs trabalham com dois tipos de dados, que são: (a) a interação dos usuários, e (b) a informação atribuída sobre os usuários e sobre os itens. Estes métodos são denominados respectivamente de Filtragem Colaborativa e Baseado em Conteúdo. Atualmente, existem quatro abordagens principais para SRs: Baseada em Conteúdo, Filtragem Colaborativa (FC), Baseada em Conhecimento e Híbrida.

### 2.2.1 Filtragem Colaborativa

Abordagens de recomendação do tipo FC exploram informações sobre o comportamento passado ou opiniões de uma comunidade de usuários existente para prever quais itens o usuário atual do sistema provavelmente gostará ou terá interesse. Ao longo dos anos, vários algoritmos e técnicas foram propostos e avaliados com sucesso em dados de testes reais e artificiais. As abordagens colaborativas tomam uma matriz de avaliações de usuário-item dadas como a entrada e normalmente produzem os seguintes tipos de saída: (a) uma predição (numérica) indicando em que grau o usuário atual irá gostar ou não de

determinado item e (b) uma lista de  $n$  itens recomendados. Essa lista *top-N*, não deve conter itens que o usuário atual já tenha (JANNACH *et al.*, 2010).

Para estabelecer recomendações, os sistemas de FC precisam relacionar duas entidades fundamentalmente diferentes: itens e usuários. Existem duas abordagens principais para facilitar essa comparação, que constituem as duas principais técnicas da FC: a abordagem da vizinhança, também denominada *memory-based* e os modelos de fatores latentes, conhecidos também como *model-based* (KOREN; BELL, 2015).

A técnica *memory-based* baseada no usuário tem a seguinte ideia principal: dado um banco de dados de classificações e o identificador (ID) do usuário atual (alvo) como uma entrada, identifique outros usuários que tenham preferências semelhantes àsquelas do usuário alvo. Então, para cada produto  $p$  que o usuário alvo ainda não tenha visto, uma previsão é calculada com base nas avaliações de  $p$  feitas pelos usuários pares. As suposições de tais métodos são que (i) se os usuários tiveram gostos semelhantes no passado, eles terão gostos semelhantes no futuro e (ii) as preferências do usuário permanecem estáveis e consistentes ao longo do tempo. A métrica de similaridade mais comumente utilizada em FC baseada no usuário é o coeficiente de correlação de *Pearson*. Este coeficiente mede a força entre duas variáveis, ou seja, a correlação entre o usuário alvo e um determinado usuário, e a similaridade é calculada apenas com itens que os dois usuários avaliaram (JANNACH *et al.*, 2010). A fórmula para o cálculo do coeficiente de correlação de *Pearson* é dada como (TORRES, 2004):

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

Na fórmula,  $w_{a,u}$  representa a correlação entre o usuário  $u$  e um determinado usuário  $a$ , onde:  $r_{a,i}$  é a avaliação do usuário  $a$  para o item  $i$ ;  $\bar{r}_a$  é a média de todas as avaliações do usuário  $a$ ;  $r_{u,i}$  é a avaliação do usuário  $u$  para o item  $i$ ;  $\bar{r}_u$  é a média de todas as avaliações do usuário  $u$ .

Embora as abordagens de FC baseadas no usuário tenham sido aplicadas com êxito em diferentes domínios, alguns desafios permanecem ao trabalhar com grande quantidade de dados como é o caso de sites de comércio eletrônico, onde é necessário lidar com milhões de usuários e milhões de itens. A necessidade de varrer um grande número de potenciais vizinhos torna impossível calcular previsões em tempo real.

Nos métodos baseados em modelos (*model-based* - fatores latentes), os dados brutos são processados *off-line* e um modelo resumido dos dados é criado primeiro. O treinamento (ou fase de modelagem) é claramente separado da fase de previsão (AGGARWAL, 2015). Em

tempo de execução, somente o modelo pré-computado ou “aprendido” é necessário para fazer previsões.

Embora as abordagens baseadas em vizinhança sejam teoricamente mais precisas, pois dados completos estão disponíveis para gerar recomendações, tais sistemas enfrentam problemas de escalabilidade em relação a bancos de dados de dezenas de milhões de usuários e milhões de itens (JANNACH *et al.*, 2010).

A abordagem FC considera as avaliações ou notas atribuídas pelos usuários, dessa forma as recomendações podem ser interessantes e inesperadas, porém existem desvantagens em relação a esparsidade, ou seja, quanto maior o número de itens e de usuários, mais esparsa ficará a tabela com as notas dos usuários e mais difícil será realizar as comparações. Existe também o problema do *cold start* tanto para um novo usuário quanto para um novo item no sistema, pois não há avaliações sobre o item ou não há itens avaliados pelo usuário. Dessa forma não é possível recomendar itens nem encontrar usuários semelhantes, ou seja, não há avaliações suficientes para gerar recomendações, para isso é necessário ter uma grande quantidade de usuários alvos no sistema (ADOMAVICIUS; TUZHILIN, 2005).

### 2.2.2 Abordagem Baseada em Conteúdo

Em abordagens Baseadas em Conteúdo as avaliações e o comportamento dos usuários são combinados com a informação de conteúdo disponível sobre o item. O termo “conteúdo” refere-se à descrição dos atributos dos itens usados para fazer as recomendações, ou seja, quando o item é um filme a descrição contém palavras chaves semelhantes com as de outro filme do mesmo gênero.

No aprendizado baseado em conteúdo de perfis de usuário (*off-line*), um modelo do usuário é criado e aprimorado com base em seu histórico de itens ou avaliações, e o *feedback* do usuário é coletado na forma de avaliações previamente especificadas (*feedback* explícito) ou atividade do usuário (*feedback* implícito). O modelo resultante é conhecido como o perfil do usuário, pois relaciona conceitualmente os interesses dos usuários (avaliações) com os atributos do item, a fim de realizar uma previsão (*on-line*) de itens que sejam atraentes para o usuário. As partes *offline* são usadas para criar um modelo resumido, que geralmente é um modelo de classificação ou regressão. Este modelo é usado para a geração *on-line* de recomendações. Por fim, ocorrem a filtragem e a recomendação, nesta etapa o modelo aprendido é usado para fazer recomendações sobre itens para usuários específicos (AGGARWAL, 2016).

Para fazer recomendações, sistemas baseados em conteúdo avaliam quão fortemente um item não visitado é similar aos itens que o usuário alvo gostou no passado. A semelhança pode ser medida de diferentes maneiras, por exemplo, dado um livro  $B$  não visto, o sistema poderia simplesmente verificar se o gênero do livro em questão está na lista dos gêneros preferidos do usuário alvo. Porém, dependendo do problema, várias medidas de similaridade são possíveis, tais como, o coeficiente de Sorensen-Dice (DICE, 1945) ou o cálculo do Cosseno (MANNING; RAGHAVAN, 2008; SALTON, 1964). A similaridade de cosseno é estabelecida como a métrica padrão, pois produz os resultados mais precisos. A fórmula para o cálculo da similaridade do Cosseno é definida como (ADOMAVICIUS, G; TUZHILIN, 2005):

$$sim(d_c, d_s) = \frac{\sum_{i=1}^k w_{i,c} w_{i,s}}{\sqrt{\sum_{i=1}^k w_{i,c}^2} \sqrt{\sum_{i=1}^k w_{i,s}^2}} \quad (2)$$

Onde:  $sim(d_c, d_s)$  é o resultado da distância dos vetores, variando de  $[0,1]$ ;  $w_{i,c}$  é o termo presente na posição  $i$  do item  $c$ ;  $w_{i,s}$  é o termo presente na posição  $i$  do item  $s$ .

Sistemas baseados em conteúdo foram desenvolvidos para filtrar e recomendar itens baseados em texto, como mensagens de e-mail ou notícias. A abordagem padrão na recomendação baseada em conteúdo é usar uma lista de palavras-chave relevantes que aparecem no documento. A ideia principal é que tal lista possa ser gerada automaticamente a partir do próprio conteúdo do documento.

Uma abordagem simples seria configurar uma lista de todas as palavras que aparecem em todos os documentos e descrever cada documento por um vetor *booleano*, no qual o valor 1 indica que uma palavra aparece em um documento e o valor 0 que a palavra não aparece. Se o perfil do usuário for descrito por uma lista semelhante (1 indicando interesse em uma palavra-chave), a correspondência de documentos pode ser feita medindo a sobreposição de interesse e conteúdo do documento. Porém, a abordagem *booleana* traz consigo alguns problemas, pois baseia-se no pressuposto de que cada palavra tem a mesma importância dentro de um documento. Além disso, uma sobreposição maior do perfil do usuário e um documento (item) serão naturalmente encontrados quando os documentos forem mais longos (JANNACH *et al.*, 2010).

Os documentos são geralmente descritos usando o formato de codificação TF-IDF (*Term-Frequency Inverse Document Frequency*) (SALTON, 1975), que é uma técnica estabelecida no campo da Recuperação da Informação utilizada para identificar termos importantes em um documento. A frequência do termo descreve a frequência com que um



determinado termo aparece em um documento (assumindo que as palavras importantes aparecem mais frequentemente).

Métodos baseados em conteúdo possuem desvantagens, como por exemplo, a do novo usuário, no qual avaliações suficientes devem ser coletadas antes que o sistema possa realmente entender as preferências do usuário e fornecer recomendações precisas. Outro problema comum desta abordagem é a superespecialização, ou seja, a tendência de sempre exibir mais do mesmo item (RICCI; ROKACH; SHAPIRA, 2011).

### **2.2.3 Abordagem Baseada em Conhecimento**

Os algoritmos de recomendação colaborativos e baseados em conteúdo podem ser usados em diferentes contextos. No entanto, existem situações nas quais tais abordagens não são a melhor escolha. Por exemplo, quando trata-se de itens que não são comprados com muita frequência, como por exemplo uma casa, um carro ou um computador. Em tal cenário, um sistema de FC não terá um bom desempenho devido ao baixo número de avaliações disponíveis (BURKE, 2000). Além disso, os intervalos de tempo desempenham um papel importante. Por exemplo, avaliações de cinco anos para computadores podem ser bastante inadequadas para recomendações baseadas em conteúdo. O mesmo vale para itens como carros ou casas, pois as preferências do usuário evoluem com o tempo. Em domínios de produtos mais complexos, como carros, os clientes muitas vezes desejam definir seus requisitos explicitamente.

A vantagem de sistemas baseados em conhecimento é que não existem problemas de *cold start*, porque nenhum dado de avaliação é necessário para o cálculo das recomendações. As recomendações são calculadas independentemente das avaliações de usuários individuais: na forma de semelhanças entre requisitos do cliente e itens ou com base em regras explícitas de recomendação. Em geral, os sistemas de recomendação baseados no conhecimento são apropriados nas seguintes situações: (1) os clientes desejam especificar explicitamente seus requisitos e, portanto, a interatividade é um componente crucial de tais sistemas; (2) é difícil obter avaliações para um tipo específico de item devido à maior complexidade do domínio do produto em termos dos tipos de itens e opções disponíveis; (3) em alguns domínios, como computadores, as avaliações podem ser sensíveis ao tempo (JANNACH *et al.*, 2010).

Uma importante característica distintiva dos sistemas baseados em conhecimento é um alto nível de customização para o domínio específico. Essa personalização é obtida por meio do uso de uma base de conhecimento que codifica o conhecimento de domínio relevante na forma de restrições ou métricas de similaridade (AGGARWAL, 2016).

Existem duas abordagens de sistemas de recomendação baseados no conhecimento que são: (a) baseados em restrições (FELFERNIG *et al.*, 2011; FELFERNIG; BURKE, 2008) e (b) sistemas baseados em casos (BRIDGE *et al.*, 2005). Ambas as abordagens são semelhantes em termos do processo de recomendação: o usuário deve especificar os requisitos e o sistema tenta identificar uma solução. Se nenhuma solução puder ser encontrada, o usuário deve alterar os requisitos.

Os SRs baseados em casos focam na recuperação de itens semelhantes, enquanto os SRs baseados em restrições confiam em um conjunto explicitamente definido de regras de recomendação. Em sistemas baseados em restrições, o conjunto de itens recomendados é determinado, por exemplo, pela pesquisa de um conjunto de itens que atendam às regras de recomendação. Os sistemas baseados em casos, por outro lado, usam métricas de similaridade para recuperar itens que são semelhantes (dentro de um limite predefinido) aos requisitos especificados pelo cliente (AGGARWAL, 2016; JANNACH *et al.*, 2010).

#### 2.2.4 Abordagem Híbrida

Um sistema híbrido combina diferentes técnicas, tais como as já mencionadas, e tenta usar as vantagens de uma para corrigir as desvantagens de outra. Do ponto de vista linguístico, o termo híbrido deriva do substantivo latino *hybrida* (de origem mista) e denota um objeto feito pela combinação de dois elementos diferentes. Analogamente, os sistemas de recomendação híbridos combinam várias implementações de algoritmos de recomendação (JANNACH *et al.*, 2010). Por exemplo, os métodos de FC sofrem de problemas de novos itens, isto é, eles não podem recomendar itens que não têm avaliações. Isso não limita as abordagens baseadas em conteúdo, já que a previsão para novos itens é baseada em suas descrições que normalmente estão facilmente disponíveis (RICCI; ROKACH; SHAPIRA, 2011).

Burke (2002) classifica os sistemas de recomendação híbridos nas seguintes categorias:

- (1) *Ponderada*: a pontuação de diferentes componentes de recomendação é combinada numericamente;
- (2) *Comutação*: o sistema escolhe entre os componentes de recomendação e aplica o selecionado.
- (3) *Misto*: recomendações de diferentes abordagens são apresentadas em conjunto.
- (4) *Combinação de Recursos*: recursos derivados de diferentes fontes de conhecimento são combinados em um único algoritmo de recomendação.

- (5) *Aumento de Recursos*: uma técnica de recomendação é usada para computar um recurso ou conjunto de recursos, que é, então, parte da entrada para a próxima técnica.
- (6) *Cascata*: os clientes recebem prioridade estrita, com os de menor prioridade quebrando os laços na pontuação dos mais altos.
- (7) *Meta-nível*: uma técnica de recomendação é aplicada e produz algum tipo de modelo, que é então a entrada usada pela próxima técnica.

Uma outra classificação é proposta por Aggarwal (2016) para a criação de sistemas de recomendação híbridos:

- (1) *Projeto Conjunto*: neste projeto, os resultados de algoritmos *off-the-shelf* são combinados em uma saída única e mais robusta. Por exemplo, pode-se combinar as saídas de classificação de um SR baseado em conteúdo e colaborativo em uma única saída.
- (2) *Projeto Monolítico*: neste caso, um algoritmo de recomendação integrado é criado usando vários tipos de dados. Uma distinção clara pode, às vezes, não existir entre as várias partes (por exemplo, conteúdo e colaboração) do algoritmo. Em outros casos, os algoritmos existentes de recomendação colaborativa ou baseada em conteúdo podem precisar ser modificados para serem usados na abordagem geral, mesmo quando houver distinções claras entre os estágios de conteúdo e de colaboração. Portanto, essa abordagem tende a integrar as várias fontes de dados com mais precisão, e não é possível visualizar facilmente componentes individuais;
- (3) *Sistemas Mistos*: assim como os conjuntos, esses sistemas usam vários algoritmos de recomendação, mas os itens recomendados pelos vários sistemas são apresentados juntos lado a lado. A principal característica dos sistemas de recomendação mista é que eles combinam as pontuações de diferentes componentes em termos de apresentação, em vez de combinar os escores previstos. Em muitos casos, os itens recomendados são apresentados próximos um do outro. Portanto, a principal característica distintiva de tais sistemas é a combinação de apresentação e não a combinação de pontuações previstas.

Sistemas híbridos permitem minimizar problemas específicos de certas abordagens. No entanto, determinar qual o melhor tipo de sistema híbrido depende de uma análise e dos diferentes domínios e condições (BURKE, 2002).

## 2.3 SISTEMAS DE RECOMENDAÇÃO SENSÍVEIS AO CONTEXTO

Incorporar informação contextual no processo de recomendação pode melhorar a qualidade da recomendação. O contexto da recomendação desempenha um papel crítico em diferentes domínios, e pode estar relacionado a diferentes tipos de elementos contextuais, tais como dados temporais, dados baseados em localização e dados sociais. Dessa forma, sistemas de recomendação passaram a considerar informações do contexto para melhorar a recomendação com base na situação do usuário. Ranganathan e Campbell (2003) descrevem o contexto como "qualquer informação sobre as circunstâncias, objetos ou condições em torno de um usuário que seja considerado relevante para a interação entre o usuário e o ambiente computacional ubíquo".

Dey (2001) diz que o contexto pode ser definido como “qualquer informação que pode ser usada para caracterizar a situação de uma entidade (uma pessoa, um lugar ou um objeto) que é considerada relevante para a interação entre o usuário e uma aplicação, incluindo o próprio usuário e a própria aplicação”. Schmidt *et al.* (1999) define algumas dimensões que fazem parte do contexto: localização (e.g., usuário em casa ou na universidade), tempo (e.g., se é dia de semana ou final de semana, quanto tempo o usuário tem disponível), condições físicas (e.g., barulho), infraestrutura (e.g., dispositivo, velocidade da internet), usuário (e.g., perfil, preferências), tarefa, ambiente social (e.g., outros usuários perto do usuário analisado).

O contexto adiciona informações à representação de um modelo de usuário com dados referentes a contextos físicos (por exemplo, localização, tempo), contextos ambientais (clima, luz e som), contextos informativos (cotações de ações, partidas esportivas), contextos pessoais (saúde, humor, agenda, atividade), contextos sociais (atividade grupal, atividade social), contextos de aplicativos (e-mails, sites visitados) e contextos de sistema (tráfego de rede, status das impressoras) (RANGANATHAN; CAMPBELL, 2003). Jiang *et al.* (2012) identificaram que a preferência individual e a influência interpessoal são fatores contextuais importantes para as recomendações sociais, pois afetam as decisões dos usuários sobre a retenção de informações.

O contexto social pode ser entendido como um caso especial de sistemas de recomendação sensíveis ao contexto. O cenário social resulta em vários fatores centrados no ser humano, como a confiança. Uma das formas possíveis de contexto é o contexto social no qual a informação social é usada para melhorar a eficácia do processo de recomendação. Por exemplo, a escolha do filme que um usuário pode assistir depende do acompanhante com quem ele escolhe assistir ao filme, ou seja, ele costuma escolher um filme diferente,

dependendo se está assistindo com seus amigos, pais, filhos ou outros. Tais recomendações podem ser tratadas diretamente no modelo multidimensional, incorporando o contexto social em algoritmos de FC (AGGARWAL, 2016).

## 2.4 SISTEMAS DE RECOMENDAÇÃO SOCIAL

A mídia social introduziu novos tipos de conteúdo que podem ser criados e compartilhados pelos usuários. Os usuários tornaram-se o centro de todos os sites de mídia social, pois têm um papel fundamental no fornecimento de *feedback* e anotação de conteúdo.

Votos e avaliações permitem que eles "curtam" (ou não gostem) de determinadas postagens. *Tags* permitem anotar o conteúdo com palavras-chave que refletem seu próprio ponto de vista. Esses novos tipos de *feedback* permitem ao SR inferir implicitamente as preferências do usuário e a popularidade do conteúdo. Sistemas de Recomendação Social são sistemas que visam o domínio de mídia social, aplicando técnicas de personalização para apresentar os dados mais relevantes e atraentes para o usuário (GUY, I., 2015).

Sistemas de Recomendação Social são baseados em estruturas de rede, *tags* sociais, pistas sociais, como por exemplo influenciadores sociais, ou uma combinação destes vários aspectos. Em geral, os sistemas baseados em pistas sociais e *tags* sociais são diferentes dos que se baseiam em aspectos estruturais. Os que se baseiam em aspectos estruturais são usados para sugerir nós e *links* dentro da própria rede, e os que se baseiam em pistas sociais e *tags* sociais são usados para recomendar itens, produtos ou conteúdo de mídias sociais (AGGARWAL, 2016).

De acordo com Bernardes *et al.* (2015) atualmente existem três famílias de recomendação social: uma baseada em links sociais explícitos, uma baseada na confiança e uma família com base em *links* sociais implícitos, detalhadas nas próximas seções.

### 2.4.1 Recomendação Social Baseada em *Links* Explícitos

Sistemas de Recomendação Social baseados em links explícitos são baseados em uma rede na qual é possível estabelecer relações explícitas, como amigo, seguidor, etc. Estes sistemas derivam da abordagem tradicional de FC, e podem ser divididos também em *memory-based* ou *model-based*, tendo como diferença o uso de relações sociais explícitas para comparar semelhanças (BERNARDES *et al.*, 2015).

As redes sociais geralmente consistem em nós, representando pessoas ou outras entidades inseridas em um contexto social, e em arestas, representando interação, colaboração

ou alguma outra forma de vínculo entre entidades (SCHALL, 2015). As redes tornaram-se onipresentes como uma ferramenta de modelagem em muitas aplicações, como redes sociais e de informação.

Vários elementos estruturais de uma rede podem ser recomendados. Cada um desses diferentes tipos de recomendação estrutural pode ter um conjunto diferente de aplicações em diferentes cenários. Alguns exemplos importantes dessas variações (AGGARWAL, 2016):

- (1) *Recomendação de nós por autoridade e contexto*: neste caso, a qualidade dos nós é julgada pelos links recebidos, e a relevância personalizada dos nós é julgada por seu contexto. Nós de alta qualidade têm muitos links de entrada. Este problema está intimamente relacionado com o dos motores de busca. Nos mecanismos de pesquisa, as páginas da *Web* (ou nós no grafo da *Web*) são classificadas com base em sua autoridade e seu conteúdo;
- (2) *Recomendando nós por exemplo*: em muitos aplicativos de recomendação, pode-se recomendar nós semelhantes a outros nós, esse problema é o da classificação coletiva de nós;
- (3) *Recomendando links*: em muitas redes sociais, como o *Facebook*, é do interesse da rede social aumentar a conectividade da rede. Portanto, os usuários geralmente são recomendados para possíveis amigos. Esse problema é equivalente ao de recomendar links em potencial em uma rede.

As aplicações dos métodos de recomendação estrutural podem ir além do domínio da rede social, podendo ser usados para recomendar elementos em qualquer sistema modelado como uma rede centrada na *Web*. Os exemplos podem incluir notícias, postagens em *blogs* ou outros conteúdos habilitados para a *Web* (AGGARWAL, 2016).

## 2.4.2 Recomendação Social Centrada na Confiança

Os usuários de redes sociais costumam pedir a seus amigos sugestões sobre filmes, restaurantes ou outros itens. A estrutura social de um usuário também pode ser vista como uma rede social de confiança. Por exemplo, se um usuário é amigo de muitas pessoas que assistiram a um filme em particular, é mais provável que ele assista a esse filme. A estrutura da rede e os interesses nas proximidades do usuário desempenham um papel fundamental no processo de recomendação (GROH; BIRNKAMMERER; KÖLLHOFER, 2012).

Em algumas redes sociais são criadas redes de confiança entre usuários que fornecem *feedback* sobre o quanto os usuários podem confiar nas opiniões uns dos outros no processo de recomendação. O fator de confiança é particularmente importante porque os interesses

personalizados de um usuário podem ser mais bem previstos a partir dos padrões de avaliação de outros usuários em quem confiou no passado.

O relacionamento de confiança é direto e intencional: um usuário  $a$  pode confiar em  $b$ , porém não significa que  $b$  confie em  $a$ . A confiança pode ser fornecida explicitamente em uma rede de confiança, ou inferida (BERNARDES *et al.*, 2015). Para inferir as relações de confiança utiliza-se a transitividade nas relações, isso significa que, se um usuário  $A$  confia em  $B$  e  $B$  confia em  $C$ , então pode-se inferir o fato de que  $A$  confia em  $C$ .

Relações de confiança são diferentes de relações sociais, os SRs com base em confiança baseiam-se no pressuposto de que os usuários têm um gosto semelhante a outros usuários em quem confiam, enquanto que nos Sistemas de Recomendação Social alguns dos amigos do usuário alvo podem ter gostos totalmente diferentes dele (MA *et al.*, 2011).

A confiança e a homofilia desempenham um papel importante no processo de recomendação social. Esses conceitos estão relacionados, mas não são exatamente os mesmos. A homofilia refere-se ao fato de que os usuários vinculados em redes sociais tendem a ser semelhantes entre si em termos de gostos e interesses. Confiança refere-se ao fato de que os usuários são mais propensos a confiar nos gostos e recomendações de seus amigos. Em alguns casos, a confiança é consequência da homofilia. Como os usuários vinculados tendem a ser semelhantes, eles tendem a confiar nos gostos e recomendações de cada um (AGGARWAL, 2016).

### 2.4.3 Abordagens de Recomendação Social e Elementos Sociais

A FC pode ser percebida como uma abordagem de recomendação social, já que um conjunto de usuários, implicitamente, produz recomendações. No entanto, o contexto social explorado na FC é restrito à avaliação semelhante em um contexto social bastante implícito (GROH; BIRNKAMMERER; KÖLLHOFER, 2012).

Um mapeamento sistemático foi conduzido para identificar o estado da arte em SR com elementos sociais (TRAMONTIN; GASPAIRNI; PEREIRA, 2018) utilizando a metodologia de Petersen *et al.* (2008). Por meio do mapeamento foi possível identificar as principais abordagens utilizadas para recomendação social e os elementos sociais mais utilizados nestas abordagens. Este mapeamento será explorado no capítulo 3.

A FC é também conhecida por Filtragem Social (NING; DESROSIERS; KARYPIS, 2015), porém a diferença está nas relações sociais explícitas em um contexto social, rede social ou de confiança. Técnicas de previsão de *links* apoiam a descoberta e o estabelecimento de relações em sistemas baseados em redes sociais.

#### 2.4.4 Recomendação Social Baseada em *Links* Implícitos

A família de *links* sociais implícitos é um novo tipo de Sistemas de Recomendação Social. A rede pode ser derivada a partir do comportamento dos usuários. Os usuários serão implicitamente conectados se, por exemplo, frequentam e tiram fotografias nos mesmos locais, participam dos mesmos eventos ou clicam nos mesmos anúncios. A rede social pode então ser usada para criar recomendações (BERNARDES *et al.*, 2015).

### 2.5 AVALIAÇÃO DE SISTEMAS DE RECOMENDAÇÃO

Em muitas aplicações as pessoas usam um sistema de recomendação para além da antecipação exata de seus gostos. Os usuários também podem estar interessados em descobrir novos itens, em explorar rapidamente diversos itens, em preservar sua privacidade, nas respostas rápidas do sistema e em muitas outras propriedades da interação com o mecanismo de recomendação. Deve-se, portanto, identificar o conjunto de propriedades que podem influenciar o sucesso de um sistema de recomendação no contexto de uma aplicação específica (GUNAWARDANA; SHANI, 2015).

Atualmente, existem três tipos principais de avaliação de sistemas de recomendação (GUNAWARDANA; SHANI, 2015):

*Estudos com usuários:* os participantes são ativamente recrutados e eles são solicitados a interagir com o sistema de recomendação para realizar tarefas específicas. Uma vantagem importante dos estudos com usuários é que eles permitem a coleta de informações sobre a interação do usuário com o sistema. Vários cenários podem ser testados sobre o efeito de alterar o sistema de recomendação na interação do usuário, como o efeito de alterar um determinado algoritmo ou interface do usuário. Por outro lado, a consciência ativa do usuário sobre o teste do sistema de recomendação pode muitas vezes influenciar suas escolhas e ações. As métricas mais comuns de SR podem ser utilizadas em conjunto com medidas qualitativas para mensurar a satisfação dos usuários, por exemplo, por meio da observação, questionários, entrevistas, etc.

*Online:* o SR é avaliado em situações reais de uso, são usuários reais em um sistema totalmente implantado ou comercial. Essa abordagem às vezes é menos suscetível ao viés do processo de recrutamento, porque os usuários usam o sistema no curso natural dos negócios. Os dados para a avaliação são capturados de forma automática, por exemplo, ferramentas de *Web Analytics*, registros de *Logs*, notas dadas pelos usuários, etc.



*Offline*: são usados os dados históricos, como avaliações. Em alguns casos, informações temporais também podem ser associadas às avaliações, como o registro de data e hora em que cada usuário classificou o item. As ações dos usuários são simuladas sem necessitar da participação dos mesmos. A principal vantagem do uso de dados históricos é que eles não exigem acesso a uma grande base de usuários. Depois que um conjunto de dados é coletado, ele pode ser usado como uma referência padronizada para comparar vários algoritmos em várias configurações. As métricas tradicionalmente utilizadas para medir a eficiência do algoritmo de recomendação nesse tipo de avaliação são: (i) *Mean Absolute Error* (MAE), (ii) *Root Mean Square Error* (RMSE), (iii) *Precision*, (iv) *Recall*, e (v) *F-Measure*. Utilizadas para calcular o quão próximas as avaliações previstas estão das avaliações reais. A principal desvantagem das avaliações *offline* é que elas não medem a propensão real do usuário para reagir ao sistema de recomendação no futuro. Por exemplo, os dados podem evoluir ao longo do tempo e as previsões atuais podem não refletir as previsões mais adequadas para o futuro.

Tradicionalmente, a qualidade de um SR é definida em termos de métricas estatísticas objetivas, por exemplo, métricas de erro e métricas de precisão, que são avaliadas por algoritmos (CREMONESI, P. *et al.*, 2011). No entanto, nos últimos anos, os pesquisadores perceberam que o objetivo de um sistema de recomendação se estende além de previsões precisas. O principal objetivo do mundo real é fornecer ajuda personalizada na descoberta de conteúdo ou itens relevantes (KONSTAN; RIEDL, 2012).

McNee *et al.* (2006) argumentam que “ser preciso não é suficiente” e que, em vez disso, “deve-se estudar as recomendações de uma perspectiva centrada no usuário para torná-los não apenas precisas e úteis, mas também um prazer de usar”. Em essência, os sistemas de recomendação aplicam algoritmos na entrada do usuário com o objetivo de fornecer algum tipo de saída personalizada. Isso significa que, além do algoritmo, há dois componentes interativos importantes para qualquer recomendação: o mecanismo pelo qual os usuários fornecem suas informações e os meios pelos quais eles recebem a saída do sistema. McNee *et al.* (2006) sugerem que os pesquisadores devem colocar mais foco na “Interação Humano-Recomendadora” e investigar esses componentes interativos.

De acordo com Cremonesi *et al.* (2013) na avaliação centrada no usuário, os usuários interagem com um sistema de recomendação em execução e recebem recomendações. As medidas são coletadas perguntando ao usuário (por exemplo, por meio de entrevistas ou pesquisas), observando seu comportamento durante o uso ou registrando automaticamente as

interações e, em seguida, submetendo os registros do sistema a várias análises (por exemplo, taxa de conversão).

## 2.6 ANÁLISE DE REDES SOCIAIS

Análise de Redes Sociais (do inglês *Social Network Analysis* - SNA) é o estudo das relações sociais entre um conjunto de atores (MIKA, 2007). Os comportamentos ou as opiniões dos indivíduos dependem das estruturas nas quais estão inseridos, são analisadas a união de relações entre os indivíduos por meio de suas interações uns com os outros (MARTELETO, 2001). Segundo Mika (2007) “os padrões de relacionamento não só podem ser usados para explicar o desempenho individual, mas também a hipótese de seu impacto sobre a própria (evolução da) rede”.

De acordo com Scott (2011) a abordagem predominante em SNA é a abordagem matemática, denominada teoria dos grafos, onde indivíduos e grupos são representados por pontos (vértices) e suas relações sociais são representadas por linhas (arestas), também denominadas conexões, links ou laços (GABARDO, 2015; DE LIMA; NETTO; GASPAR, 2014).

SNA visa estudar as relações entre os indivíduos e a identificação de comunidades. A análise é realizada por meio de teoremas da teoria de grafos para analisar as propriedades formais dos sociogramas resultantes. Essas propriedades podem ser em relação ao número de arestas e vértices ou indivíduos da rede (densidade), em relação ao posicionamento dos vértices (métricas de centralidade) ou quanto à estrutura e à formação de subredes ou subgrupos. Em geral, métricas de centralidade referem-se à “popularidade” de determinado indivíduo e podem ser de diferentes tipos, dentre elas: de grau (*degree*), de proximidade (*closeness*), de intermediação (*betweenness*) e de autovetor (*eigenvector*) (DE SOUZA SACERDOTE *et al.*, 2015; SCOTT, 2011).

De acordo com Scott (2017), a mais simples e direta forma de medir um ponto de centralidade local é pela medida de grau, que é simplesmente o número de outros pontos ao qual um ponto é adjacente. Um ponto então é central se tem um alto grau de conexões diretas, ignorando qualquer conexão indireta. Já a proximidade é uma medida de centralidade global e é expressa em termos de distâncias entre os vários pontos do grafo. Dois pontos estão conectados por um caminho se existe uma sequência de linhas distintas conectando-os, e o comprimento de um caminho é medido pelo número de linhas das quais é composto. A intermediação mede a extensão entre vários outros pontos no grafo e permite medir a capacidade que um ponto tem de influenciar os seus pares.

O conceito de laços sociais fornece informações sobre as propriedades estruturais de um usuário, bem como sobre as propriedades dos pares isolados. Os laços sociais podem ser categorizados em laços fortes (por exemplo, amigos confiáveis ou membros da família) que compartilham informações redundantes com grande sobreposição, e em contraste, laços fracos (por exemplo, conhecidos) compartilham informações mais diversas e novas. Esta informação pode ser usada em sistemas de recomendação social para gerar recomendações mais específicas (OECHSLEIN; HESS, 2014; SETH, 2008).

De acordo com Granovetter (1973), a força do laço entre dois nós depende da sobreposição de seus vizinhos. Em particular, quanto mais vizinhos em comum que um par de nós A e B podem ter, mais forte é o laço entre eles. Se a sobreposição de vizinhanças entre A e B for grande, considera-se que A e B têm um laço forte. Caso contrário, eles são considerados como tendo um laço fraco. A força do laço é formalmente definida por meio do coeficiente de *Jaccard* (SUN; TANG, 2011):

$$S(A, B) = \frac{|n_A \cap n_B|}{|n_A \cup n_B|} \quad (3)$$

Onde  $n_A$  e  $n_B$  são o conjunto de vizinhos de A e B, respectivamente. A força do laço de uma aresta é alta se dois nós incidentes na aresta tiverem uma alta sobreposição de vizinhanças.

Entretanto, é possível inferir a força do laço de outras maneiras, como por exemplo, por meio das interações entre dois indivíduos, sendo a duração e a frequência de conversas em salas de bate papo uma delas (ASABERE *et al.*, 2014). Uma propriedade fundamental das redes sociais é que as pessoas tendem a ter atributos semelhantes aos de seus amigos, e isso pode ocorrer por duas razões: (1) por meio da influência social, onde as pessoas adotam comportamentos exibidos por aqueles com quem interage e (2) as pessoas tendem a formar relacionamentos com outras que já são semelhantes a elas (CRANDALL *et al.*, 2008).

Diferentes estudos (MACEDO; MARINHO; SANTOS, 2015; PHAM *et al.*, 2012; XIA *et al.*, 2013; ZHANG *et al.*, 2013) mostram que o uso de informações sociais em sistemas de recomendação podem melhorar a precisão de uma recomendação. Os usuários das redes sociais *on-line* preferem as recomendações feitas por seus amigos do que as fornecidas por SRs tradicionais que utilizam pessoas anônimas com semelhanças e preferências similares a elas (BERNARDES *et al.*, 2015). Dessa forma, “os sistemas de recomendação social apresentam valor adicional e um novo e individualizado consumo de conteúdo é possível” (OECHSLEIN; HESS, 2014).

## 2.7 AUTORIDADE COGNITIVA

Autoridade é um relacionamento envolvendo pelo menos duas pessoas. Ter autoridade é diferente de ser um *expert*. Uma pessoa pode ser um expert apesar de outros não perceberem ou reconhecerem o fato. Nenhum indivíduo pode ser uma autoridade para ele mesmo pois autoridade requer que alguém atribua a outro alguém.

Autoridade cognitiva, também conhecida como autoridade epistêmica, ocorre quando as pessoas dizem, "Ele é uma autoridade em Informática na Educação", significa que ele é superior a outros dentro do campo à luz do conhecimento sobre Informática na Educação para quem concorda com a afirmação (RIEH, 2010).

De acordo com Wilson (1983) autoridade cognitiva é um tipo de influência consciente, julgada própria e adequada pelo conessor de autoridade, pois está claramente relacionada com a credibilidade. Aqueles que são autoridades cognitivas influenciam profundamente outros pensamentos. O que distingue as pessoas que são autoridades cognitivas daquelas que não são é que a influência dos autores (autoridade ou formador de influência) é reconhecida de alguma maneira oficial, sem exigir necessariamente uma justificativa para tal. Autoridade cognitiva é uma questão de grau: assim, o peso que as palavras de uma autoridade cognitiva carregam para os outros pode variar.

Conceder autoridade cognitiva a alguém é uma decisão subjetiva do indivíduo cujas justificativas estão além de qualquer questionamento. Se "A" possui credibilidade para com "B", então, existem razões para que "B" considere "A" uma autoridade cognitiva (PEREIRA, 2008). Uma autoridade é aquela pessoa a quem se procura para obter informações, mas pode ser também aquela pessoa a quem se recorre para obter um conselho, uma opinião, mesmo que não exista conhecimento para ser empregado no assunto. As autoridades não são avaliadas apenas por suas "expertises". As autoridades também são avaliadas por suas opiniões, seus conselhos sobre atitudes adequadas, sobre exemplos, discussões, respostas propostas, etc. Essa autoridade pode se estender por diversas áreas (moral, política, filosófica, técnica, científica) e, embora a autoridade cognitiva não possa dizer a uma pessoa "o que se deve pensar", ela pode influenciar em qualquer crença ou atitude (WILSON, PATRICK, 1983).

O conessor de autoridade é livre para categorizar suas fontes de informação da forma que julgar mais adequada, sem restrições ou limitações, representando, assim, a sua opinião sobre aquela fonte. A autoridade cognitiva representa a subjetividade do indivíduo com

relação a quem ele confia, gosta de obter informações, respeita e dá crédito (PEREIRA, 2008).

## 2.8 CONSIDERAÇÕES DO CAPÍTULO

No decorrer deste capítulo foram apresentados conceitos e abordagens de SRs, desde as abordagens tradicionais à Sensível ao Contexto e a abordagem Social. Foram apresentadas as técnicas tradicionais de avaliação de sistemas de recomendação, e conceitos sobre a avaliação envolvendo usuários.

No âmbito da abordagem Social, as técnicas de recomendação mais comumente utilizadas são FC e suas variações, como por exemplo, a Filtragem Social.

A informação social pode ser inserida ao contexto e utilizada como um caso especial de sistemas de recomendação sensíveis ao contexto. Sistemas de Recomendação Social podem ser baseados em *links* explícitos, em confiança e em *links* implícitos.

Apresentadas as questões relacionadas à SR, é necessário compreender os conceitos básicos inerentes à Análise de Redes Sociais. Estes conceitos foram apresentados a fim de tornar perceptível a importância das relações entre os usuários e os meios pelos quais estão conectados.

A Análise de Redes Sociais estuda as relações sociais entre os usuários de uma rede, visando compreender o comportamento do usuário por meio de suas interações. Sistemas de Recomendação Social precisam destas informações de relacionamentos para melhorar a qualidade das recomendações.

A autoridade cognitiva é um relacionamento entre duas pessoas  $a$  e  $b$ . A pessoa ( $a$ ) é quem julga ser a outra pessoa ( $b$ ) autoridade em determinado assunto, ou seja, não existe o uso do poder e é definida como um tipo de influência, representando a subjetividade da pessoa que concede a autoridade a alguém e que, portanto, pode se beneficiar de recomendações baseadas nos itens desse alguém.

O próximo capítulo apresenta um mapeamento sistemático realizado para identificar o estado da arte sobre SR com elementos sociais.

### 3 MAPEAMENTO SISTEMÁTICO DE LITERATURA

Com o intuito de identificar o estado da arte em SRs que usam elementos sociais, um Mapeamento Sistemático (MS) foi conduzido utilizando a metodologia de *Petersen et al.* (2008), que fornece uma estrutura de relatórios de pesquisa com resultados de trabalhos que foram publicados categorizando-os, apresentando um resumo visual dos seus resultados, obtendo uma visão geral de uma área de pesquisa, identificando a quantidade, o tipo de pesquisa e os resultados disponíveis dentro dela.

#### 3.1 PROCESSO DO MAPEAMENTO

Um MS possui passos essenciais que são: (1) Definição de Perguntas de Pesquisa: quando são definidos o objetivo da pesquisa e os resultados no Escopo da Revisão. (2) Conduzir a Pesquisa: quando todos os documentos potencialmente relevantes são identificados. (3) Triagem de documentos: com base em critérios de seleção, apenas documentos relevantes para pesquisa permanecem. (4) Palavra-chave usando Resumos: os pesquisadores procuram palavras-chave e conceitos que refletem a contribuição de cada artigo e o conjunto de palavras-chave de diferentes trabalhos são combinados para desenvolver uma compreensão de alto nível sobre a natureza e estado da área de estudo. (5) Extração de Dados e Mapeamento de Estudos: com base na classificação feita na etapa 4, os artigos são categorizados e as informações relevantes são extraídas e representadas visualmente (PETERSEN *et al.*, 2008). O processo de mapeamento foi realizado de Fevereiro de 2017, mês em que a extração de dados ocorreu, a Novembro de 2017, com a finalização das análises.

##### 3.1.1 Definição das Questões de Pesquisa

Com o objetivo de estudar o estado atual acerca de SRs que usam elementos sociais no processo de recomendação, o MS busca responder a Questão Principal de Pesquisa (QPP): Qual o estado da arte em SR com elementos sociais? Para ajudar a responder a QPP, cinco Questões de Pesquisas Secundárias (QPS) foram elaboradas: QPS1: Em quais domínios são utilizados SRs com elementos sociais? QPS2: Quais as principais abordagens/técnicas de recomendação utilizadas? QPS3: Quais elementos sociais são explorados? QPS4: Qual tipo de avaliação é realizado? QPS5: Existem SRs que utilizam elementos sociais para eventos acadêmicos?

### 3.1.2 Processo de Busca

No MS foi utilizada uma *string* de busca simples, com as palavras-chaves: (“*Recommender system*” AND “*Social*”), em diferentes Mecanismos de Busca Acadêmicos (MBA’s), a citar: *ACM Digital Library*, *Elsevier Scopus*, *IEEE Digital Library* e *Science Direct*. Foram filtrados artigos publicados a partir de 2007, abrangendo os últimos dez anos com o intuito de identificar o estado da arte durante este período. Esse período de publicações foi escolhido porque julga-se que dez anos é tempo suficiente para se obter uma visão geral da área e apontar tendências futuras, assim como, identificar trabalhos recentes. A busca identificou 321 trabalhos que apresentavam em seus títulos, resumos ou palavras-chaves os vocábulos mencionados. A partir dessa identificação foi possível iniciar a análise dos trabalhos em relação à temática em estudo e gerar os resultados apresentados nas seções a seguir.

### 3.1.3 Processo de Seleção

O processo de seleção consiste na aplicação de um conjunto de Critérios de Inclusão (CI) e Critérios de Exclusão (CE) para adicionar ou remover trabalhos em nossa análise. A relevância do trabalho em relação às questões de pesquisa foi determinada por meio de análise do título, palavras-chave e resumo. Após conduzir a busca em todos os MBA’s, além da data de publicação igual e superior a 2007, os seguintes critérios foram aplicados: CI1: Artigos disponíveis para download; CI2: Artigos no idioma inglês; CI3: Artigos completos (quatro páginas ou mais); CE1: Artigos duplicados; CE2: Artigos que não visam uma estratégia/abordagem de recomendação com elementos sociais; CE3: Artigos cujo título e/ou resumo abordem marcação (*tagging*). O foco do estudo são os elementos sociais associados às relações sociais. Somente artigos que atenderam a todos os CI foram avaliados, artigos que atenderam a algum CE foram removidos.

Quadro 1 - Processo de Seleção

	ACM DL	IEE Xplore	Science Direct	Scopus	Total
A partir de 2007	88	27	9	197	321
Após CI1	87	27	9	101	224
Após CI2	86	27	9	101	223
Após CI3	47	23	9	78	157
Após CE1	44	20	9	42	115
Após CE2					74
Após CE3					59

Fonte: a Autora.

De acordo com o Quadro 1, que mostra todo o processo de seleção executado, os artigos filtrados pela *string* de busca a partir de 2007 foram 321, estando disponíveis para download 224 artigos, destes, 223 em inglês dos quais 157 são artigos completos. Removidos os artigos duplicados restaram 115, dentre eles 41 artigos não apresentavam uma abordagem ou estratégia de recomendação, totalizando 74 trabalhos que ao serem analisados pelo CE3 foram removidos 15, totalizando 59 artigos científicos que atendem aos critérios do MS. Destes 59 artigos, foram extraídos os dados para responder as questões de pesquisa.

### 3.2 RESULTADOS E ANÁLISES

Esta seção apresenta os resultados encontrados no MS, bem como a descrição das análises realizadas nos trabalhos selecionados.

#### 3.2.1 Domínio de Aplicação

A fim de responder a Questão Principal de Pesquisa (QPP) e identificar como são geradas e avaliadas as recomendações com elementos sociais, é necessário responder às questões secundárias de pesquisa. A QPS1 busca responder em quais domínios os SRs com elementos sociais são aplicados.

Os domínios de aplicação identificados são: Acadêmico (3%), Corporativo (9%), Entretenimento (31%), Genérico (3%, onde se propõe a aplicação em qualquer domínio), Pontos de Interesse (9%), Redes Sociais (3%), Avaliação e Revisão de Produtos (15%) e Outros (22%). Dentre os trabalhos analisados apenas 5% não apresentam um domínio de aplicação e entre os domínios acima citados destacam-se o Entretenimento, a Revisão de Produtos e Outros, que é um agrupamento de diversos domínios, entre eles: E-commerce,



Alimentar, Corporativo, Artístico, E-learning, Empregos, Eventos, Restaurantes, Fotografia, Telecomunicações, Livros, Marketing, Salvar e Organizar Links, Comunidade Social On-line.

### 3.2.2 Abordagens

Buscando responder a QPS2, que visa conhecer as principais abordagens/técnicas de recomendação, 1 foi possível observar que a FC é a principal abordagem utilizada nos trabalhos analisados. Em seguida, a abordagem Híbrida e posteriormente a Filtragem Social. Trabalhos que utilizam a FC utilizam a similaridade no processo de recomendação.

Trabalhos que utilizam abordagem Híbrida combinam diferentes técnicas e abordagens. As técnicas encontradas são: Baseada em Conteúdo, Baseada em Conhecimento, Baseado em Comportamentos Sociais, Sensível ao Contexto, Baseada em Influência, Análise do Sentimento, Análise de Redes Sociais, Baseada em Confiança, Métodos Centrados em Rede, Laços Sociais, Preferências do Usuário, Análise Semântica, Mineração de Influência Social, *Factorized Personalized Markov Chains* (FPMC) e *Visual Bayesian Personalized Ranking* (VBPR) (HE *et al.*, 2016).

Na Filtragem Social, os trabalhos analisados utilizam a rede social em que o usuário está inserido e suas relações para gerar as recomendações, que podem ser por meio da similaridade de itens, de amigos e por meio da confiança explícita, que tem características explicadas pela teoria da Autoridade Cognitiva.

Outras abordagens/técnicas foram identificadas nos trabalhos selecionados, tais quais: Recuperação de Associação, Baseada em Redes Sociais, Baseada em Comunidade, Mineração de Dados, Abordagens Semânticas, Baseada em Conteúdo e Baseado em Confiança.


### 3.2.3 Elementos Sociais

A QPS3 tem por fim identificar quais elementos sociais são explorados e adicionados ao processo de recomendação. Foram identificados neste MS nove elementos sociais: (1) Interações Sociais, (2) Confiança, (3) Afinidade entre Amigos, (4) Influência de Amigos, (5) Similaridade entre Amigos, (6) Relacionamentos, (7) Preferências de Amigos, (8) Popularidade e (9) Reputação.

Verifica-se no Gráfico 1 que a Similaridade entre Amigos é o aspecto social mais utilizado no processo de recomendação, isso pode ser explicado devido à maioria dos trabalhos utilizarem a abordagem FC, que gera as recomendações com base na similaridade de usuários ou itens. Portanto, a Similaridade entre Amigos pode abranger a similaridade

entre membros da mesma comunidade, grupo, rede ou sistema. O segundo aspecto Social mais utilizado é a Confiança e o terceiro são as Interações Sociais.

Gráfico 1 - Elementos Sociais



Fonte: a Autora.

Foram analisados os Elementos Sociais utilizados nas principais abordagens identificadas neste mapeamento por serem utilizadas com maior frequência: FC, Híbrida e FS. É possível observar que estas abordagens apresentam com frequência o uso dos mesmos elementos apresentados no Gráfico 1: a Similaridade de Amigos, a Confiança e as Interações Sociais.

### 3.2.4 Avaliação

Nos trabalhos analisados verificou-se que 8 dos 59 trabalhos não realizaram avaliação. O tipo de avaliação predominante dentre os 51 que fizeram avaliação é o *Offline* representando 55% dos trabalhos, 25% realizam avaliação *Online* e 16% *User Studies*, respondendo a QPS4 - Qual tipo de avaliação é realizado?

A partir da análise dos trabalhos selecionados foi possível extrair o conjunto de dados utilizado para realizar as avaliações. Foram identificados 73 diferentes conjuntos de dados, sendo que alguns trabalhos utilizam até 4 conjuntos de dados diferentes em suas análises e experimentos. Destacam-se os seguintes: *Faceboock*, *Epinions*, *MovieLens*, *Douban* e *Flixter*.

Com base nas análises e considerando a resposta à QPS1, cujo objetivo é identificar o domínio em que os Sistemas de Recomendação Social são utilizados, pode-se responder a QPS5 que visa identificar se existem Sistemas de Recomendação Social para eventos acadêmicos. Na QPS1 foi possível identificar apenas um trabalho no domínio de Eventos (MACEDO; MARINHO; SANTOS, 2015), no entanto o trabalho não é relacionado ao meio

acadêmico ou científico. O foco do trabalho analisado são recomendações de eventos em redes sociais baseadas em eventos, como por exemplo, a *Meetup*. Dessa forma, entende-se que SRs para eventos acadêmicos com uso de elementos sociais é um tema com poucas publicações e que pode ser amplamente explorado.

### 3.3 DISCUSSÃO

A abordagem de recomendação baseada na rede social surgiu com o advento das redes sociais *on-line*. Esta abordagem assume uma rede social entre os usuários, que pode ser explícita ou implícita, e faz recomendações com base nas avaliações dos usuários que possuem relações sociais diretas ou indiretas com o usuário alvo (TANG; HU; LIU, 2013). As repostas às QPSs analisadas no MS ajudam a responder a QPP que visa conhecer o estado da arte em SRs com elementos sociais. Observam-se os diversos domínios de aplicação e as diversas propostas para melhorar o processo de recomendação com o uso desses elementos.

Muitos trabalhos apresentam o uso de técnicas tradicionais de recomendação, como por exemplo, a FC e adicionam elementos sociais no processo de recomendação, tais como a similaridade entre amigos, a confiança e as interações sociais. A FC é a abordagem mais popular e foi empregada em muitas aplicações. A técnica de FS utiliza somente elementos sociais para realizar as recomendações, destacando-se a similaridade entre amigos e a confiança. A FC e a Filtragem Social são utilizadas isoladamente ou em conjunto com outras técnicas em abordagens Híbridas. Os trabalhos que utilizam a abordagem Híbrida combinam diferentes técnicas, algumas já conhecidas na literatura de SRs e técnicas de outras áreas, como por exemplo, a Análise de Redes Sociais, a Análise Semântica e a Análise do sentimento.

Os elementos sociais mais utilizados no processo de recomendação das abordagens citadas são: similaridade entre amigos, confiança e interações sociais. A similaridade entre amigos consiste na semelhança de perfil e de gostos do usuário alvo com seus amigos. A confiança é uma indicação de quão confiável um indivíduo é para o usuário alvo, pode ser direta e intencional ou calculada. Quando é direta e intencional, ou seja, uma ação explícita do usuário alvo, é uma forma de conceder autoridade cognitiva ao indivíduo. As interações sociais são utilizadas para indicar a existência de um relacionamento, calcular grau de afinidade e a influência interpessoal.

Em suma, os trabalhos encontrados são aplicados ao domínio de entretenimento, todavia, SRs com uso de elementos sociais são utilizados em diversos domínios, isso pode estar relacionado ao crescente uso de redes sociais em diferentes tipos de aplicações na web.

As avaliações são realizadas predominantemente do tipo *Offline* as propostas apresentadas são comparadas com abordagens do estado da arte por meio de métricas que avaliam a precisão da recomendação.

### 3.4 CONSIDERAÇÕES DO CAPÍTULO

Este capítulo descreveu a realização de um mapeamento sistemático sobre Sistemas de Recomendação com uso de Elementos Sociais que visa conhecer o estado da arte atual e entender o uso destes elementos no processo de recomendação. O método utilizado foi o sugerido por *Petersen et al.* (2008) que possui passos essenciais para coletar, analisar e sumarizar pesquisas. Iniciou-se com a análise de 321 trabalhos e após uma inspeção cuidadosa, 262 trabalhos foram descartados por não atenderem aos critérios de inclusão e de exclusão. Os demais trabalhos (59) foram considerados estudos com evidências que respondem às questões de pesquisa.

Por meio da análise dos trabalhos selecionados e das respostas às questões de pesquisa, foi possível identificar o estado da arte atual sobre Sistemas de Recomendação que fazem uso de Elementos Sociais, e foi possível constatar que a abordagem de recomendação mais utilizada é a FC e, conseqüentemente, o Elemento Social mais utilizado é a Similaridade entre Amigos. O tipo de avaliação empregado com maior frequência para obter resultados sobre a qualidade da recomendação é a *Offline*.

O MS tornou possível perceber as oportunidades de pesquisa a serem estudadas. As abordagens de recomendação que foram utilizadas com menor frequência, como por exemplo, a Baseada em Confiança ou em Redes Sociais e demais técnicas que podem ser úteis para trabalhos futuros, assim como, os Elementos Sociais pouco explorados: reputação, afinidade entre amigos, preferências de amigos, influência e popularidade. A realização de experimentos com usuários reais também é uma oportunidade e um diferencial importante em relação aos demais trabalhos, pois coletar o feedback dos usuários contribui para aperfeiçoar pesquisas futuras.

Apenas um trabalho no Domínio de Aplicação Eventos foi identificado por meio do MS, o trabalho de Macedo, Marinho e Santos (2015), que aborda recomendações de eventos em geral em Redes Sociais baseadas em Eventos. Dessa forma, por meio da *string* de busca utilizada e dos critérios de inclusão e exclusão no processo do mapeamento, não foi possível identificar trabalhos no Domínio de Aplicação de Eventos acadêmico-científicos.

## 4 TRABALHOS RELACIONADOS

Muitos são os fatores que influenciam os pesquisadores, estudantes e outros interessados na decisão de quais sessões participar em eventos científicos. Dentre eles, a relevância dos temas, os tópicos de interesse, a localização, a duração, os palestrantes, os relacionamentos (amigos, coautores, autoridades) entre outros fatores que o participante julgar relevante. Neste capítulo são discutidas as semelhanças e diferenças entre as propostas apresentadas nos trabalhos relacionados e a proposta desta dissertação, o MRSSEC.

Primeiramente são apresentados os trabalhos relacionados à recomendação de sessões em Eventos científicos. Posteriormente são apresentados trabalhos em que a avaliação da recomendação é realizada pelo usuário alvo em contextos sociais diferentes aos de eventos científicos. Por fim, são apresentadas as considerações deste capítulo.

O trabalho de Asabere *et al.* (2014) foi encontrado por meio de levantamento bibliográfico tradicional realizado após os resultados do mapeamento, os trabalhos de Farzan e Brusilovsky (2008) e de Pham *et al.* (2012) são citados por Asabere *et al.* (2014) e, conforme mencionado no capítulo 3, Macedo, Marinho e Santos (2015) abordam o problema de recomendação de eventos em geral.

Dentre os trabalhos relacionados, o trabalho de Farzan e Brusilovsky (2008) é o primeiro artigo no período em que abrange a pesquisa. Os autores tentam ajudar o usuário por meio da navegação social, permitindo visualizar os trabalhos mais acessados no sistema. Dessa forma, o usuário percebe o filtro visual e pode selecionar os trabalhos mais visualizados pela comunidade, adicionando-os à sua agenda.

Os dados coletados no trabalho de Farzan e Brusilovsky (2008) são dados de uso do sistema e o *feedback* dos usuários por meio de questionário. Porém, difere nas questões técnicas diretamente relacionadas ao sistema, onde o usuário interage com o sistema com antecedência, permitindo que faça seu planejamento de comparecimento ao evento antecipadamente. A recomendação social apresentada por Farzan e Brusilovsky (2008) está relacionada à interface de navegação e não são apresentados métodos, algoritmos ou modelos.

No trabalho de Pham *et al.* (2012), percebe-se a preocupação em auxiliar os participantes de eventos científicos por meio do uso de dispositivos móveis. Eles propõem uma versão modificada do algoritmo FC, denominado CAMRS, que leva em conta a mobilidade, a sensibilidade ao contexto e as relações sociais, e utilizam a previsão de *link* para recomendar pessoas.

Pham *et al.* (2012) identificam dois tipos de vínculo entre os participantes por meio da rede de coautoria e de citação, pares diretos e pares indiretos. Pares diretos são autores com quem o usuário alvo tem colaborado ou referenciado diretamente, sendo medidos pela existência ou inexistência. Vale ressaltar que os autores não apresentam como as recomendações por pares diretos são geradas. Pares indiretos são pesquisadores que tem interesses similares ou que estão trabalhando em tópicos similares, mas não estão diretamente conectados na rede

Pham *et al.* (2012) coletaram *feedbacks* dos participantes por meio de um formulário de avaliação no final da conferência, porém as questões não foram apresentadas pelos autores.

O trabalho de Asabere *et al.* (2014), denominado SARVE, é semelhante ao trabalho de Pham *et al.* (2012), pois recomendam locais de apresentação por meio de dispositivos móveis com técnicas da abordagem FC, e também consideram o contexto local e temporal. O SARVE permite que os usuários se comuniquem com os apresentadores por meio de mensagens, então, a força do laço entre eles é medida por meio da duração e frequência do contato, ou seja, quanto maior o contato entre apresentador e participante, mais forte será considerado o relacionamento entre eles.

O SARVE verifica a força do laço entre o apresentador e os usuários participantes da conferência apenas por meio da frequência de contato, a popularidade de um apresentador é considerada no processo de recomendação, já no MRSSEC a popularidade de autores ou participantes não é considerada.

Asabere *et al.* (2014) desenvolveram o algoritmo FC e realizaram testes com métricas de precisão e abrangência. No MRSSEC não são realizadas comparações com outros modelos, nem testes de desempenho, mas são realizadas análises para verificar se o modelo gera recomendações relevantes por meio de experimento misto, *Online* com pesquisa qualitativa.

O trabalho de Macedo, Marinho e Santos (2015) aborda o problema de recomendação de eventos em geral e publicados em Redes Sociais Baseadas em Eventos, portanto, o trabalho difere em relação ao contexto de aplicação. Os autores apresentam uma abordagem, denominada MCLRE, que utiliza as dimensões do contexto para classificar eventos. Por meio de simulação realizaram a comparação do método proposto com 3 outros métodos do estado da arte.

O Quadro 2 apresenta uma comparação dos principais aspectos entre os trabalhos relacionados e o MRSSEC, que são **Contexto, Elementos Sociais, Rede Social e Avaliação**, assinaladas com um “X” para indicar a presença do aspecto citado.

Quadro 2 - Comparação dos trabalhos relacionados com MRSSEC

	Farzan e Brusilovsky 2008	Pham <i>et al.</i> 2012	Asabere <i>et al.</i> 2014	Macedo, Marinho e Santos 2015	MRSSEC (proposta desta dissertação)
<b>Contexto</b>					
Local	-	X	X	X	X
Temporal	-	X	X	X	-
Social	-	X	X	X	X
<b>Elementos Sociais</b>					
Preferências de Amigos	X	-	-	-	-
Similaridade entre Amigos	-	X	X	-	X
Interações Sociais	-	-	X	X	-
Popularidade	-	-	X	-	-
Relacionamentos	-	-	-	-	X
Confiança	-	-	-	-	X
<b>Rede Social</b>					
Comunidade	X	-	X	-	X
Pesquisa Científica	-	X	-	-	X
Amizades	-	-	-	-	X
Baseada em Eventos	-	-	-	X	X
<b>Avaliação</b>					
<i>Online</i>	X	X	-	-	X
<i>Offline</i>	-	-	X	X	-
Estudos com usuários	X	X	-	-	X

Fonte: a Autora.

Em relação ao contexto, os trabalhos que consideram informações do **Contexto** para melhorar a recomendação com base na situação do usuário, conforme descrito por Ranganathan e Campbell (2003) são: Pham *et al.* (2012), Asabere *et al.* (2014) e Macedo, Marinho e Santos (2015). Estes consideram o contexto Local, Temporal e Social. No MRSSEC são explorados o contexto Local, pois em grandes eventos informações contextuais de localização podem produzir recomendações que auxiliem o usuário alvo a encontrar sessões relevantes próximas a ele e Social, pois informações contextuais sociais possibilitam conhecer melhor o usuário alvo a partir de seus relacionamentos. Farzan e Brusilovsky (2008) não apresentam o uso de informações baseadas na situação do usuário.

No mapeamento sistemático apresentado no Capítulo 3 foram identificados **Elementos Sociais** que são explorados e adicionados ao processo de recomendação. Os elementos sociais do mapeamento foram identificados nos trabalhos relacionados e são: Preferências de Amigos, Similaridade entre Amigos, Interações Sociais, Popularidade, Relacionamentos e Confiança. A seguir são apresentados os trabalhos relacionados e os respectivos elementos sociais.

O trabalho de Farzan e Brusilovsky (2008) por ser baseado em comunidade apresenta recomendações por meio de sugestões visuais com base nas preferências dos membros da

comunidade do usuário alvo no sistema, correspondendo ao elemento social Preferências de Amigos. Pham *et al.* (2012) propõe um algoritmo baseado na técnica de FC utilizando a similaridade entre os pesquisadores para gerar as recomendações, analisando pares indiretos dentro da mesma rede (coautoria e citação), que equivale ao elemento social Similaridade entre Amigos. Asabere *et al.* (2014), através de interações sociais, medem a força do laço entre usuários e apresentadores, utilizam FC para similaridade entre dois usuários (participante e apresentador) e a popularidade de um apresentador é medida por meio do grau de centralidade. Dessa forma, os elementos sociais correspondentes são Similaridade entre Amigos, Interações Sociais e Popularidade.

Macedo, Marinho e Santos (2015) consideram interações entre usuários e todos os grupos em que estão afiliados e entre os grupos e os eventos criados por eles, correspondendo ao elemento social Interações Sociais.

Na proposta desta dissertação, o MRSSEC utiliza os elementos sociais Similaridade entre Amigos, Relacionamentos e Confiança. A similaridade é medida entre usuários implicitamente conectados no local do evento, os Relacionamentos são obtidos por meio das redes sociais, e quando o usuário seleciona autores para seguir, indicando seus relacionamentos por meio da Confiança.

Nos trabalhos de Farzan e Brusilovsky (2008) e Asabere *et al.* (2014) os participantes recebem recomendações baseadas nas preferências de membros da mesma Comunidade. Pham *et al.* (2012) utilizam **Redes Sociais** de Pesquisa Científica, coautoria, citação e colaborações. Macedo, Marinho e Santos (2015) utilizam uma rede social *online* Baseada em Eventos. O MRSSEC permite a utilização de todas as redes sociais apresentadas no Quadro 2, e possibilita a combinação de mais de uma fonte de dados sociais, como por exemplo, a rede social pode ser derivada de redes de coautoria ou de citação, ou redes sociais acadêmico-científicas, porém, a rede social é utilizada para encontrar apenas relacionamentos diretos, pares indiretos não são analisados. Além disso, é considerado um modelo baseado em comunidade, pois utiliza dados da comunidade acadêmica no local do evento para influenciar as decisões do usuário alvo.

Em relação aos três principais tipos de **Avaliação** de sistemas de recomendação, Farzan e Brusilovsky (2008) e Pham *et al.* (2012) realizam avaliação *Online* e *Estudos com Usuário*, da mesma forma também é realizado no MRSSEC. Já Asabere *et al.* (2014) e Macedo, Marinho e Santos (2015) realizam somente avaliação *Offline*.

Farzan e Brusilovsky (2008) realizaram a avaliação do sistema durante toda a conferência do ELearn 2007. O evento foi dividido em 15 sessões paralelas com um total de



150 artigos. Os títulos e resumos foram fornecidos várias semanas antes da conferência, permitindo planejar antecipadamente. Foram analisados dados de *log* e dados de questionários.

Pham *et al.* (2012) realizaram dois estudos: uma simulação de conferência usando dados do ICWL 2010 (*International Conference on Web-based Learning* - Conferência Internacional sobre Aprendizagem Baseada na Web) e um estudo no local no EC-TEL 2011 (*European Conference on Technology Enhanced Learning* - Conferência Européia sobre Aprendizado Aprimorado por Tecnologia). O objetivo do estudo foi avaliar o desempenho da abordagem proposta quanto ao contexto social e a mobilidade de usuários no local do evento.

O tipo de procedimento experimental usado por Asabere *et al.* (2014) para avaliar o SARVE foi *off-line*. O experimento foi realizado simulando a conferência internacional ICWL 2012 a fim de obter o conhecimento de quanto um usuário irá avaliar um item. Para identificar interesses de pesquisa e informações contextuais dos participantes da conferência que foram comparados com os interesses e informações contextuais dos apresentadores, foram reunidos dados de 78 membros/alunos da Escola de *Software* da Universidade de Tecnologia de Dalian, na China.

A abordagem de Macedo, Marinho e Santos (2015) foi comparada com 3 métodos do estado da arte em SR baseados em eventos: (1) MP (*Most Popular*): uma linha de base padrão “mais popular”, que classifica eventos em ordem decrescente do número de positivos que eles receberam; (2) BPR-MF (*Bayesian Personalized Ranking-Matrix Factorization-Based*): o ranking personalizado *bayesiano*, que é um algoritmo baseado em fatoração de matriz de última geração para as principais recomendações de itens; (3) BPR-NET (*Bayesian Personalized Ranking Network-Based*): esta abordagem refere-se ao método de recomendação de evento proposto por Qiao *et al.* (2014 apud Macedo, Marinho e Santos 2015).

Alguns estudos de SR no contexto social priorizam a perspectiva do usuário em relação à avaliação da recomendação. A seguir serão apresentados dois trabalhos em que a avaliação da recomendação é realizada pelo usuário alvo em contextos sociais diferentes aos de eventos científicos.

Guy *et al.* (2009) estudam recomendações personalizadas em um conjunto de aplicativos de um software social corporativo. Recomendam itens de três aplicações: páginas da web (favoritos), registros de blog e comunidades. A pesquisa está centrada em uma comparação entre recomendações que são baseadas na rede de familiaridade e de similaridade do usuário, também analisam o uso das explicações das recomendações. A rede de

familiaridade consiste nas pessoas que o usuário conhece. A rede de semelhanças contém pessoas cuja atividade social está sobreposta à atividade social do usuário.

Na avaliação realizada por Guy *et al.* (2009) os participantes foram solicitados a fornecer *feedback* sobre seu interesse em itens recomendados de acordo com uma das três opções: *Interessante*, *Não Interessante*, ou *Eu já sei*. Os participantes também podiam comentar livremente sobre cada item recomendado e um comentário geral ao final da pesquisa. Em relação à resposta *Eu já sei*, Guy *et al.* (2009) consideram que acertar um item que o usuário já tenha visto é uma indicação do potencial do sistema para identificar itens interessantes. Em comparação ao trabalho de Guy *et al.* (2009) quanto a avaliação, os participantes também foram solicitados a fornecer *feedback* sobre os itens recomendados, porém, em relação a relevância em uma escala de *Likert*, não são realizadas comparações entre abordagens ou métodos de recomendação social, a explicação da recomendação também não foi avaliada.

Shiwan Zhao *et al.* (2010) projetaram um sistema para funcionar em sites sociais centralizados em conteúdo, como fóruns de discussão e *blogs*, que geralmente contêm grande quantidade de informações. Os pesquisadores desenvolveram um sistema de recomendação baseado em mapas sociais, denominado *Pharos*. Um mapa social resume o comportamento social dos usuários relacionado ao conteúdo ao longo do tempo (por exemplo, comportamento de leitura, escrita e comentários durante a semana anterior). O *Pharos* foi implementado para ajudar os usuários a navegar no *site* do *blog* e localizar seus interesses.

Para avaliar a utilidade do *Pharos* ao ajudar os usuários a localizar conteúdo e pessoas relevantes, Shiwan Zhao *et al.* (2010) realizaram a avaliação com dez usuários, a cada um foi solicitado que realizasse duas tarefas, uma usando o *Pharos* e a outra usando o site original *BlogCentral*. O estudo realizado nesta dissertação realiza avaliação com usuários para identificar se as recomendações de sessões geradas por meio do modelo são consideradas relevantes por eles, porém não realiza um estudo controlado no qual o usuário necessite realizar tarefas pré-definidas.

No trabalho de Shiwan Zhao *et al.* (2010), o usuário foi convidado a preencher um questionário de avaliação pós-tarefa, solicitando sua opinião subjetiva sobre a utilidade do *Pharos*, seus recursos mais/menos apreciados e sugestões para melhorias futuras. Por meio de dados de *log*, foram computadas duas medidas objetivas, de tempo e de qualidade. Comparando com este trabalho, nesta dissertação os participantes foram convidados a preencher um questionário de avaliação subjetiva e dados de uso foram coletados.

Shiwan Zhao *et al.* (2010) analisaram a relevância e a importância das recomendações do ponto de vista do usuário, e foram medidas em uma escala *likert* de 5 pontos, sendo 1 a pontuação mais negativa e 5 a pontuação mais positiva. Nesta dissertação apenas a percepção subjetiva do usuário em relação à relevância da recomendação é analisada, também por meio de uma escala *likert* de 5 pontos.

Avaliar as recomendações sob a ótica do usuário alvo e não apenas usar medidas estatísticas para avaliar a qualidade da recomendação, em contextos sociais, possibilita ao pesquisador visualizar fatores humanos que podem contribuir para melhoria do processo de recomendação. A avaliação subjetiva com usuários permite compreender se as recomendações correspondem adequadamente ao interesse ou expectativa do usuário alvo, por meio de questionários.

#### 4.1 CONSIDERAÇÕES DO CAPÍTULO

Neste capítulo foram apresentados os trabalhos com propostas para recomendar apresentações, sessões e locais de sessões em eventos científicos. Por meio da análise dos trabalhos relacionados foi possível identificar características que contribuíram para o desenvolvimento do modelo e para a avaliação com o usuário. Portanto, a Proposta que será apresentada no Capítulo 5 é de um Modelo que leva em conta o Contexto Social e Local, utiliza os Elementos Sociais Similaridade, Confiança (por meio da Autoridade Cognitiva), e de Relacionamentos (que são laços sociais já estabelecidos). O modelo tem como característica a flexibilidade e aplicabilidade a qualquer tipo de evento científico, por isso podem ser utilizadas diferentes Redes Sociais ou fonte de dados sociais, conforme apresentado no Quadro 2.

Acredita-se que a perspectiva do usuário, principalmente em contextos sociais, deve ser priorizada em relação à avaliação da recomendação, por isso, foram acrescentados dois trabalhos em que a avaliação da recomendação é realizada pelo usuário alvo, pois além do tipo de avaliação ter sido *Online*, um estudo com os usuários foi realizado.

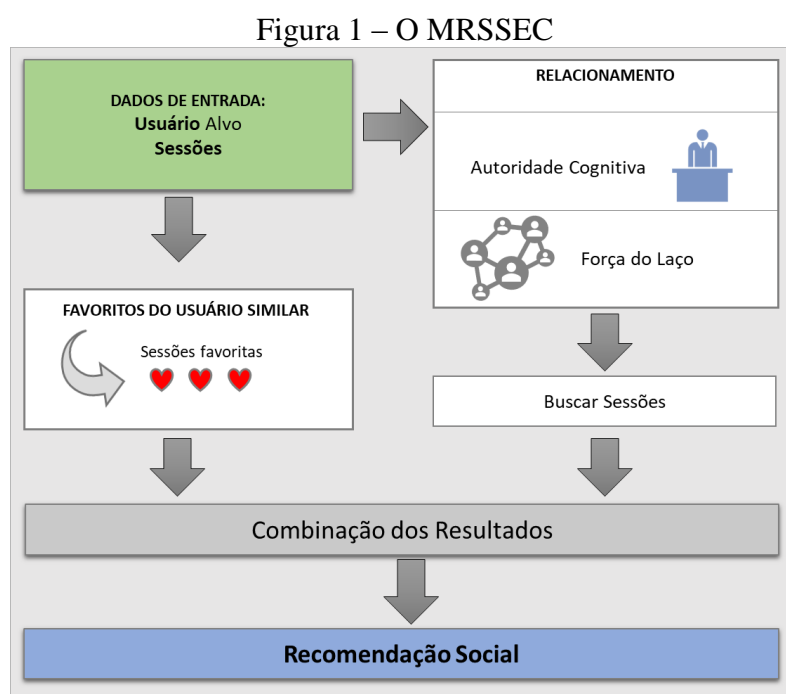
A oportunidade de pesquisa foi identificada por meio do mapeamento sistemático apresentado no Capítulo 3, e os trabalhos apresentados nesta seção também contribuíram para a construção e avaliação do modelo.

## 5 MODELO DE RECOMENDAÇÃO SOCIAL

Neste Capítulo será apresentado o Modelo de Recomendação Social de Sessões para Eventos Científicos (MRSSEC). O modelo considera relacionamentos: (i) provenientes de redes sociais e/ou base de dados sociais; (ii) indicados pelo participante e (iii) por similaridade entre os usuários presentes no evento, ou seja, entre a comunidade de pesquisadores.

### 5.1 MRSSEC

O MRSSEC é um modelo flexível e pode ser implementado de maneira parcial ou integral e aplicado em diferentes tipos de eventos científicos. No MRSSEC existem duas formas de analisar o relacionamento, por meio da Força do Laço e por meio da Autoridade Cognitiva. O relacionamento Força do Laço é medido de acordo com as características da rede, como por exemplo, em uma rede social que permite interações pode-se extrair dados que determinam a força do relacionamento entre usuários. Já o relacionamento Autoridade Cognitiva é indicado pelo próprio usuário alvo na aplicação do modelo. O MRSSEC é apresentado na Figura 1.



Fonte: a Autora.

Na Figura 11, os dados de entrada são os dados do *Usuário* e das *Sessões*, em seguida os dados são processados com base no Relacionamento e nos Favoritos do Usuário Similar.

O usuário pode indicar quais autores/palestrantes deseja “Seguir”, indicando confiança, admiração, interesse, definindo assim o que pode ser considerado a indicação de confiança explícita, baseada na teoria da Autoridade Cognitiva de Wilson (1983).

Os Favoritos de Usuários Similares são obtidos por meio da comparação dos tópicos de interesse do usuário alvo com os tópicos de interesse dos demais usuários do evento, conectados implicitamente por meio da aplicação em que o modelo está implementado. Posteriormente os dados são agrupados priorizando os *inputs* sociais e então a recomendação pode ser apresentada.

## 5.2 COMPONENTES ESSENCIAIS

O MRSSEC é composto por três componentes para gerar recomendações sociais, (1) *Usuário*, (2) *Sessões* e (3) *Rede Social*. Esses elementos são componentes de base do modelo e serão apresentados em detalhes a seguir.

### 5.2.1 Usuário

O componente *Usuário* trata-se do usuário do SR e é responsável por fornecer os dados para ser possível encontrá-lo e conhecê-lo, que são:

- Nome;
- Sobrenome;
- Instituição;
- Tópicos de Interesse.
- Sessões Favoritas.

O usuário alvo é um participante do evento científico, que pode ser desde um pesquisador experiente a um estudante ou qualquer pessoa que tenha interesse em participar do evento. Para a aplicação do MRSSEC é importante conhecer o Nome e Sobrenome do usuário. A Instituição também é um dado que torna possível conhecer o participante do evento. Os Tópicos de Interesse são tópicos dos temas relacionados ao evento científico, sendo que o participante os seleciona. Da mesma forma as Sessões Favoritas, são sessões indicadas pelo participante como favoritas. A Instituição, Tópicos de Interesse e Sessões Favoritas são dados opcionais, que podem ser utilizados de acordo com o formato e objetivo do evento.

### 5.2.2 Sessões

O componente *Sessões* possui os atributos das sessões para serem identificadas e recomendadas para o usuário alvo. Os atributos da sessão são:

- Título da Sessão;
- Horário;
- Local;
- Apresentações (Autores, Títulos, Palavras-chave, Instituições).
- *Chair*;
- Tópicos de Interesse;

O Título, Horário e Local da sessão são necessários para exibir a recomendação ao participante. Porém, para gerar as recomendações com base em Relacionamentos, é importante conhecer os autores dos trabalhos a serem apresentados. O *Chair* e os Tópicos de Interesse são opcionais e outros atributos, como por exemplo, palavras-chave, podem ser utilizados de acordo com o formato e objetivo do evento.

### 5.2.3 Rede Social

O componente *Rede Social* é responsável por prover dados sobre as relações sociais do elemento *Usuário*, tornando possível conhecer seus relacionamentos e gerar recomendações sociais.

Podem ser utilizadas redes sociais profissionais ou de amizades, bem como, bases de dados acadêmicas/científicas de:

- Coautoria;
- Citações;
- Projetos;
- Orientações;
- Colaborações;
- Redes Sociais de Pesquisa Científica.

A rede social também pode ser derivada do histórico de participações e apresentações do evento. Podem ser utilizadas uma ou mais fontes de dados sociais. O desenvolvedor, ao implementar o modelo, define qual rede social ou base de dados sociais vai utilizar para extrair dados que sejam relevantes para gerar recomendações de sessões.

### 5.3 RELACIONAMENTO

As relações sociais entre os indivíduos são também denominadas laços sociais. A seguir são apresentados dois métodos, Força do Laço e Autoridade Cognitiva, para obter os relacionamentos do usuário alvo.

#### 5.3.1 Força do Laço

O relacionamento Força do Laço é identificado pela aplicação na qual o modelo será implementado. A Força do Laço constitui em analisar o quão forte é o relacionamento entre o usuário alvo e os demais membros da rede. Assume-se que um relacionamento forte entre dois indivíduos possui um grande número de conexões ou interações sociais.

De acordo com a Figura 2, o relacionamento é obtido por meio da Força do Laço entre o usuário alvo e os demais membros da rede. A Força do Laço pode ser calculada entre pares diretos por meio da frequência de interações (comentários, compartilhamentos, conversas, colaborações), a duração e a atualidade dessas interações também podem ser analisadas para determinar a Força do Laço.

A Força do Laço também pode ser medida por meio da sobreposição da vizinhança, ou seja, o número de vizinhos em comum entre dois pares, utilizando o coeficiente de *Jaccard* (Fórmula 3, Seção 2.6). Se os relacionamentos (arestas) possuírem pesos e se existirem muitos relacionamentos, os pesos podem ser utilizados como filtro e uma lista *top-N* de relacionamentos fortes pode ser gerada. Porém, nas redes sociais em que os pesos não possam ser calculados, ou não existam muitos pares diretos a serem analisados, todos os relacionamentos podem ser considerados no processo de geração da recomendação social. As sessões dos relacionamentos fortes são selecionadas e armazenadas em uma *Lista\_ForçaDoLaço* (Figura 2) para serem recomendadas ao término do processamento do MRSSEC.

Por ser um modelo genérico e flexível, não são exploradas todas as possíveis mensurações de relacionamentos em redes sociais. Portanto, as medidas apresentadas são as que facilmente podem ser encontradas na literatura e fica a critério do desenvolvedor utilizar a que mais se adequa a seu projeto.

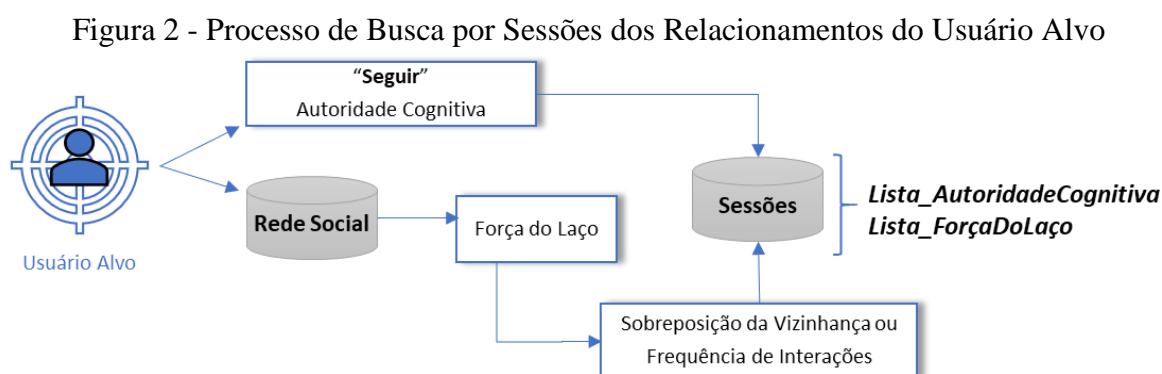
É importante salientar que o desenvolvedor, ao aplicar o modelo, conheça bem o público alvo do evento para poder selecionar redes sociais que forneçam dados sociais relevantes para o método de recomendação por Força do Laço.

### 5.3.2 Autoridade Cognitiva

O relacionamento Autoridade Cognitiva representa uma relação de autoridade cognitiva reconhecida de um indivíduo para outro, ou seja, o usuário indica quem ele deseja “Seguir” de acordo com sua experiência pessoal, confiança, reputação, popularidade, entre outros aspectos que o indivíduo julga pertinente considerar e que estão além de questionamento externo. Cada pessoa determina suas próprias autoridades, ninguém pode determinar quem é uma autoridade para outra pessoa a não ser ela própria (TOLEDO; PEREIRA; OLIVEIRAJR, 2015).

Este relacionamento é uma indicação de confiança explícita, e por ser baseada na teoria da Autoridade Cognitiva de Wilson (1983), este método do MRSSEC foi denominado Autoridade Cognitiva.

A Figura 2 apresenta o processo de busca por sessões por meio do Relacionamento a partir da ação “Seguir” e dos dados do usuário alvo na Rede Social.



Fonte: a Autora

Conforme apresentado na Figura 2, a existência de um relacionamento por Autoridade Cognitiva no MRSSEC é indicada exclusivamente pelo usuário alvo, sendo uma ação opcional. Dessa forma, na aplicação do modelo deve-se apresentar ao usuário a relação de autores, instituições, ou grupos (comunidades) presentes nas sessões de apresentações permitindo selecioná-los. As sessões em que os autores selecionados estão presentes são armazenadas em uma lista (*Lista\_AutoridadeCognitiva*) para serem recomendadas ao término do processamento do MRSSEC. Não deve haver duplicidade de sessões na lista, considera-se essa possibilidade, pois dois ou mais autores podem estar presentes na mesma sessão. Outro aspecto importante a ser considerado, por ser uma ação explícita do usuário e por não serem atribuídos pesos aos autores que ele selecionou, pode-se definir uma lista do tipo *top-N* de Autoridade Cognitiva, classificada por sessões que possuam o maior número de autores



selecionados pelo usuário alvo. Dessa forma, podem ser atribuídos pesos às sessões de acordo com a classificação.

Acredita-se que as autoridades cognitivas tendem a oferecer itens de maior interesse para o usuário que concede a autoridade, e nesse caso, a confiança é fornecida explicitamente. Identificar as pessoas e instituições que determinado usuário respeita pode ser considerada, assim, uma forma viável e útil de encontrar itens relevantes para serem recomendados.

#### 5.4 FAVORITAS DO USUÁRIO SIMILAR

Os usuários presentes no evento estão implicitamente conectados por compartilharem interesses em comum, sendo possível identificar uma rede social implícita no local (BERNARDES *et al.*, 2015). Em eventos científicos as apresentações são inéditas, portanto, não é possível obter avaliações antecipadas para recomendá-las. Porém por meio da rede social implícita é possível obter a semelhança entre usuários através dos tópicos de interesse. Dessa forma é possível obter a similaridade de tópicos de interesse, que são termos e/ou palavras chaves, entre o usuário alvo e os demais usuários utilizando a fórmula do Cosseno (Fórmula 2, Seção 2.2). Uma abordagem semelhante, baseada em conteúdo, foi utilizada por Oliveira *et al.* (2017), porém comparando tópicos de interesses do usuário alvo aos tópicos de interesse das sessões.

Os usuários mais similares ao usuário alvo são classificados em uma lista *top-N*. Caso o usuário mais similar não tenha favoritado sessões ou as sessões favoritadas por ele são as mesmas favoritadas pelo usuário alvo, analisa-se o próximo usuário similar. Quando o usuário mais similar possuir sessões favoritas diferentes das favoritadas pelo usuário alvo, essas serão recomendadas. O Quadro 3 apresenta um exemplo da lista *top-N* de usuários similares e suas sessões favoritas. O usuário  $U_1$  é o mais similar, porém as sessões favoritadas por ele são iguais as favoritadas pelo usuário Alvo. Excluindo-se o usuário  $U_1$ , o usuário  $U_2$  está em destaque, pois é mais similar em relação aos demais usuários e possui sessões a serem recomendadas.

Quadro 3 – Lista *top-N* de Usuários Similares e Sessões favoritas

Usuário	Similaridade	Sessões Favoritas do usuário similar	Sessões Favoritas do usuário Alvo ST01, ST07, ST13, ST16	Sessões recomendadas ao usuário alvo
$U_1$	0.88	ST01, ST07, ST13		-
$U_2$	<b>0.75</b>	<b>ST01, ST04, ST07, ST09, ST14</b>		<b>ST04, ST09, ST14</b>
$U_3$	0.73	-		-
$U_4$	0.66	ST01, ST07, ST13, ST10, ST14		-
$U_n$	0.57	ST11, ST14		-

Fonte: a Autora.

Os pré-requisitos para implementação deste método são os Tópicos de interesse e as Sessões Favoritas do componente *Usuário*. É importante destacar que é selecionado apenas o usuário mais similar pois o objetivo é recomendar sessões relevantes sem sobrecarregar o usuário alvo.

## 5.5 LOCALIZAÇÃO

A Localização é útil quando o modelo é implementado em uma aplicação para dispositivos móveis para uso em grandes eventos. O usuário pode receber recomendações de sessões levando em conta também a proximidade física. A localização pode ser implícita ou explícita. Implícita quando a localização é capturada por sensores (*Wifi*, *GPS*, *Bluetooth*) e explícita quando o usuário informa manualmente a sua localização (*QR-Code*, *Opção de Menu*, *Check-in*). É possível parametrizar essa característica de acordo com o tamanho e propósito do evento.

O uso de dados de localização é opcional assim como a escolha do método, implícito ou explícito, fica a critério do desenvolvedor, e deve-se levar em conta a proximidade do usuário ao local da sessão, e o horário de início. Técnicas de localização não serão contempladas neste trabalho, a localização pode ser utilizada para filtrar sessões quando conveniente, ou necessário, e deve-se seguir a relação de prioridades dos filtros como descrito na seção 5.6.

## 5.6 COMPOSIÇÃO DOS RESULTADOS

Após a seleção das sessões dos Relacionamentos e das sessões favoritas do usuário similar, os resultados são agrupados para serem recomendados ao usuário alvo.

No processo de recomendação priorizam-se os critérios sociais. Os critérios de maior peso são os relacionados a ação do usuário, ou seja, as sessões de autores que o usuário optou por “Seguir”, pois acredita-se que as autoridades cognitivas tendem a oferecer itens de maior interesse para o usuário que concede a autoridade. Posteriormente, são priorizadas as sessões dos Laços Fortes obtidos por meio da Rede Social, por serem relacionamentos que já existem nas redes sociais em que o usuário alvo está presente, fornecendo recomendações relevantes. Por fim, as sessões dos usuários mais similares de acordo com os tópicos de interesse, obtidas por meio da rede social implícita no local do evento, pois os participantes, mesmo não tendo um relacionamento direto ou explícito com o usuário alvo, compartilhar interesses em comum. Se a Localização for uma característica habilitada na aplicação do modelo, pode ser utilizada como um critério. Os critérios são classificados em grau de prioridade com seus respectivos pesos de acordo com a Tabela 1.

Tabela 1 – Prioridade dos Critérios Sociais

<b>Critério</b>	<b>Grau Ordinal de Prioridade</b>
Relacionamento:	
Autoridade Cognitiva	1º
Força do Laço	2º
Favoritos do Usuário Similar	3º
Localização	4º

Fonte: a Autora.

Ao compor os resultados das recomendações, o desenvolvedor deve estar atento às duplicidades de sessões a serem recomendadas. Respeitando a prioridade dos critérios sociais, as sessões recomendadas por Autoridade Cognitiva permanecem na lista, de acordo com o exemplo no Quadro 4.

Quadro 4 – Exemplo das Listas de Sessões a serem Recomendadas

<i>Lista_autoridade_cognitiva</i> : {ST02,ST03,ST07,ST11,ST13,ST14,ST15,ST18}
<i>Lista_força_laço</i> : {ST01, <del>ST02</del> ,ST04, <del>ST14</del> ,ST16}
<i>Lista_força_laço</i> : {ST01,ST04,ST16}
<i>Sessões_usuario_similar</i> : {ST05, <del>ST03</del> , <del>ST04</del> ,ST06,ST12,ST17,ST19, <del>ST18</del> ,ST21}
<i>Sessões_usuario_similar</i> : {ST05,ST06,ST12,ST17,ST19,ST21}
<i>Recomendação Social</i> : <i>Lista_autoridade_cognitiva</i> + <i>Lista_força_laço</i> + <i>Sessões_usuario_similar</i> + <i>Localização</i>

Fonte: a Autora.

As listas geradas em cada processo de recomendação são associadas resultando na Recomendação Social. Ao apresentar a recomendação para o usuário alvo deve-se respeitar a prioridade dos critérios sociais em todas as aplicações do modelo.

Respeitando os critérios, outras formas de combinar os resultados podem ser empregadas, como por exemplo, o desenvolvedor pode aplicar os critérios para atribuir pesos às sessões que se repetem nas listas geradas, obtendo um peso total da sessão a ser recomendada destacando-a em relação as demais.

No processo de recomendação, não são consideradas as sessões em paralelo. Sugere-se apresentar todas as sessões, deixando o usuário decidir de qual sessão participar. O intuito é não esconder sessões que podem ser relevantes para ele. Porém, caso o desenvolvedor opte por apresentar somente uma sessão, a sugestão é sempre priorizar os critérios sociais.

## 5.7 CENÁRIOS DE USO

Com o intuito de demonstrar o uso do MRSSEC, cenários de uso foram criados. De acordo com Rosson e Carrol (2002), “um cenário é uma narrativa, textual ou pictórica, concreta, rica em detalhes contextuais, de uma situação de uso da aplicação, envolvendo usuários, processos e dados reais ou potenciais”. Nesta seção, são apresentados Cenários onde o MRSSEC pode ser aplicado, a Tabela 2 apresenta 8 possibilidades de Cenários de uso.

Tabela 2 – Possíveis Combinações do MRSSEC em Cenários de Uso

Cenário	<i>Relacionamento</i>		Favoritos Usuário Similar	Localização
	Autoridade Cognitiva	Força do Laço		
1	X	X	X	X
2	-	X	X	X
3	X	X	-	X
4	-	X	-	X
5	X	X	X	-
6	-	X	X	-
7	X	X	-	-
8	-	X	-	-

Fonte: a Autora.

### 5.7.1 Cenário de Uso 1

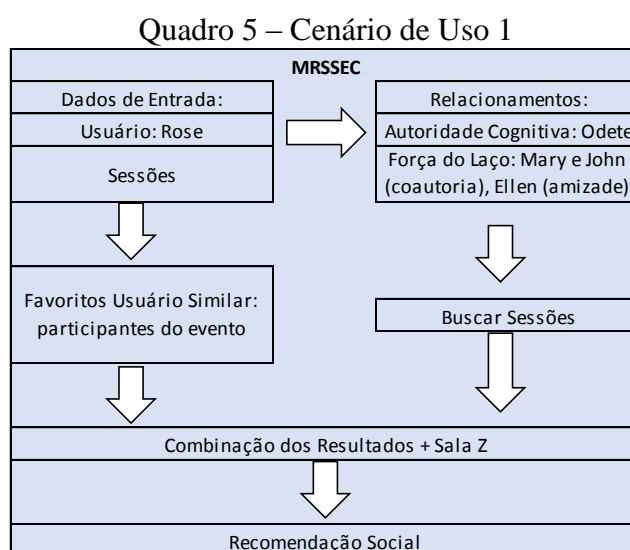
O Cenário de Uso 1 ilustra a aplicação completa do MRSSEC. Rose é aluna do curso de graduação em uma universidade e submeteu seu primeiro trabalho para um evento acadêmico em conjunto com professores da instituição, Mary e John. Com o aceite do trabalho, Rose foi até ao local do evento para realizar sua apresentação e prestigiar as demais. Ao chegar, Rose foi informada sobre um sistema desenvolvido para auxiliar os participantes a encontrarem sessões de apresentação e demais atividades, ela realizou o cadastro no sistema informando alguns dados pessoais (nome, sobrenome e e-mail) e a instituição de ensino a qual

representa. Rose permitiu que o sistema a localizasse em uma rede social de amizades. No sistema ela selecionou alguns tópicos de interesse e a autora que deseja seguir no evento, Odete, uma das pioneiras em publicações em pesquisas relacionadas aos interesses de Rose.

O sistema localizou na base de dados de Autoria do evento os coautores de Rose, Mary e John, e a sessões de apresentações em que possuem trabalhos a serem apresentados, exibindo recomendações de sessões por frequência de interações, nesse caso por meio de relacionamento de coautoria.

Por meio da rede social de amizades, o sistema também procurou amigos com maior número de amizades em comum. Dentre os amigos considerados laços fortes, Ellen possui um trabalho a ser apresentado no evento atual. O sistema recomendou o trabalho de Ellen para Rose. O sistema apresentou também recomendações baseadas na similaridade de tópicos de interesse, ou seja, encontrou usuários que selecionaram os tópicos de interesse similares aos de Rose e recomendou as sessões que esses usuários favoritaram, diferentes às favoritadas por ela.

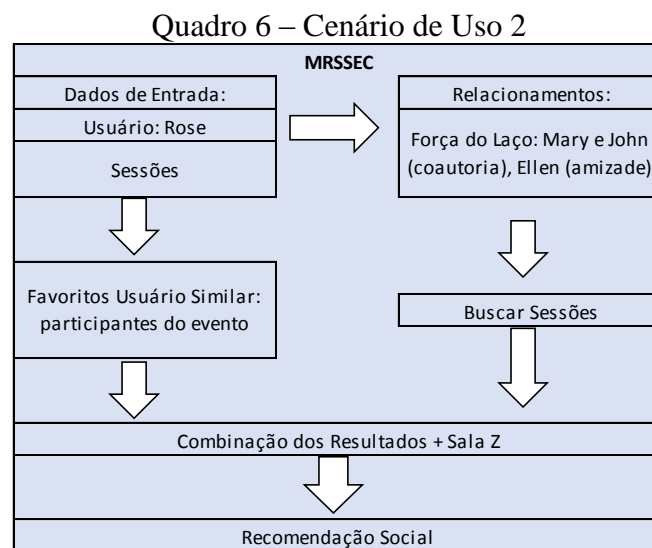
O sistema apresentou à Rose as sessões de apresentações em que a autora Odete está presente. O evento está sendo realizado em um grande pavilhão, possuindo um auditório, diversas salas, entre outros espaços com apresentações e exposições de trabalhos. Rose utiliza o sistema em seu dispositivo móvel e fez *check-in* via *QR-Code* ao entrar na Sala Z para assistir a uma apresentação. A sua localização foi identificada pelo sistema e, portanto, Rose recebeu também uma recomendação de sessão de apresentação que ocorrerá na mesma sala, após o término da sessão atual. O esquema deste cenário é representando no Quadro 5.



Fonte: a Autora.

### 5.7.2 Cenário de Uso 2

No Cenário de Uso 2, conforme Quadro 6, a diferença em relação ao Cenário 1 é a inexistência do Relacionamento Autoridade Cognitiva, que é opcional tanto na implementação do modelo, por ser flexível, como na ação do usuário, que pode optar por não selecionar nenhuma pessoa para seguir (i.e., nenhuma autoridade cognitiva). Portanto, no Cenário de Uso 2 o usuário alvo Rose não recebe recomendações por meio da Autoridade Cognitiva, ou seja, não “segue” a autora Odete. As demais recomendações permanecem conforme exemplificado no Cenário de Uso 1.

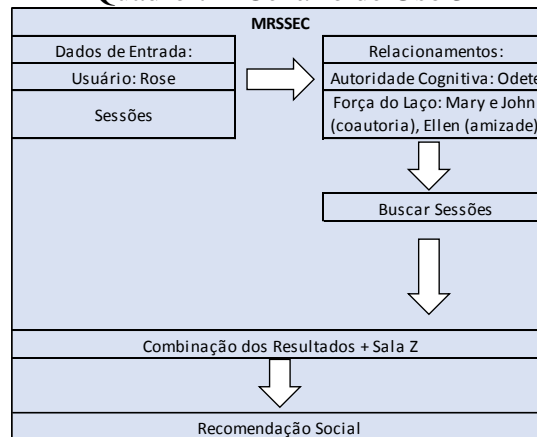


Fonte: a Autora.

### 5.7.3 Cenário de Uso 3

No Cenário de Uso 3, conforme Quadro 7 não há recomendações com base nos Favoritos do Usuário Similar. O usuário pode optar por não selecionar tópicos de interesse ou o desenvolvedor pode não implementar esta função. Desse modo, no Cenário de Uso 3 o usuário alvo Rose não recebe esse tipo de recomendação. As demais recomendações permanecem conforme exemplificado no Cenário de Uso 1.

Quadro 7 – Cenário de Uso 3

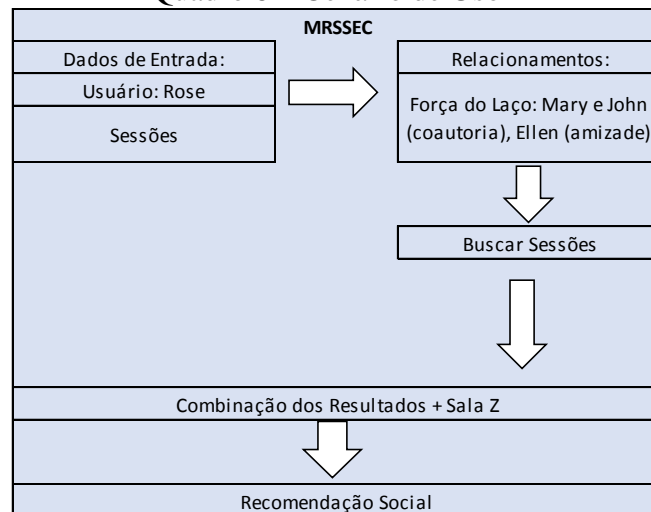


Fonte: a Autora.

#### 5.7.4 Cenário de Uso 4

O Cenário de Uso 4 demonstra o uso parcial do MRSSEC. Neste cenário, o usuário alvo não recebe recomendações por Autoridade Cognitiva e nem por Favoritas do Usuário Similar. Rose receberá recomendações por meio da Força do Laço e por Localização, demonstrado no Quadro 8.

Quadro 8 – Cenário de Uso 4

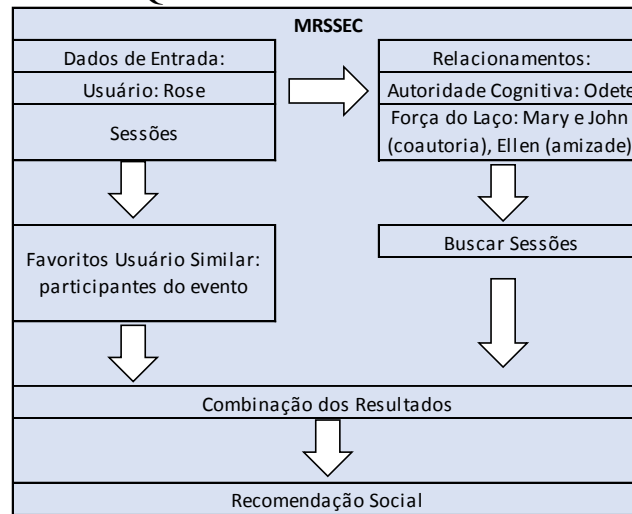


Fonte: a Autora.

#### 5.7.5 Cenário de Uso 5

O Cenário de Uso 5 apresenta a aplicação do MRSSEC sem a Localização, conforme Quadro 9, o usuário alvo Rose recebe recomendações por Autoridade Cognitiva, Força do Laço e Favoritos do Usuário Similar.

Quadro 9 – Cenário de Uso 5

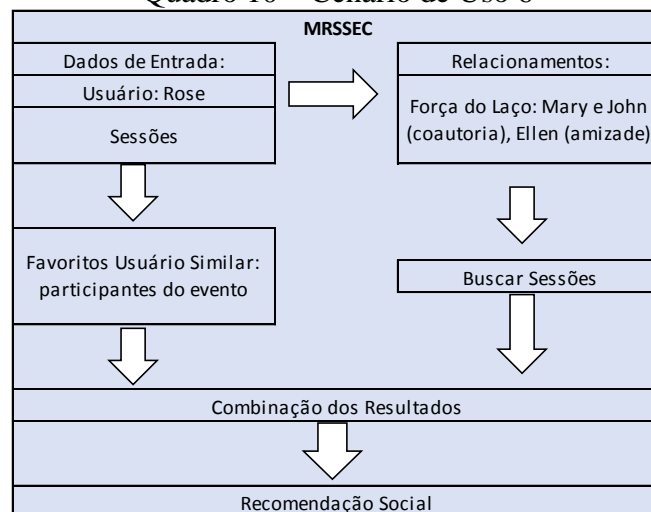


Fonte: a Autora.

### 5.7.6 Cenário de Uso 6

O Cenário de Uso 6 apresenta a aplicação do MRSSEC sem a Localização e sem Autoridade Cognitiva, conforme Quadro 10, o usuário alvo Rose recebe recomendações por Força do Laço e Favoritos do Usuário Similar.

Quadro 10 – Cenário de Uso 6



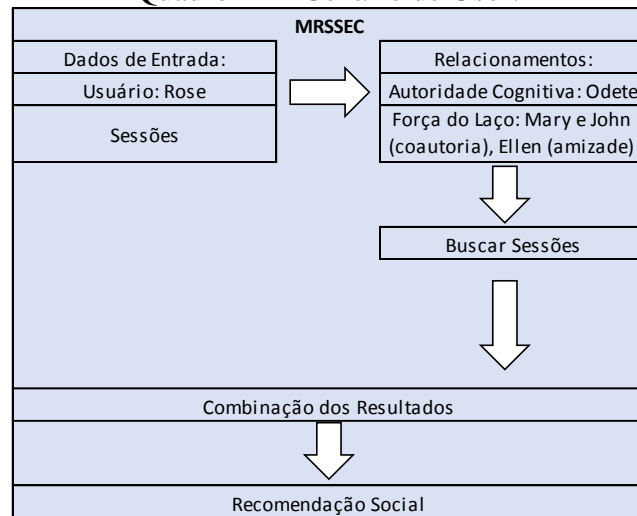
Fonte: a Autora.

### 5.7.7 Cenário de Uso 7

O Cenário de Uso 7 apresenta a aplicação do MRSSEC sem a Localização e sem Favoritos do Usuário Similar, conforme Quadro 11, o usuário alvo recebe recomendações por Autoridade Cognitiva e Força do Laço.



Quadro 11 – Cenário de Uso 7

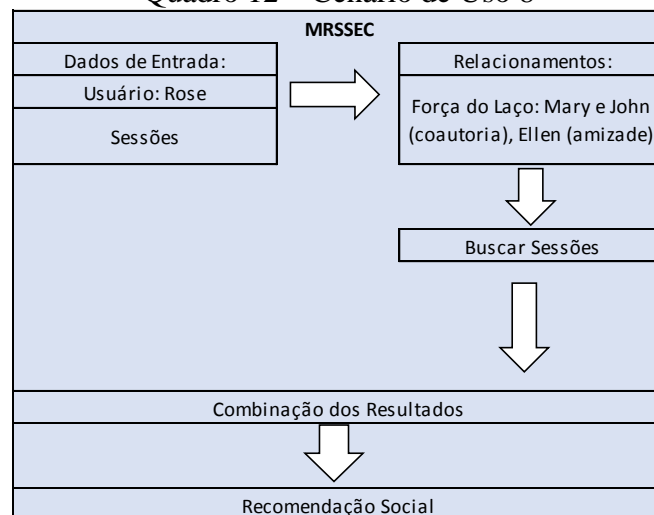


Fonte: a Autora.

### 5.7.8 Cenário de Uso 8

O Cenário de Uso 8 apresenta a aplicação do MRSSEC sem a Localização, sem Favoritos do Usuário Similar e sem Autoridade Cognitiva, conforme Quadro 12, o usuário alvo recebe recomendações por Força do Laço.

Quadro 12 – Cenário de Uso 8



Fonte: a Autora.

## 5.8 CONSIDERAÇÕES DO CAPÍTULO

Neste capítulo foi apresentado o MRSSEC, um modelo de recomendação social. O MRSSEC é um modelo flexível que pode ser parcialmente implementado e possui os 3 componentes essenciais: *Usuário*, *Sessões* e *Rede Social*.

O Relacionamento do usuário alvo pode ser obtido por meio da Autoridade Cognitiva, ao indicar um autor para seguir, ou pela Força do Laço quando são encontrados nas redes ou base de dados sociais.

O MRSSEC também possui um método denominado Favoritos do Usuário Similar, que busca por usuário similar por meio da seleção de tópicos de interesse e das sessões favoritas, recomendando apenas as sessões que o usuário alvo não favoritou.

A Localização também pode ser utilizada para filtrar as recomendações, ficando a critério do desenvolvedor a escolha do método.

Os resultados são agregados e apresentados ao usuário alvo. A apresentação da recomendação deve respeitar a prioridade dos critérios, sendo a recomendação que envolve a ação do usuário a mais importante.

São sugeridas métricas para determinar a Força do Laço e a Similaridade de Tópicos de Interesse com base na Fundamentação Teórica, Mapeamento Sistemático e nos Trabalhos Relacionados. Porém, devido à flexibilidade do modelo e as diferentes possibilidades de aplicação, o desenvolvedor pode utilizar as métricas que melhor se ajustem ao cenário em que será aplicado o modelo.

Cenários de Uso foram apresentados para exemplificar o modelo e a sua flexibilidade, para que possa ser utilizado em diferentes eventos científicos. O Relacionamento Força do Laço é um método obrigatório em todos os cenários por ser a *Rede Social* um componente essencial do MRSSEC.

## 6 APLICAÇÃO DO MRSSEC

Este Capítulo apresenta dois estudos de caso de aplicação do MRSSEC que foram realizados em situação real para avaliação do modelo proposto. O modelo foi aplicado no Simpósio Brasileiro sobre Fatores Humanos em Sistemas Computacionais (IHC), que em 2017 ocorreu no mês de outubro na cidade de Joinville, Santa Catarina, e em 2018, também em outubro, na cidade de Belém no estado do Pará.

### 6.1 IHC 2017

Esta seção apresenta a aplicação do modelo MRSSEC em um experimento realizado durante o evento IHC 2017 em Joinville SC.

#### 6.1.1 Planejamento

Para a implementação do modelo foi necessário definir os componentes *Usuário*, *Sessões* e *Rede Social*. Os dados dos trabalhos completos publicados e apresentados no IHC no Brasil foram reunidos e armazenados em uma base de dados por um grupo de pesquisadores. Nesta base de dados foram inseridos trabalhos de 1998 à 2015. Essa base possui dados sobre os trabalhos e seus autores. Portanto, desta base foi possível obter a rede de coautoria para a aplicação do MRSSEC no evento IHC 2017. O componente *Usuário* é formado pelos participantes previamente inscritos no evento, o componente *Sessões* são as sessões de apresentações de trabalhos submetidos e aceitos para o evento, e a *Rede Social* é extraída da base de dados de autoria dos eventos do IHC no Brasil. A Tabela 3 apresenta os componentes essenciais do MRSSEC implementados neste experimento.

Tabela 3 – Componentes do MRSSEC IHC 2017

<i>Componente</i>	<i>Característica</i>
<i>Usuário</i>	Inscritos no evento IHC 2017
<i>Sessões</i>	Sessões de Apresentações do IHC 2017
<i>Rede Social</i>	Base de dados trabalhos do IHC Brasil (1998-2015)

Fonte: a Autora.

Após a definição dos componentes *Usuário*, *Sessões* e *Rede Social*, foi necessário definir como o modelo seria implementado. Neste experimento, o MRSSEC foi desenvolvido para uso em um aplicativo para dispositivos móveis, o AppIHC, que é um aplicativo *open source* desenvolvido para o Sistema Operacional Android com o uso de *guidelines* do *Material*

*Design* e foi desenvolvido para apoiar os participantes no IHC2017 utilizando o banco de dados *Firebase* (OLIVEIRA *et al.*, 2017).

Nesta aplicação do MRSSEC, apenas o Relacionamento Força do Laço, foi implementado. Portanto, a recomendação por Força do laço foi realizada por meio da rede de coautoria do IHC, e o cenário de uso em que o experimento se enquadra. Conforme apresentado na Tabela 2 do Capítulo 5, este constitui o cenário de uso 8.


Oliveira (2018) desenvolveu um SR baseado em conteúdo que foi adicionado ao AppIHC e visando minimizar os possíveis conflitos e tempo de processamento no momento de uso do aplicativo, a recomendação social foi processada antes da realização do evento por meio da lista de inscritos.

### 6.1.2 Implementação

Um *script* foi desenvolvido com a linguagem de programação PHP (acrônimo recursivo de *Hypertext Preprocessor*). Os dados de entrada, por meio da lista de inscritos no evento, foram: nome, sobrenome e instituição. Esses dados foram utilizados para, além de encontrar o usuário na base de coautoria e gerar as recomendações, identificar o usuário no momento do cadastro na aplicação em que o modelo foi implementado (AppIHC).

A rede de coautoria foi representada como um grafo não direcionado, os autores são os vértices e as publicações são as arestas. O objetivo é quantificar o número de publicações em coautoria, ou seja, quantas arestas cada par da rede possui. Assim, de acordo com a Figura 3, a relação de coautoria entre dois autores, vértices  $p2$  e  $p3$ , é representada por uma ligação em destaque, pois possuem mais de um trabalho em conjunto.

Figura 3 - Representação da Força do Laço na Rede de Coautoria



Fonte: a Autora.

Dessa forma, considera-se que quanto maior o número de publicações em coautoria, mais forte é a relação entre os autores e a recomendação para o usuário alvo é gerada com base nas publicações dos coautores, as quais o usuário alvo não seja autor no evento em

questão. Os pares são selecionados e o desempate é realizado por meio da coautoria mais recente. Se o usuário não possuir uma relação de coautoria forte na rede, os laços fracos também são analisados e a recomendação é gerada da mesma forma. Quando não existem laços a serem analisados, não são geradas recomendações.

O cálculo da Força do Laço foi desenvolvido e aplicado neste experimento para obter uma medida que identifica o coautor que possua a maior quantidade de trabalhos com um usuário alvo  $u$ . Seja  $C(p)$  o conjunto de coautores de  $p$  e  $V_{p,k}$  a quantidade de publicações que  $p$  tem com um usuário  $k \in C(p)$ , a Força do Laço de Coautoria é definida pela equação:

$$FRCoatoria(u) = \{k : p \in C(p), \max(V_{p,k})\} \quad (4)$$

Ao final do processamento um arquivo *JavaScript Object Notation* (JSON) (W3SCHOOLS, 2018) foi gerado com a relação de trabalhos a serem recomendados para cada usuário inscrito identificado na base de coautoria, a Figura 4 exemplifica o formato dos dados no arquivo.

Figura 4 – Dados de Coautoria do Participante no formato JSON

```
"06": {
  "nome": "Isabela",
  "sobrenome": "Gasparini",
  "instituicao": "UDESC",
  "recomendados": {
    "coautoria": {
      "-KvnGe6a_znc1CzbWycd": "1508841000",
      "-KvnGe6a_znc1CzbWycd": "1508848200"
    }
  },
  "07": {
    "nome": "Roberto",
    "sobrenome": "Pereira",
    "instituicao": "UFPR",
    "recomendados": {
      "coautoria": {
        "-KvmygGFPxdLae1HSdiP": "1508841000",
        "-Kvn83NLPvcWLGiCoRhU": "1509021000",
        "-KvnC7KlHXFnQ0fVBsaD": "1509107400"
      }
    }
  }
}
```

Fonte: a Autora.

O arquivo JSON foi importado para a base de dados do aplicativo que realiza a apresentação da recomendação para o usuário alvo.

### 6.1.3 Teste Piloto

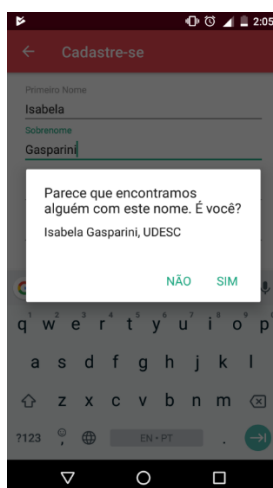
Antes da execução do experimento com usuários reais, foram realizados testes com os 5 integrantes da equipe de desenvolvimento e com 11 voluntários, alunos da disciplina IHC ministrada pela professora Dra. Isabela Gasparini na Universidade do estado de Santa Catarina. Foram criados 6 perfis de usuários coautores para simular as recomendações. Também foram realizados testes em relação ao envio do arquivo para a base de dados e a validação dos dados enviados. Os *feedbacks* dos usuários foram positivos em relação à apresentação implícita da recomendação. Não foi possível coletar a percepção dos participantes em relação à relevância da recomendação por coautoria, pois alguns perfis foram criados apenas para a simulação, não representando autores reais.

### 6.1.4 Execução

No primeiro dia do evento, a organização iniciou um trabalho de divulgação do AppIHC. Os participantes ao realizarem o credenciamento eram convidados a instalar o aplicativo disponível no *Play Store* (GOOGLE, 2018)

Por meio da lista de inscritos no evento atual e de seus relacionamentos de coautoria, obtidos da base de dados de publicações do evento nos anos anteriores, foi possível pré-processar a recomendação. Portanto, o usuário alvo ao realizar seu cadastro no AppIHC, informando nome e sobrenome, recebia uma notificação indicando que foi identificado na base de dados da aplicação, e o sistema solicita-o que confirme se é realmente ele, desse modo seus dados básicos são preenchidos automaticamente, conforme Figura 5.

Figura 5 - Identificação do Usuário no AppIHC

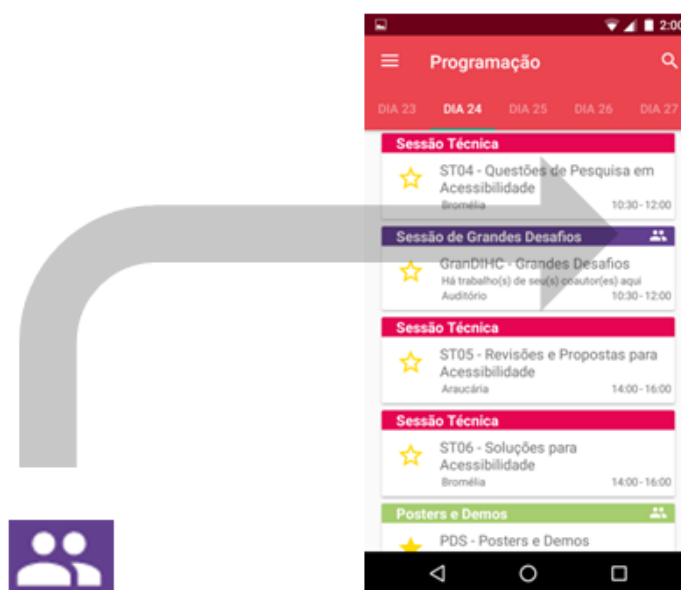


Fonte: (APPIHC, 2017).

Os usuários que foram encontrados na base de coautoria puderam aproveitar a facilidade do pré-cadastro.

A recomendação social por coautoria foi adicionada de forma implícita, exibida textualmente e por meio de ícone social na programação do evento, apresentada por dia de acordo com a Figura 6.

Figura 6 - Ícone Social e Recomendação Social



Fonte: a Autora.

### 6.1.5 Análise

O IHC2017 teve 250 participantes, 108 utilizaram o aplicativo. O algoritmo identificou 35 participantes, previamente inscritos no evento, que são coautores na base do IHC, porém apenas 14 destes participantes instalaram o aplicativo, e consequentemente, receberam recomendação por coautoria. Essa quantidade pode estar relacionada à restrição de que o aplicativo foi desenvolvido somente para plataforma *Android*.

Como forma de avaliar as recomendações, um questionário foi enviado após o evento para os 14 coautores que usaram o aplicativo, 8 usuários responderam as seguintes perguntas:

Quadro 13 – Questões Fechadas

	Sim	Não Opinou	Não
Q1- Você percebeu a indicação de que em determinada sessão existia(m) seu(s) coautor(es)?	5	2	1
Q2- Essa informação influenciou seu processo de decisão a quais sessões assistir?	1	2	5
Q3- Você considera útil a indicação de coautoria para recomendar sessões?	5	2	1

Fonte: a Autora.

No Quadro 13, percebe-se que a maioria afirma não ter sido influenciado ao decidir a qual sessão assistir, porém, a maioria também afirma ser útil a indicação de coautoria. Desse modo, entende-se que o usuário não utilizou a recomendação para a tomada de decisão mas achou interessante saber que os trabalhos de seu(s) coautor(es) estão em determinada sessão. Essa informação foi triangulada analisando o registro de atividades dos usuários no *Firebase*. Foi possível identificar que um dos cinco que afirmaram não terem sido influenciados pela recomendação de coautoria marcou a sessão recomendada como favorita. Isso indica que apesar de o usuário considerar não ter sido influenciado, gostou da sessão recomendada.

As demais questões do questionário eram abertas e tinham como objetivo identificar sugestões de melhorias para o processo de recomendação, com e sem o uso de elementos sociais. Essas sugestões possibilitam o levantamento de requisitos para o aprimoramento do modelo de recomendação e também do aplicativo. As questões abertas aplicadas foram: (1) Por favor, nos diga quais outros critérios você acha interessante utilizarmos para gerar recomendações de sessões? (2) Quais outros elementos sociais você considera importante para gerar recomendações em sessões de eventos científicos? (3) Quais outros elementos sociais você considera importante para gerar recomendações de uma forma geral? (4) Quais são suas sugestões de melhorias para o sistema de recomendação?

No âmbito das questões sociais, os usuários sugerem: permitir selecionar e visualizar os interesses dos coautores; criar uma rede de amigos, adicionando pessoas da comunidade acadêmica, não necessariamente coautores; compartilhar preferências, interesses e trabalhos a serem apresentados, com devido consentimento; recomendar e receber recomendações de outros usuários.



## 6.2 IHC 2018

Esta seção apresenta a aplicação do modelo MRSSEC em um experimento realizado durante o evento IHC 2018 em Belém PA. A execução do experimento no IHC 2017 contribuiu para melhoria do modelo e do planejamento do experimento para o IHC 2018.

### 6.2.1 Planejamento

Para a implementação do modelo neste segundo experimento foi necessário definir os componentes *Usuário*, *Sessões* e *Rede Social*. A base de dados utilizada foi a mesma utilizada no experimento anterior. Porém, a base foi atualizada com os artigos completos e artigos resumidos apresentados no IHC 2017. Desta base foi possível obter a rede de coautoria para a aplicação do MRSSEC no evento IHC 2018. O componente *Usuário* é formado pelos participantes no evento, uma lista de participantes inscritos foi enviada pela coordenação do evento. O componente *Sessões* são as sessões de apresentações de trabalhos submetidos e aceitos para o evento, estas sessões foram recebidas pela coordenação do evento, também disponível no site do evento (<http://www.ihc2018.ufpa.br>). A *Rede Social* é extraída da base de trabalhos completos publicados e apresentados no evento IHC no Brasil. A Tabela 4 apresenta os componentes do MRSSEC implementados neste experimento.

Tabela 4 – Componentes do MRSSEC IHC 2018

<i>Componente</i>	<i>Característica</i>
<i>Usuário</i>	Participantes no evento IHC 2018
<i>Sessões</i>	Sessões de Apresentações do IHC 2018
<i>Rede Social</i>	Base de dados trabalhos do IHC Brasil (1998-2015 e 2017)

Fonte: a Autora.

Neste experimento, o MRSSEC também foi desenvolvido para uso no aplicativo para dispositivos móveis, o AppIHC2018, que foi melhorado e foi disponibilizado para as plataformas *Android* e *IOS*, utilizando banco de dados *Firebase*. Além disso, o usuário tem a opção de favoritar sessões para compor a sua própria agenda, exibindo as sessões que ele favoritou por dia.

Nesta aplicação do MRSSEC os métodos implementados foram Favoritos do Usuário Similar, Autoridade Cognitiva e Força do Laço, somente a Localização não foi implementada, pois o evento é de pequeno porte e as sessões ocorrem em poucos ambientes e, geralmente, muito próximos. O cenário de uso em que o experimento se enquadra, conforme apresentado na Tabela 2 do Capítulo 5, é o Cenário de Uso 5. As recomendações por Autoridade

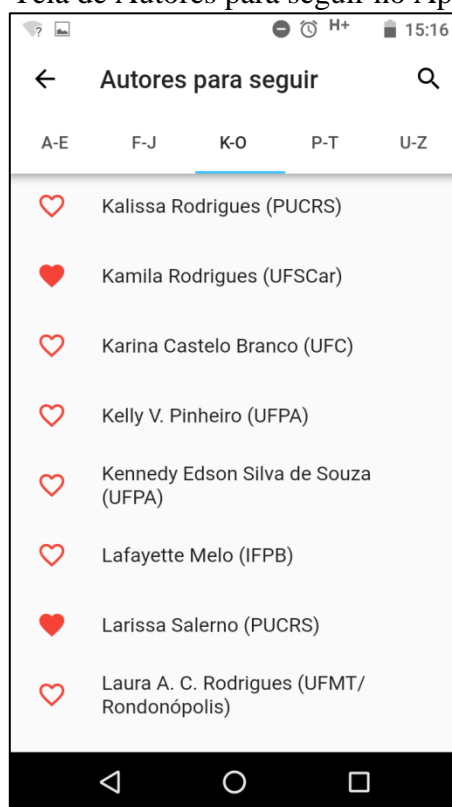
Cognitiva e Favoritas do Usuário Similar foram planejadas para serem executadas em tempo real. Devido ao atraso na entrega do aplicativo AppIHC2018, não foi possível realizar um teste piloto.

### 6.2.2 Implementação

O modelo foi desenvolvido em *Python*, pois a linguagem possui bibliotecas que permitem a comunicação com o banco de dados *Firebase* e possibilita o processamento das recomendações em tempo real no servidor, para posteriormente serem apresentadas no AppIHC2018. Portanto, o modelo foi implementado para ser processado em um servidor web e fazer comunicação com a base de dados do AppIHC2018.

No AppIHC2018 é possível Selecionar Autores para Seguir conforme Figura 7. Os autores selecionados são adicionados ao perfil do usuário, e a recomendação por Autoridade Cognitiva é realizada filtrando-se as sessões em que estes autores estão presentes.

Figura 7 – Tela de Autores para seguir no AppIHC 2018



Fonte: (APPIHC, 2018).

A recomendação por Força do laço foi realizada por meio da rede de coautoria do IHC, semelhante ao experimento anterior. Um *script* em PHP foi desenvolvido e os dados de entrada foram nome e sobrenome por meio da relação dos participantes inscritos no evento.

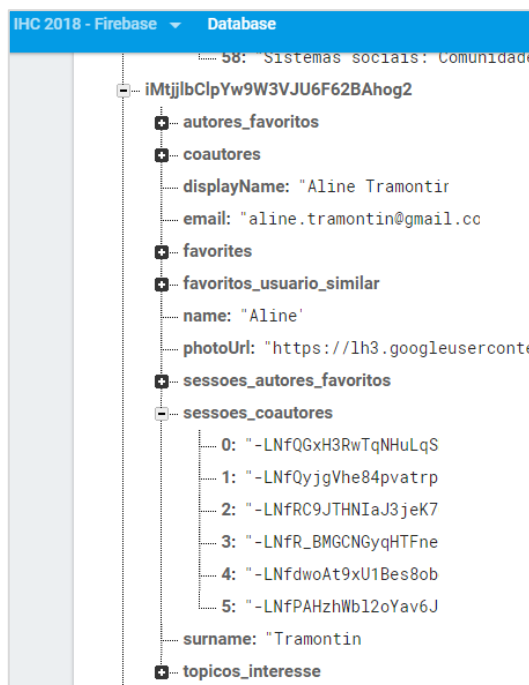
Porém, neste experimento todos os laços são considerados com o intuito de alcançar o maior número de relacionamentos possível. Desse modo, o desempate por coautoria mais recente também não é realizado.

Os dados dos inscritos no evento foram pré-processados localizando-se os coautores na base de dados do IHC. Os dados dos inscritos e de seus respectivos coautores foram armazenados em um arquivo JSON que foi adicionado no servidor no qual a rotina foi executada.

Quando a recomendação é processada no servidor, todos os usuários que instalaram o aplicativo são percorridos e, para cada usuário é realizada uma consulta no arquivo JSON buscando identificá-lo por meio do sobrenome e do nome. Caso o usuário seja identificado, seus coautores são armazenados em seu perfil no *Firebase* e uma busca das sessões em que seus coautores estão presentes é realizada. As sessões são armazenadas na base de dados juntamente com o perfil do usuário conforme a Figura 8.

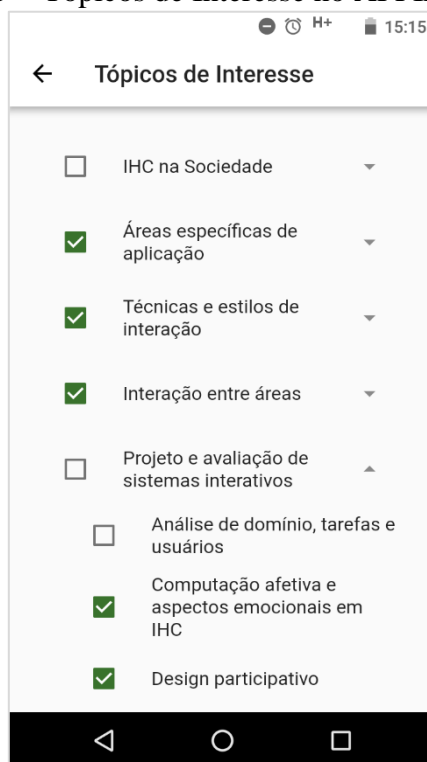
Para realizar a recomendação de sessões Favoritas do Usuário Similar, foram disponibilizados tópicos de interesse para o usuário selecionar no AppIHC 2018, de acordo com a Figura 9.

Figura 8 – Dados de Coautoria Armazenados ao Perfil do Usuário no *Firebase*



Fonte: *Firebase* (Google, 2018)

Figura 9 – Tópicos de Interesse no APPIHC 2018



Fonte: (APPIHC, 2018)

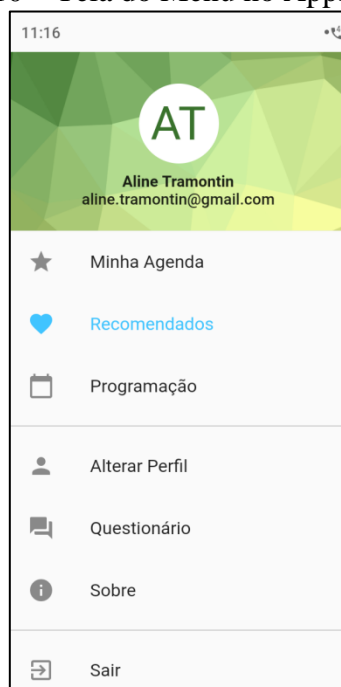
Neste estudo, por meio da seleção dos tópicos de interesse e realizando cálculo do Cosseno (Fórmula 2, Seção 2.2), foi possível identificar os dez usuários mais similares ao usuário alvo. Dentre os dez usuários mais similares, uma busca por sessões favoritas e diferentes das sessões do usuário alvo foi realizada, identificando assim o usuário mais similar com sessões diferentes a serem recomendadas. As sessões diferentes do usuário similar são armazenadas no perfil do usuário alvo.

A rotina desenvolvida em *Python* foi planejada para ser executada a cada dez minutos. Dessa forma, todos os usuários da base de dados do AppIHC2018 são percorridos para serem verificadas mudanças na seleção de Autores para Seguir, ou nos Tópicos de Interesse, pois as recomendações são processadas novamente. No caso da Força do Laço são verificados os usuários que ainda não tenham recomendações por coautoria em seu perfil, a recomendação por coautoria é gerada uma única vez.

### 6.2.3 Apresentação da Recomendação

Após realizar o registro no AppIHC2018, o usuário é direcionado para as telas de Tópicos de Interesse e Autores para Seguir (ações opcionais), e em seguida o usuário pode acessar a opção Recomendados no menu do aplicativo (Figura 10).

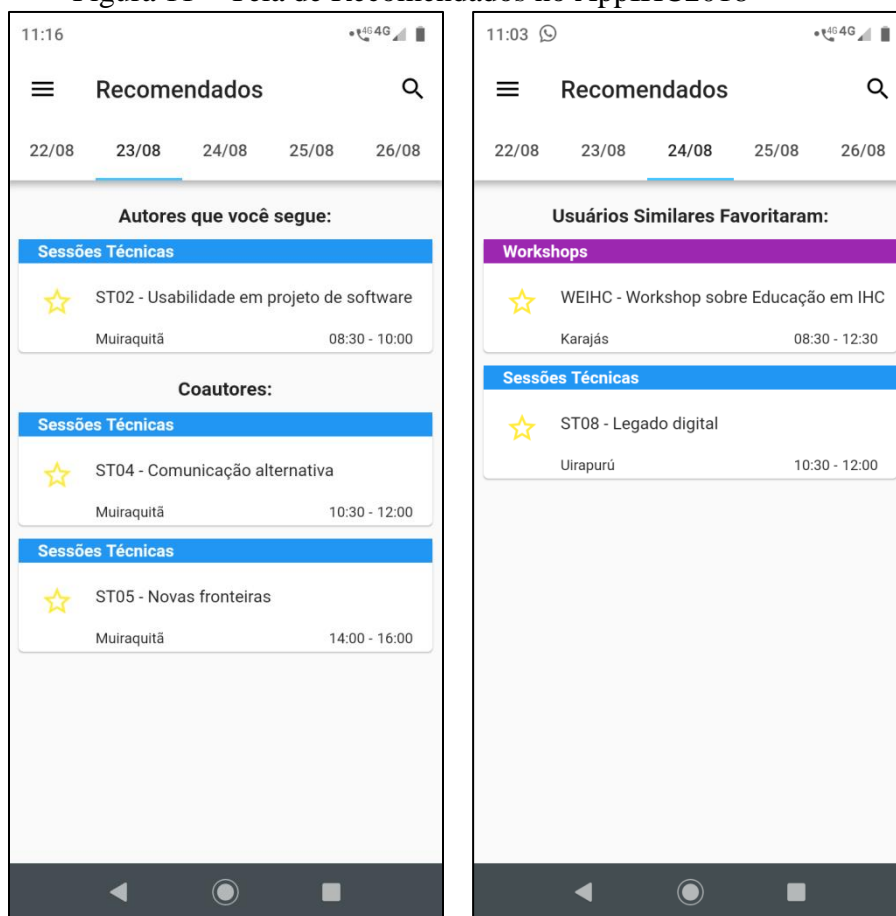
Figura 10 – Tela do Menu no AppIHC2018



Fonte: (APPIHC2018, 2018)

As recomendações são exibidas por dia, semelhante a uma agenda, na qual o usuário navega selecionando o dia em que deseja visualizar as sessões recomendadas. Na Figura 11 é possível observar a apresentação da recomendação das sessões por dia, como por exemplo, no dia 23/08 o usuário recebeu recomendações baseadas em Autoridade Cognitiva (autores que segue) e em Força do Laço (coautores). No dia 24/08 o usuário recebeu recomendações baseadas em sessões que os usuários similares favoritaram.

Figura 11 – Tela de Recomendados no AppIHC2018



Fonte: (APPIHC, 2018)

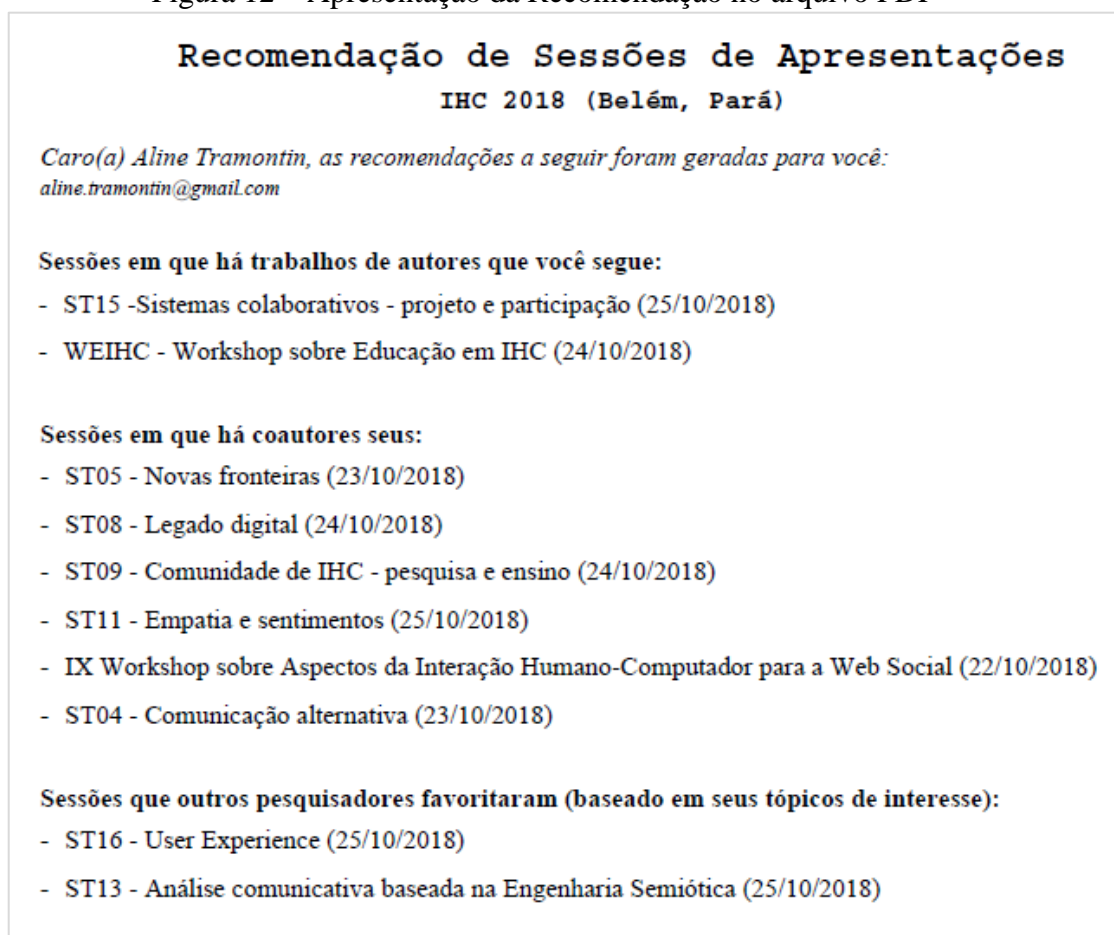
#### 6.2.4 Execução

No primeiro dia do evento a organização iniciou um trabalho de divulgação do AppIHC. Os participantes foram convidados a instalar o aplicativo disponível no *Play Store* (GOOGLE, 2018) e *App Store* (APPLE, 2018).

Durante o primeiro dia do evento quatro usuários relataram que estavam recebendo as recomendações corretamente. Porém, no segundo dia, realizando-se testes observou-se que as recomendações não estavam sendo geradas e, não havia um responsável técnico disponível para identificar o problema de comunicação entre o aplicativo e o servidor em que a rotina de recomendação era executada. Por este motivo, as recomendações não foram geradas em tempo real para todos os usuários durante o evento. Após a realização do evento, analisando a base de dados foi possível constatar que apenas os quatro participantes receberam recomendações durante o evento.

Buscando uma alternativa para este problema, as recomendações foram processadas após o evento para todos os usuários registrados na base de dados *Firebase*, ou seja, que usaram o AppIHC2018. Para cada usuário, foram gerados relatórios contendo as recomendações de sessões. Um e-mail foi enviado para cada usuário explicando o objetivo do estudo. Em anexo ao e-mail foram enviados dois arquivos, o primeiro com as recomendações e o segundo com a programação do evento para lembrar o usuário quando cada sessão foi realizada. Foi solicitado ao usuário que respondesse um questionário (Apêndice A) sobre a recomendação recebida. A Figura 12 apresenta como a recomendação gerada foi exibida para o usuário no arquivo.

Figura 12 – Apresentação da Recomendação no arquivo PDF



Fonte: a Autora.

A análise das respostas foi triangulada com os dados de uso coletados durante o evento e serão apresentadas na seção 6.2.5.

### 6.2.5 Análises

O IHC 2018 teve 294 inscritos, 98 usuários instalaram o aplicativo, 2 usuários inscritos não participaram do evento e 1 usuário do aplicativo não estava inscrito no evento. Durante o evento, 4 usuários receberam recomendações. Porém, devido ao problema de comunicação com o AppIHC2018 as recomendações não foram apresentadas durante o evento. Desta forma, após o evento as recomendações foram geradas para os usuários inscritos que utilizaram o aplicativo, 77 usuários receberam recomendações, e 18 usuários não receberam nenhum tipo de recomendação. As recomendações que foram geradas para os 77 usuários foram enviadas por e-mail, anexadas com a programação e um *link* para responder a um questionário.

As questões do questionário foram divididas em 3 seções de acordo com o tipo de recomendação: (i) *Força do Laço*, (ii) *Autoridade Cognitiva* e (iii) *Favoritos do Usuário Similar*. Cada participante foi instruído a responder apenas as seções que representam o tipo de recomendação recebida, pois muitos participantes receberam mais de um tipo de recomendação. Portanto, o número de respostas é maior que o número de respondentes.

Dos 77 usuários (população) que receberam recomendações, 46 (amostra) responderam a pesquisa, representando 60% da população. Porém, dois participantes não responderam as questões de acordo com a recomendação recebida, dessa forma o número de participantes com respostas válidas foi 44, representando 58% da população.

Na Tabela 5 são apresentados dados que representam a quantidade de participantes e o tipo de recomendação, agrupadas em *População* (n=77), *Amostra* (n=46) e *Respostas Válidas* (n=44) da amostra. Portanto, são 44 respondentes, e destes foram recebidas 9 respostas de recomendações por *Força do Laço*, 22 respostas de recomendações por *Autoridade Cognitiva* e 42 respostas de recomendações por *Favoritos do Usuário Similar*.

Tabela 5 – Quantidade de Respostas do Questionário

Tipo de Recomendação	População (n=77)	Amostra (n=46)	Respostas Válidas (n=44)
<i>Força do Laço</i>	15	9	9
<i>Autoridade Cognitiva</i>	38	24	22
<i>Favoritos do Usuário Sim.</i>	74	44	42
	<i>Total de Respostas</i>		73

Fonte: a Autora.

A análise do questionário é qualitativa, buscando analisar a percepção do usuário quanto às recomendações recebidas, e os dados de uso do AppIHC2018 são analisados para ajudar a compreender a percepção do usuário em relação a recomendação social.



Duas questões do questionário são comuns a todas as 3 seções: (a) “As recomendações são relevantes?” e (b) “Você assistiu a alguma das sessões recomendadas?”.

Para a questão (a) foi apresentada uma escala de *Likert* de 5 pontos, de 1-Totalmente Irrelevante, 2-Irrelevante, 3-Indiferente, 4-Relevante e 5-Totalmente Relevante, considera-se o ponto 4 (Relevante), um valor positivo.

Para a questão (b) foi apresentada uma escala percentual, Nenhuma sessão recomendada (0%), Menos de 30% das sessões recomendadas, Entre 30% até 50% das sessões recomendadas e Mais de 50% das sessões recomendadas, considera-se a faixa percentual Entre 30% até 50% das sessões recomendadas, uma faixa positiva.

As outras questões visam compreender os motivos de o usuário considerar ou não as recomendações relevantes. As análises das respostas serão apresentadas nas seções a seguir de acordo com os tipos de recomendação.

Sobre o perfil do participante desta pesquisa, foi solicitado que informassem o *link* de seu currículo da Plataforma Lattes (CNPQ, 2019), para ser possível obter dados de atuação profissional e formação acadêmica. Nem todos os participantes informaram seus currículos, alguns foram encontrados por pesquisa textual através do nome completo, e apenas 1 não foi localizado.

Dentre os 46 participantes da pesquisa, 27 são estudantes, representando 59% da amostra, 17 são professores, representando 37% da amostra, 1 participante é secretário acadêmico e 1 participante não foi localizado na Plataforma Lattes, ambos representam 4% da amostra. A formação acadêmica dos participantes é apresentada na Tabela 6.

**Tabela 6 – Formação Acadêmica dos Participantes**

<b>Formação</b>	<b>Nº Participantes</b>
Doutorado	16
Doutorado em andamento	5
Mestrado	0
Mestrado em andamento	11
Especialização	1
Graduado	0
Graduação em andamento	11
Técnico	1
Não informou	1
<b>Total</b>	<b>46</b>

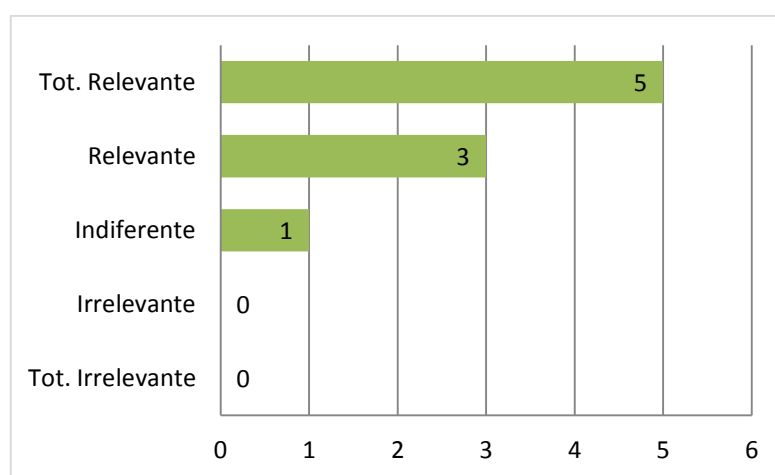
Fonte: a Autora.

Observando a Tabela 6 é possível visualizar que a maior parte dos participantes desta pesquisa são Estudantes (59%) seguidos de Professores (37%), sendo os Estudantes de Doutorado (5), Mestrado (11) e Graduação (11).

### 6.2.5.1 Análises Força do Laço

A recomendação pela Força do Laço foi realizada por Coautoria e foi gerada para os participantes que possuem coautores no evento atual (IHC 2018) com publicações em comum em outras edições do mesmo evento. Dos 9 participantes que receberam recomendação por Coautoria, 5 consideraram as recomendações Totalmente Relevante, 3 consideraram Relevante e 1 considerou Indiferente. Nenhum participante considerou as recomendações Totalmente Irrelevante ou Irrelevante, conforme Gráfico 2.

Gráfico 2 – Relevância das Recomendações por Coautoria



Fonte: a Autora.

Quanto ao perfil dos participantes que receberam a recomendação por Coautoria: 6 são Professores e 3 Estudantes. Percebe-se que estão envolvidos com pesquisas científicas relacionadas ao evento.

A Tabela 7 apresenta os motivos apontados pelos participantes que consideraram as recomendações relevantes mesmo que parcialmente. O questionário apresentou diversas opções relacionadas, e também deixou aberto para o participante escrever na opção “Outros”. Os participantes poderiam selecionar mais de um motivo.

Tabela 7 – Motivos pelo qual Considera a Recomendação Relevante

Motivo	Nº Respostas
Acho interessante saber que meus coautores estão presentes no evento	4
Tenho interesse na linha de pesquisa em que meus coautores trabalham atualmente	7
Gosto de prestigiar as apresentações de meus coautores	9

Fonte: a Autora.

Observando a Tabela 7 é possível constatar que 4 participantes selecionaram que acham interessante saber que seus coautores estão presentes no evento, 7 participantes selecionaram

“Tenho interesse na linha de pesquisa em que meus coautores trabalham atualmente” e todos os 9 participantes que receberam recomendação por coautoria, selecionaram “Gosto de prestigiar as apresentações de meus coautores”, inclusive o participante que se manifestou Indiferente.

Pode-se dizer que 44,44% acham interessante saber que seus coautores estão no evento, mas não necessariamente estão interessados na pesquisa em si, 77,77% destes participantes, tem interesse na mesma linha de pesquisa que seus coautores e 100% dos participantes que receberam este tipo de recomendação, gostam de prestigiar seus coautores, indicando a relevância da recomendação mesmo não estando relacionada ao interesse de pesquisa do participante.

Foi questionado aos participantes se assistiram às sessões recomendadas, opções de uma escala em percentual foram apresentadas e poderiam adicionar outra resposta pela opção “Outros”. Conforme Tabela 8, dentre os 9 participantes que receberam recomendações por coautoria, 3 participantes afirmaram ter assistido *Menos de 30% das sessões recomendadas*, 4 participantes afirmaram ter assistido *Entre 30% até 50% das sessões recomendadas*, 1 participante afirma ter assistido *Mais de 50% das sessões recomendadas* e outro participante *Não lembra* se assistiu as sessões recomendadas. Percebe-se que a maioria das respostas se concentra na faixa *Entre 30% até 50% das sessões recomendadas*, considerada uma referência positiva.

Tabela 8 – Coautoria – Respostas à “Você assistiu a alguma das sessões recomendadas?”

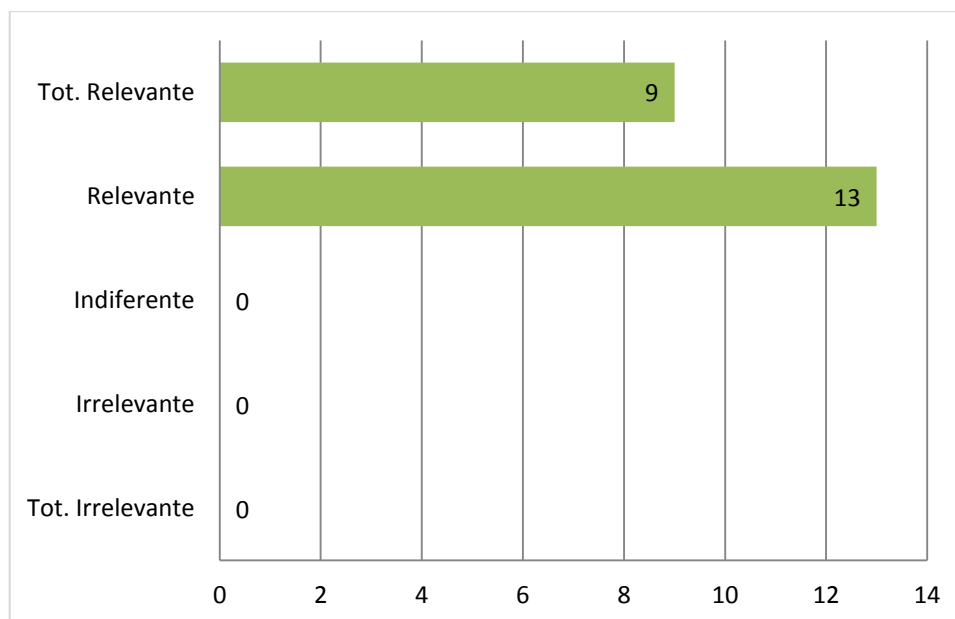
<b>Você assistiu a alguma das sessões recomendadas?</b>	<b>Nº Respostas</b>
Nenhuma sessão recomendada	0
Menos de 30% das sessões recomendadas	3
Entre 30% até 50% das sessões recomendadas	4
Mais de 50% das sessões recomendadas	1
Não lembra	1

Fonte: a Autora.

#### 6.2.5.2 Análises Autoridade Cognitiva

A recomendação por Autoridade Cognitiva foi gerada para os usuários que selecionaram Autores para “Seguir”. Dos 22 participantes que receberam recomendação por Autoridade Cognitiva, 9 consideraram as recomendações Totalmente Relevante e 13 consideraram Relevante. Nenhum participante considerou Irrelevante, Indiferente ou Totalmente Irrelevante, representado no Gráfico 3.

Gráfico 3 – Relevância das Recomendações por Autoridade Cognitiva



Fonte: a Autora.

Analisando o Gráfico 3 é possível perceber que as recomendações baseadas na Autoridade Cognitiva tem relevância para o participante, sendo que a ação de “Seguir” um autor está diretamente relacionada aos seus interesses.

Quanto ao perfil dos participantes que receberam a recomendação por Autoridade Cognitiva: 5 são Professores, 15 Estudantes, 1 Secretário Acadêmico e 1 não informou.

A Tabela 9 apresenta os motivos apontados pelos participantes que consideraram as recomendações relevantes. No questionário era possível selecionar mais de um motivo e o participante também poderia adicionar outro motivo na opção “Outros”.

Tabela 9 - Motivos pelo qual Considera a Recomendação Relevante

Motivo	Nº Respostas
São meus coautores e gostaria de encontrá-los no evento	5
São autores renomados e/ou prestigiados pela comunidade do IHC no Brasil	12
Tenho interesse na mesma linha de pesquisa em que os autores que sigo	13
Atuo ou tenho interesse em atuar na mesma linha de pesquisa em que os autores que sigo	15

Fonte: a Autora.

Na Tabela 9 observa-se que 5 (22,72%) participantes selecionaram que as sessões recomendadas são de coautores e gostariam de encontrá-los no evento, 12 (54,54%) participantes selecionaram que as sessões recomendadas são de autores renomados e/ou prestigiados pela comunidade do IHC no Brasil, 13 (59%) selecionaram que tem interesse na mesma linha de pesquisa dos autores que seguem e 15 (68%) selecionaram que atuam ou tem interesse em atuar na mesma linha de pesquisa dos autores que seguem.

A recomendação por Autoridade Cognitiva não é calculada, ela é a ação do usuário indicando quem ele deseja “Seguir” no evento. Os motivos apresentados ajudam a compreender a percepção do usuário em relação à sessão recomendada, e nesse caso percebe-se que a maioria, 68% dos participantes que receberam a recomendação por Autoridade Cognitiva, atuam ou tem interesse em atuar na mesma linha de pesquisa dos autores que seguem, indicando dessa forma o principal motivo pelo qual a recomendação foi considerada relevante.

Os participantes foram questionados se assistiram às sessões recomendadas, opções de uma escala em percentual foram apresentadas e poderiam adicionar outra resposta pela opção “Outros”. Conforme Tabela 10, dentre os 22 participantes que receberam recomendações por Autoridade Cognitiva, 2 participantes responderam que não assistiram *Nenhuma sessão recomendada*, 3 participantes afirmaram ter assistido *Menos de 30% das sessões recomendadas*, 4 participantes afirmaram ter assistido *Entre 30% até 50% das sessões recomendadas*, 10 participantes afirmaram ter assistido *Mais de 50% das sessões recomendadas*, 2 participantes não lembram se assistiram as sessões recomendadas e 1 participante diz ter assistido a *Todas as sessões recomendadas*.

Na Tabela 10 percebe-se que 4 respostas se concentram na faixa considerada positiva *Entre 30% até 50% das sessões recomendadas*, porém, 10 respostas estão acima desta faixa e 1 resposta, que foi adicionada pelo participante, corresponde a ter assistido 100% das sessões recomendadas. Portanto, estas respostas agrupadas também são consideradas positivas.

Tabela 10 – Autoridade Cognitiva – Respostas à “Você assistiu a alguma das sessões recomendadas?”

<b>Você assistiu a alguma das sessões recomendadas?</b>	<b>Nº Respostas</b>
Nenhuma sessão recomendada	2
Menos de 30% das sessões recomendadas	3
Entre 30% até 50% das sessões recomendadas	4
Mais de 50% das sessões recomendadas	10
Não lembra	2
Todas as sessões recomendadas	1


Fonte: a Autora.

### 6.2.5.3 Análises Favoritos do Usuário Similar

A recomendação de Favoritos do Usuário Similar foi gerada para os usuários que selecionaram tópicos de interesse similares a de outros usuários. Dentre os 42 participantes que receberam recomendações por Favoritos do Usuário Similar, 9 consideram Totalmente

Relevante, 18 Relevante, 10 Indiferente, 4 Irrelevante e 1 Totalmente Irrelevante, conforme apresentado no Gráfico 4.

Gráfico 4 - Relevância das Recomendações por Favoritos do Usuário Similar



Fonte: a Autora.

Vinte e sete participantes consideraram as recomendações entre Relevante e Totalmente Relevante, representando assim a maioria. Quanto ao perfil dos participantes: 14 são Professores, 26 Estudantes, 1 Secretário Acadêmico e 1 não informou.

A Tabela 11 apresenta os motivos apontados pelos participantes que consideraram as recomendações relevantes. No questionário era possível selecionar mais de um motivo e o participante também poderia adicionar outro motivo na opção “Outros”.

Tabela 11 - Motivos pelo qual Considera a Recomendação Relevante

Motivo	Nº Respostas
As sessões recomendadas possuem trabalhos de autores do meu interesse	11
As sessões recomendadas possuem trabalhos relacionados aos meus tópicos de interesse	25
Outros	
Me interessam temas interdisciplinares e de fronteira.	1
A maioria foram keynotes e eventos gerais, naturalmente interessantes	1

Fonte: a Autora.

Na Tabela 11 é possível observar que 11 (26%) dos 42 participantes que receberam a recomendação por Favoritos do Usuário Similar selecionaram o motivo “*As sessões recomendadas possuem trabalhos de autores do meu interesse*”, 25 (59,52%) participantes selecionaram o motivo “*As sessões recomendadas possuem trabalhos relacionados aos meus tópicos de interesse*”, e 2 participantes adicionaram seus próprios motivos. Um participante

disse *“Me interessam temas interdisciplinares e de fronteira”* e o outro disse *“A maioria foram keynotes e eventos gerais, naturalmente interessantes”*.

Buscando compreender as respostas dos participantes em relação ao Totalmente Irrelevante, Irrelevante e Indiferente, além dos dados de uso serem analisados, foi solicitado que apontassem os motivos por não considerar relevante.

O participante que considerou Totalmente Irrelevante disse: *“A maioria eram as sessões gerais, como keynotes e workshops, portanto de alta visibilidade, em que a recomendação é desnecessária. Não sei de onde saíram os tópicos de interesse, mas os tópicos recomendados não são os que eu buscaria numa conferência, então para mim não funcionou”*.

O participante afirma que as recomendações de sessões de alta visibilidade para ele são desnecessárias, isso não significa que são irrelevantes. Os tópicos de interesse deste participante foram consultados na base de dados do AppIHC2018 e foi possível constatar que todos os tópicos foram selecionados, ou seja, 58 tópicos. Dessa forma, a recomendação gerada realmente não é relevante para o participante. Porém, outro dado de uso analisado foi se o usuário favoritou sessões. O participante em questão recebeu 12 recomendações de sessões por *Favoritos do Usuário Similar*, das quais 6 ele havia selecionado como Favorito no aplicativo durante o evento, ou seja 50% das recomendações representavam algum interesse durante o evento.

Dos 4 participantes que consideraram as recomendações por Favoritos do Usuário Similar Irrelevantes, apenas 2 responderam dizendo: (a) *“Não estão relacionadas as linhas que eu atuo. Apenas uma (ST11) que, apesar de não ser a linha que eu atuo, me gerou interesse e foi recomendada corretamente (dada minha perspectiva atual)”* e (b) *“Uma das palestras principais recomendadas não está diretamente relacionada a minha área de pesquisa; a trilha que tenho maior interesse, acessibilidade, não foi sugerida; apenas algumas sessões do meu interesse, ensino, foram sugeridas”*.

O participante (a) afirma ter se interessado por uma das sessões recomendadas, porém recebeu 15 recomendações diferentes, ou seja, 14 são irrelevantes para ele. O participante (b) diz não ter recebido recomendações de sessões relacionadas ao seu interesse, porém as de ensino são. Este participante recebeu 8 recomendações, das quais 2 são relacionadas à ensino, representando 25% das recomendações. Portanto, há uma pequena relevância.

Dentre os 10 participantes que consideraram as recomendações Indiferentes, 3 se posicionaram em relação a não relevância da recomendação: (d) *“Não tem nada a ver com os meus tópicos de interesse”*; (e) *“4 das 7 recomendações não tem relação com minha*

pesquisa” e (f) “*Uma das recomendações é relacionada aos meus tópicos de interesse, outra é geral (solenidade de abertura), e as outras duas não são diretamente relacionadas aos meus tópicos de interesse*”.

Para o participante (d) não foi possível verificar dados de uso, pois não favoritou sessões e, de acordo com a resposta, percebe-se que o participante esperava receber recomendações de acordo com seus tópicos de interesse. Já o participante (e) recebeu 7 recomendações das quais 4 não tem relação com a pesquisa dele. Da mesma forma o participante (f) afirma ter recebido 4 recomendações, das quais uma é relacionada ao seu interesse. Os participantes (e) e (f) indicaram ter recebido pelo menos uma recomendação relacionada à pesquisa ou interessante dentre as recomendações recebidas.

Destes 10 participantes que consideraram as recomendações Indiferentes, 4 também se posicionaram, porém, em relação a relevância da recomendação. Os motivos apontados por eles foram: “*As sessões recomendadas possuem trabalhos de autores do meu interesse*” e “*As sessões recomendadas possuem trabalhos relacionados aos meus tópicos de interesse*”. Analisando estas respostas e as respostas do parágrafo anterior, pode-se dizer que, parte dos participantes que se consideram indiferentes às recomendações por Favoritos do Usuário Similar recebeu pelo menos uma recomendação que eles consideram relevante ou que tenha alguma relação com os seus interesses de pesquisa.

O principal motivo apontado pelos participantes que receberam a recomendação por Favoritos do Usuário Similar é “*As sessões recomendadas possuem trabalhos relacionados aos meus tópicos de interesse*”. Acredita-se que pessoas com interesses ou gostos similares no passado, podem ter os mesmos interesses ou gostos no futuro, portanto, a recomendação por Favoritos do Usuário Similar com base na similaridade de tópicos de interesse pode gerar recomendações relevantes para o usuário alvo.

Foi solicitado aos participantes que respondessem se assistiram às sessões recomendadas, opções de uma escala em percentual foram apresentadas e poderiam adicionar outra resposta pela opção “Outros”. Conforme Tabela 12, dentre os 42 participantes que receberam recomendações por Favoritos do Usuário Similar, 8 participantes responderam que não assistiram *Nenhuma sessão recomendada*, 8 participantes afirmaram ter assistido *Menos de 30% das sessões recomendadas*, 15 participantes afirmaram ter assistido *Entre 30% até 50% das sessões recomendadas* e 11 participantes afirmaram ter assistido *Mais de 50% das sessões recomendadas*. Percebe-se que a maioria das respostas se concentram nas faixas consideradas positivas. Ainda, deve-se investigar mais profundamente os motivos de 16 participantes terem assistido menos de 30% das sessões recomendadas.



Tabela 12 – Favoritos do Usuário Similar - Respostas à “Você assistiu a alguma das sessões recomendadas?”

<b>Você assistiu a alguma das sessões recomendadas?</b>	<b>Nº Respostas</b>
Nenhuma sessão recomendada	8
Menos de 30% das sessões recomendadas	8
Entre 30% até 50% das sessões recomendadas	15
Mais de 50% das sessões recomendadas	11

Fonte: a Autora.

#### 6.2.5.4 Outras Análises


Esta seção apresentam outras análises em relação às recomendações e são apresentados gráficos que adicionam a compreensão visual os dados gerais apresentados.

Ao agrupar a questão “As recomendações são relevantes?” de cada tipo de recomendação, foi possível analisar as respostas dos participantes de um modo geral.

Dentre as 9 respostas para a recomendação por Força do Laço, 22 respostas para a recomendação por Autoridade Cognitiva e 42 respostas por Favoritos do Usuário Similar, totalizando 73 respostas, 1 participante considerou as recomendações Totalmente Irrelevante, 4 participantes consideram as recomendações Irrelevantes, 11 participantes consideram Indiferente, 34 participantes consideram as recomendações Relevantes e 23 participantes consideram as recomendações Totalmente Relevante.

No Gráfico 5 é possível observar que somando o número de respostas Relevantes ao de respostas Totalmente Relevantes, têm-se 57 respostas dentro do que se considera Relevante. Desse modo, pode-se dizer que dentre as 73 respostas válidas, 78% são respostas de participantes que consideram as recomendações de sessões relevantes.


Gráfico 5 – Relevância de Todas as Recomendações



Fonte: a Autora.


Neste Experimento não são realizadas comparações entre os métodos de recomendação social utilizados no MRSSEC. Porém, para visualizar a Relevância das recomendações por tipo de recomendação foi gerado o Gráfico 6. Neste gráfico, é possível observar visualmente que somente na recomendação por Favoritos do Usuário Similar há indicação de Totalmente Irrelevante e Irrelevante, para a recomendação por Força do Laço e por Autoridade Cognitiva não houve indicações de irrelevância.

Gráfico 6 – Relevância das Recomendações por Tipo de Recomendação



Fonte: a Autora

Gráfico 7 - Relevância de cada Tipo de Recomendação por Participante



Fonte: a Autora


No Gráfico 7 são apresentadas as respostas dos participantes em relação à relevância de cada Tipo de Recomendação. As respostas são em escala de *Likert*, sendo (1) Totalmente Irrelevante, (2) Irrelevante, (3) Indiferente, (4) Relevante e (5) Totalmente Relevante. É possível verificar que o número 4 se repete com maior frequência, seguido do número 5, em

uma análise geral, a maioria dos participantes consideram que as recomendações de sessões são relevantes. Dos 44 participantes, 39 receberam pelo menos uma recomendação considerada Relevante ou Totalmente Relevante.

No AppIHC2018 foram verificadas as quantidades de sessões favoritadas pelos participantes da pesquisa. Portanto, uma análise foi realizada para identificar as sessões recomendadas após o evento que foram favoritadas pelo participante durante o evento. Dentre os 46 participantes que receberam as recomendações após o evento, 24 participantes favoritaram pelo menos uma sessão durante o evento. Destes 24, 17 participantes receberam a recomendação de pelo menos uma sessão que havia sido favoritada.

O Gráfico 8 apresenta a relação dos 17 usuários que receberam recomendações de sessões favoritadas.

Gráfico 8 – Quantidade de Sessões Favoritadas x Favoritadas e Recomendadas



Fonte: a Autora.

No Gráfico 8, pode-se observar em azul, a quantidade de sessões favoritadas e em vermelho a quantidade de sessões favoritadas que foram recomendadas. Para o usuário número 17, por exemplo, após o evento foram recomendadas 15 sessões das 18 sessões que ele favoritou durante o evento. Representando um indício explícito de relevância, indicado

pelo participante durante o evento quando favoritou as sessões, pois os dados de uso não foram utilizados na implementação do MRSSEC.

### 6.3 SUGESTÕES

Foi solicitado ao participante que, ao final do questionário, respondesse a seguinte pergunta: “Que outros elementos poderiam ser levados em consideração para recomendar sessões em eventos científicos?”. Dentre os 44 participantes, 24 responderam a esta questão. O conteúdo das respostas foi analisado e são representados em 13 categorias, conforme Tabela 13.

Tabela 13 – Sugestões de Elementos para Recomendar Sessões em Eventos Científicos

Nº	Elementos
1	<b>Recomendar sessões de autores da mesma universidade.</b>
2	Sessões que o usuário alvo favoritou no evento passado.
3	<b>Autores mais Seguidos.</b>
4	<b>Sessões mais Favoritadas.</b>
5	<b>Tópicos mais Discutidos</b>
6	Trabalhos em Destaque.
7	Áreas relacionadas às publicações do usuário alvo (Lattes, ResearchGate).
8	Linhas de pesquisas correlatas às áreas relacionadas às publicações do usuário alvo.
9	Semelhança entre palavras chave: trabalho do usuário alvo x demais trabalhos no evento
10	Semelhança entre palavras chave: fornecidas pelo usuário alvo (biografia) x demais trabalhos no evento
11	<b>Sessões de autores referenciados no artigo do usuário alvo</b>
12	Trabalhos da trilha em que o usuário alvo possui trabalho
13	Tipo de atuação do usuário alvo (pesquisador acadêmico ou da indústria)

Fonte: a Autora.

Os elementos em destaque apresentados na Tabela 13 são considerados sociais, pois envolvem a ação de outras pessoas da comunidade, portanto tem relação com a proposta apresentada neste trabalho. As demais sugestões podem contribuir para alavancar as recomendações em eventos científicos, porém não envolvem elementos sociais. Tais sugestões podem ser utilizadas para aprimoramento do modelo em trabalhos futuros.

### 6.4 DISCUSSÃO

Neste capítulo foram apresentados os experimentos em que o MRSSEC foi aplicado, ambos no Simpósio Brasileiro sobre Fatores Humanos em Sistemas Computacionais, em 2017 na cidade de Joinville SC e em 2018 na cidade de Belém PA.

No primeiro experimento (IHC 2017), o MRSSEC foi parcialmente implementado e foram consideradas as relações de coautoria entre os participantes do evento para gerar

recomendações sociais. A recomendação foi exibida no aplicativo AppIHC por meio de ícone social nas sessões em que coautores estavam presentes. Um questionário foi aplicado após o evento, e dados de uso foram analisados, meios pelo qual foi possível obter a percepção dos usuários, que consideraram útil a indicação de coautoria para a recomendação de sessões em eventos científicos. O modelo foi aprimorado e um novo experimento foi realizado no IHC 2018.

No IHC 2018, os três tipos de recomendação foram implementadas, exceto a Localização. Foram geradas recomendações com base nos Relacionamentos Autoridade Cognitiva, Força do Laço e nos Favoritos do Usuário Similar. As recomendações foram exibidas explicitamente por meio do menu “Recomendados” no AppIHC2018. Por problemas técnicos de comunicação entre o aplicativo e o servidor em que o modelo estava sendo executado, não foi possível gerar as recomendações em tempo real durante o evento.

Após o evento, as recomendações foram geradas para os usuários que utilizaram o aplicativo e foram enviadas por e-mail em anexo com a programação. Um *link* para responderem ao questionário também foi enviado. As respostas e os dados de uso dos usuários foram analisados.

As análises mostram que a maioria dos participantes da pesquisa são estudantes, e que, de um modo geral, as recomendações foram consideradas relevantes mesmo por participantes que as consideraram indiferentes.

Ao analisar o conteúdo das respostas dos participantes que não consideraram as recomendações relevantes, foi possível perceber que esperavam que as recomendações geradas tivessem relação direta com seus tópicos de interesse. Porém, o objetivo do modelo é encontrar participantes com gostos semelhantes e recomendar sessões que o usuário alvo ainda não selecionou como favorita. Dessa forma, acredita-se que há necessidade de melhorar a explicação da recomendação, pois não deixa claro o motivo pelo qual foi apresentada ao usuário alvo.

Por meio das análises gerais e específicas de cada tipo de recomendação foi possível perceber que a maioria dos participantes considerou as Recomendações Relevantes.

Dos 44 participantes, 39 receberam pelo menos uma recomendação considerada Relevante ou Totalmente Relevante. Um indício explícito de relevância foi indicado pelos participantes que favoritaram sessões durante o evento, 17 participantes receberam a recomendação de pelo menos uma sessão que havia sido favoritada. Para cada tipo de recomendação gerada, a maioria dos participantes afirmou ter assistido entre 30% até 50% das sessões, sendo considerada uma faixa percentual positiva para a aplicação do experimento.

Os resultados do experimento demonstram a importância da priorização dos critérios sociais, apresentados na seção 5.6. Reforçando a crença de que as autoridades cognitivas tendem a oferecer itens de maior interesse para o usuário que concede a autoridade e que os laços sociais existentes contribuem para gerar recomendações relevantes.

## 6.5 LIMITAÇÕES E AMEAÇAS A VALIDADE DO EXPERIMENTO

Nesta seção são apresentadas as limitações do experimento realizado e as ameaças que podem ter influenciado o resultado do experimento.

Uma ameaça à validade do experimento é que o modelo foi implementado parcialmente no primeiro experimento, e no segundo experimento não foi implementada a Localização e os dois experimentos foram aplicados no mesmo evento, de pequeno porte. Portanto, é necessário realizar outros experimentos para verificar a aderência do modelo completo e em todos os cenários apresentados e com públicos diferentes.

Uma limitação do experimento é o tamanho da amostra, tanto no primeiro como no segundo experimento poucos participantes responderam à pesquisa, que poderia ter resultados mais conclusivos se mais participantes tivessem aderido, e análises estatísticas inferenciais poderiam ter sido aplicadas.

Outra limitação consiste em que as recomendações não terem sido geradas em tempo real, no segundo experimento, pois mais dados de uso poderiam ter sido coletados, além do *feedback* que poderia ter sido coletado durante o evento.

A utilização de apenas uma fonte de dados sociais também limitou a abrangência das recomendações em relação aos relacionamentos provenientes da rede social derivada da rede de coautoria.

O questionário sobre a percepção dos participantes em relação à relevância das recomendações recebidas foi aplicado apenas meses depois do experimento, sendo outra ameaça à validade do experimento, pois muitos participantes podem não se lembrar das apresentações das sessões recomendadas.

Sobre o participante considerar a recomendação da sessão relevante ao responder o questionário, também é uma ameaça a validade do experimento. Se o participante realmente assistiu à sessão recomendada e gostou ou não, pode influenciar na resposta, ele poderia ter considerado relevante durante o evento antes de assistir, e depois de assistir não considerar mais tão relevante assim.

Sobre o participante afirmar ter assistido a recomendação da sessão, também pode ser uma ameaça à validade do experimento, devido à intenção de assistir, porém o participante pode não ter assistido por existirem sessões em paralelo. Como o questionário foi aplicado meses depois, o participante pode não ter observado esse fato.



## 7 CONSIDERAÇÕES FINAIS

Eventos científicos têm por objetivo reunir pesquisadores, estudantes e outros interessados em conhecer as diferentes pesquisas apresentadas pela comunidade científica. Além de promover a reunião de pesquisadores de determinada área do conhecimento, um evento científico proporciona oportunidades de conhecer novos pesquisadores e aumentar a rede de colaborações. Em geral, eventos científicos são dinâmicos, diferentes tipos de sessões podem acontecer simultaneamente e ocorrem por um curto período de tempo. Por serem dinâmicos, as pessoas estão se movimentando entre uma sessão e outra e podem ter dificuldade de escolher a quais sessões assistir.

Sistemas de Recomendação podem auxiliar os participantes do evento fornecendo sugestões de apresentações que sejam relevantes para o participante. Porém, existem problemas inerentes a SRs, como por exemplo, escassez de avaliações e o *cold start*, que no âmbito de eventos científicos são agravados devido ao curto período de tempo em que um evento existe, além da falta de histórico de participações e avaliações. SRs podem utilizar dados sociais para melhorar as recomendações. Esses dados podem ser oriundos de relações sociais, de interações sociais, de participações em eventos, entre outros dados que contribuem na melhoria do processo de recomendação.

Um mapeamento sistemático foi conduzido para identificar o estado da arte em SRs que usam elementos sociais, para identificar trabalhos relacionados a esta pesquisa e entender o uso de elementos sociais no processo de recomendação. Dos 59 trabalhos selecionados, apenas um utilizava elementos sociais para recomendação de eventos, porém não científicos ou acadêmicos. Os demais trabalhos do mapeamento foram importantes para o embasamento e para o processo de construção do modelo. Outros trabalhos relacionados foram analisados e também contribuíram para o desenvolvimento do modelo.

O objetivo geral desta dissertação foi propor um Modelo de Recomendação Social de Sessões para Eventos Científicos (MRSSEC). O MRSSEC aplicado em duas edições do Simpósio Brasileiro sobre Fatores Humanos em Sistemas Computacionais (IHC), em outubro de 2017 e em outubro de 2018.

Com o objetivo de compreender a percepção dos usuários em relação à relevância das recomendações, dois experimentos foram realizados, ambos qualitativos, que ajudaram a identificar limitação do modelo, como por exemplo, não considerar sessões em paralelo, o usuário deve decidir qual julga mais relevante assistir. Em eventos pequenos isto pode não ser

um problema devido a pouca quantidade de sessões em paralelo, mas em grandes eventos pode gerar desconforto ao usuário alvo.

O MRSSEC também pode ser utilizado como um complemento às abordagens tradicionais, adicionando informações que podem fornecer recomendações diferentes e inesperadas.

Como resultado, e respondendo à pergunta norteadora para o problema de pesquisa, “O uso de elementos sociais no processo de recomendação de sessões pode gerar recomendações relevantes para os participantes de um evento científico?”, com base nos experimentos aplicados, constata-se que os elementos sociais utilizados no MRSSEC contribuem positivamente no processo de recomendação de sessões, fornecendo recomendações relevantes para os participantes de eventos científicos.

Com isso, as principais contribuições deste trabalho incluem a definição de um Modelo de Recomendação Social de Sessões para Eventos Científicos flexível, aplicável a qualquer evento científico com diferenciais tais como a Autoridade Cognitiva, que é a indicação explícita de uma relação de confiança, admiração, entre outros motivos do usuário em relação aos autores, o Favoritos do Usuário Similar, que amplia a diversidade da recomendação e aumentam-se as chances de se encontrar serendipidades relevantes aos interesses do usuário. A utilização de diferentes fontes de dados sociais, como redes sociais ou bases de dados em que possam ser extraídos relacionamentos, e a similaridade de tópicos de interesse entre os usuários conectados implicitamente em uma rede social local também são diferenciais em relação aos trabalhos existentes, buscando auxiliar os participantes destes eventos a encontrarem sessões relevantes com facilidade.

Como trabalhos futuros pretende-se aplicar as sugestões destacadas dos participantes apresentadas na seção 6.3, como recomendar sessões de autores da mesma universidade e sessões mais favoritas. Recomendar os tópicos mais discutidos, que pode ser verificado por meio da interação do usuário com o sistema, recomendar sessões de autores referenciados no artigo do usuário alvo. Outra sugestão de melhoria para o modelo é no caso de sessões em paralelo, apresentar ao usuário alvo uma opção em que ele possa indicar qual sessão é mais relevante, dessa forma o MRSSEC pode construir um perfil para o usuário alvo e conhecê-lo melhor.

Como continuidade deste trabalho, a autora pretende continuar pesquisando sobre elementos sociais e aspectos cognitivos que influenciam a comunidade acadêmica na tomada de decisão de participar ou não de um evento e de assistir as sessões.

O desenvolvimento deste trabalho resultou em algumas publicações:

- TRAMONTIN, A. P. A.; GASPARINI, I.; PEREIRA, R.. Uso de Elementos Sociais para a Recomendação de Sessões em Eventos Acadêmicos. Anais do VIII Workshop sobre Aspectos da Interação Humano-Computador na Web Social (WAIHCWS'17) co-located with XVI Simpósio Brasileiro sobre Fatores Humanos em Sistemas Computacionais (IHC 2017), 2017. v. 2039. p. 48-57.
- TRAMONTIN, A.; GASPARINI, I.; PEREIRA, R. Sistemas de Recomendação com Elementos Sociais: Um Mapeamento Sistemático. In: XIV Simpósio Brasileiro de Sistemas de Informação (SBSI), 2018, Caxias do Sul.
- TRAMONTIN, A.; GASPARINI, I.; PEREIRA, R.. Using Social Elements to Recommend Sessions in Academic Events. International Conference on Human-Computer Interaction (HCI), Las Vegas, 2018.
- TRAMONTIN, A.; SOHN, R.; OLIVEIRA, B.; GASPARINI, I.; PEREIRA, R.. Emotion and Movement with AppIHC: Promoting Interaction and Socialization among Participants of Scientific Events via Mobile Application. International Conference on Human-Computer Interaction (HCI), Orlando, 2019.

Além disso, este trabalho faz parte do projeto AppIHC, que, em parceria com outros pesquisadores, teve como resultado:

- OLIVEIRA, B.; TRAMONTIN, A. P. A. ; NEVES, E. S.; SOHN, R.; ARDJOMAND, L.; GASPARINI, I. . AppIHC: Uma proposta de Aplicativo Móvel para Eventos Científicos. In: Simpósio Brasileiro sobre Fatores Humanos em Sistemas Computacionais (IHC) (pôsteres e demonstrações), 2017, Joinville. Extended Proceedings of the 16th Brazilian Symposium on Human Factors in Computing Systems. (IHC2017), 2017. p. 78-79.

## REFERÊNCIAS

- ADOMAVICIUS, G.; TUZHILIN, A. Toward The Next Generation Of Recommender Systems: A Survey Of The State-Of-The-Art And Possible Extensions. *IEEE Transactions On Knowledge And Data Engineering*, v. 17, n. 6, p. 734–749, 2005.
- AGGARWAL, CC. *Data mining: The Textbook*. Springer, 2015.
- AGGARWAL, CC. *Recommender Systems*. Springer International Publishing, 2016.
- ALAHMADI, Dimah H.; ZENG, Xiao-Jun. ISTS: Implicit social trust and sentiment based approach to recommender systems. *Expert Systems with Applications*, v. 42, n. 22, p. 8840–8849, 2015.
- ASABERE, N. Y., XIA, F., WANG, W., RODRIGUES, J. J., BASSO, F., & Ma, J. (2014). Improving smart conference participation through socially aware recommendation. *IEEE Transactions on Human-Machine Systems*, 44(5), 689-700.
- BAHAREHSHAMSZAMENJANI, Engineer. Marketing based on user behavior in Facebook social network through recommender system design. 2nd International Congress on Technology, Communication and Knowledge, ICTCK 2015, n. Ictck, p. 181–185, 2016.
- BERNARDES, D.; DIABY, M.; FOURNIER, R.; FOGELMANSOULIÉ, F.; VIENNET, E.. A Social Formalism and Survey for Recommender Systems. *ACM SIGKDD Explorations Newsletter*, v. 16, n. 2, p. 20–37, 2015.
- BIANCALANA, C.; GASPARETTI, F.; MICARELLI, A.; SANSONETTI, G. An approach to social recommendation for context-aware mobile services. *ACM Transactions on Intelligent Systems and Technology*, v. 4, n. 1, p. 1–31, 2013.
- BRIDGE, D.; GÖKER, M.H.; MCGINTY, L.; SMYTH, B. Case-Based Recommender Systems. *The Knowledge Engineering Review*, v. 20, n. 3, 315–320, 2005.
- BURKE, R. Hybrid Web Recommender Systems. In: *The adaptive web*. Springer, Berlin, Heidelberg, 2007. p. 377-408.
- BURT, R. S. Structural Holes versus Network Closure as Social Capital. In *Social capital Theory and Research*. Routledge, 2001. p. 31–56.
- CHIU, Y.-S.; LIN, K.-H.; CHEN, J.-S. A Social Network-based serendipity recommender system. 2011, Information and Communications Research Laboratories, Industrial Technology Research Institute of Taiwan, Hsinchu, Taiwan, 2011.
- CIRIBELI, J.; PAIVA, V. Redes e mídias sociais na internet: realidades e perspectivas de um mundo conectado. *Revista Mediação*, v. 13, n. 12, p. 57–74, 2011.
- CRANDALL, D.; COSLEY, D.; HUTTENLOCHER, D.; KLEINBERG, J.; SURI, S. Feedback Effects between Similarity and Social Influence in Online Communities. 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '08), p. 160–168, 2008.
- CREMONESI, P.; GARZOTTO, F.; NEGRO, S.; PAPADOPOULOS, A. V.; TURRIN, R.

Looking for “ Good ” Recommendations : A Comparative Evaluation of Recommender Systems. 2011, Berlin, Heidelberg: Springer, 2011. p. 152–168.

CREMONESI, Paolo; GARZOTTO, Franca; TURRIN, Roberto. User-Centric vs. System-Centric Evaluation of Recommender Systems, 2013, p. 334–351.

DE SOUZA SACERDOTE, H. C.; SAMPAIO, R. B.; GONÇALVES, M. D. P.; HENRIQUE, J.; FERNANDES, C. Utilização Dos Métodos De Análise De Redes Sociais Na Avaliação Das Interações Sociais Em Um Ambiente Virtual De Aprendizagem. *Int. J. Knowl. Eng. Manage*, v. 4, n. 9, p. 2316–6517, 2015.

DIABY, M.; VIENNET, E.; LAUNAY, T. Exploration of methodologies to improve job recommender systems on social networks. *Social Network Analysis and Mining*, v. 4, n. 1, 2014.

DIABY, M; VIENNET, E; LAUNAY, T. Toward the next generation of recruitment tools: An online social network-based job recommender system. 2013, Université Paris 13, Sorbonne Paris Cité, L2TI, F-93430, Villetaneuse, France, 2013. p. 821–828.

DEY, A. K. Understanding And Using Context. *Personal And Ubiquitous Computing*, 2001, 5(1), 4-7.

DICE, L.R. Measures of the amount of ecologic association species. *Ecology*, n. 26, p. 297–302, 1945.

DRON, Jon. Designing the Undesignable: Social Software and Control. *Educational Technology & Society*, v. 10, n. 3, p. 60–71, 2007.

DWIVEDI, P.; BHARADWAJ, K.K. E-learning recommender system for learners in online social networks through association retrieval, 2012.

FATEMI, M; TOKARCHUK, L. A Community Based Social Recommender System for individuals & groups. 2013, School of Electronic Engineering and Computer Science, Queen Mary University of London, London, United Kingdom, 2013. p. 351–356.

FARZAN, R; BRUSILOVSKY, P. Where did the researchers go?: supporting social navigation at a large academic conference. In *Proceedings of the nineteenth ACM conference on Hypertext and hypermedia (HT '08)*. ACM, 2008. New York, NY, USA, 203-212.

FELFERNIG, A.; FRIEDRICH, G.; JANNACH, D.; ZANKER, M. Developing Constraint-Based Recommenders. In: *Recommender Systems Handbook*. Springer US, 2011. p. 187-215.

FELFERNIG, A; BURKE, R. Constraint-based Recommender Systems: Technologies and Research Issues. In: *Proceedings of the 10th International Conference On Electronic Commerce*. ACM, 2008. p. 3.

GABARDO, AC. Análise De Redes Sociais: Uma Visão Computacional. 2015.

GOLDBERG, D.; NICHOLS, D.; OKI, B.; TERRY, D. Using Collaborative Filtering To Weave An Information Tapestry. *Communications of the ACM*, v. 35, n. 12, p. 61-70, 1992.

GROH, G.; BIRNKAMMERER, S.; KÖLLHOFER, V. Social Recommender systems. In: Recommender Systems For The Social Web. Springer Berlin Heidelberg, 2012. p. 3-42.

GRANOVETTER, Mark S. The Strength of Weak Ties Author ( s ): Mark S . Granovetter Source : The American Journal of Sociology , Vol . 78 , No . 6 ( May , 1973 ), pp . 1360-1380.

GUNAWARDANA, A.; SHANI, G. Evaluating Recommender Systems. Recommender Systems Handbook. Boston, MA: Springer US, 2015. p. 265–308.

GUY, I. Social recommender systems. In: Recommender Systems Handbook. Springer, Boston, MA, 2015. p. 511-543.

GUY, I.; ZWERDLING, N.; CARMEL, D.; RONEN, I.; UZIEL, E.; YOGEV, S.; OFEKKOIFMAN, S. Personalized Recommendation of Social Software Items Based on Social Relations. In Proceedings of the third ACM conference on Recommender systems (pp. 53-60), 2009. p. 53–60.

HAO, M.; ZHOU D.; LIU C.; LYU M.; KING I. Recommender systems with social regularization, 2011.

HE, R.; FANG C.; WANG Z.; MCAULEY J. Vista: A Visually, Socially, and Temporally-aware Model for Artistic Recommendation. p. 309–316, 2016.

HUANG, Z A N; CHEN, Hsinchun; ZENG, Daniel. Applying Associative Retrieval Techniques to Alleviate the Sparsity Problem in Collaborative Filtering. ACM Transactions on Information Systems, v. 22, n. 1, p. 116–142, 2004.

JANNACH, D.; ZANKER, M.; FELFERNIG, A.; FRIEDRICH, G. Recommender Systems: An Introduction. Cambridge University Press, 2010.

JIANG, M., CUI, P., LIU, R., YANG, Q., WANG, F., & ZHU, W. (2012). Social contextual recommendation. In Proceedings of the 21st ACM international conference on Information and knowledge management. ACM, 2012, p. 45–54.

KAPLAN, A.M.; HAENLEIN, M. Users of the world, unite! The challenges and opportunities of Social Media. Business Horizons, 2010, v.53, n.1, p. 59–68.

KONSTAN, Joseph A; RIEDL, John. Recommender systems: from algorithms to user experience. User modeling and user-adapted interaction, 2012. p. 101–123.

KOREN, Y.; BELL, R. Advances in Collaborative Filtering. Recommender Systems Handbook. Boston, MA: Springer US, 2015. p. 77–118.

LICAMELE, L.; GETOOR, L. Social capital in friendship-event networks. Proceedings - IEEE International Conference on Data Mining, ICDM, p. 959–964, 2006.

LIMA, DPR; NETTO, JFM; GASPAR, W. Um Sistema Multiagente que Caracteriza as Relações Sociais entre Alunos de um Ambiente Virtual de Aprendizagem. In: Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE). 2014. p. 1163.

LIN, N; COOK, KS; BURT, RS. Social Capital: Theory and research. 2001.

MA, H.; ZHOU, D.; LIU, C.; LYU, M.R.; KING, I. Recommender Systems With Social Regularization. In: Proceedings Of The Fourth ACM International Conference On Web Search And Data Mining. ACM, 2011. p. 287-296.

MACEDO, A.Q.; MARINHO, L.B.; SANTOS, R.L.T. Context-Aware Event Recommendation in Event-based Social Networks Categories and Subject Descriptors. In: Proceedings of the 9th ACM Conference on Recommender Systems. ACM, 2015. p. 123-130.

MANNING, C.D.; RAGHAVAN, P. Introduction to Information Retrieval. Americas, v. 32, p. 10013–2473, 2008.

MARCHIORI, P.; ADAMI A.; FERREIRA S.; CRISTOFOLI F. FATORES MOTIVACIONAIS DA COMUNIDADE CIENTÍFICA PARA PUBLICAÇÃO E DIVULGAÇÃO DE SUA PRODUÇÃO EM REVISTAS CIENTÍFICAS, 2006.

MARTELETO, R.M. Análise De Redes Sociais: Aplicação Nos Estudos De Transferência Da Informação. Ciência Da Informação, SciELO Brasil, v. 30, n. 1, p. 71–81, 2001.

MCNEE, Sean M; RIEDL, John; KONSTAN, Joseph A. Being Accurate is Not Enough : How Accuracy Metrics have hurt Recommender Systems, 2006. p. 1097–1101.

MCLOUGHLIN, C.; LEE, M.J.W. Social Software And Participatory Learning: Pedagogical Choices With Technology Affordances. In: The Web 2.0 Era Introduction: Social Trends And Challenges, 2007.

MIKA, P. Social networks and the semantic web. In: Proceedings of the 2004 IEEE/WIC/ACM International Conference on Web Intelligence. IEEE Computer Society, 2004. p. 285-291.

NING, X.; DESROSIERS, C.; KARYPIS, G. A comprehensive survey of neighborhood-based recommendation methods. In: Recommender systems handbook. Springer, Boston, MA, 2015. p. 37-76.

OECHSLEIN, O.; HESS, T. The Value Of A Recommendation: The Role Of Social Ties In Social Recommender Systems. In: System Sciences (HICSS), 2014 47th Hawaii International Conference on. IEEE, 2014. p. 1864-1873.

OLIVEIRA, B.; GASPARINI, I. Sistema de Recomendação Baseado em Conteúdo: Recomendando Sessões em Eventos Científicos. 2017.

OLIVEIRA, B.; TRAMONTIN, A. P. A. ; NEVES, E. S.; SOHN, R.; ARDJOMAND, L.; GASPARINI, I. . AppIHC: Uma proposta de Aplicativo Móvel para Eventos Científicos. In: Simpósio Brasileiro sobre Fatores Humanos em Sistemas Computacionais (IHC) (pôsteres e demonstrações), 2017, Joinville. Extended Proceedings of the 16th Brazilian Symposium on Human Factors in Computing Systems. (IHC2017), 2017. p. 78-79.

PASCOAL, LML. Um método social-evolucionário para geração de rankings que apoiem a recomendação de eventos. 2014.

PEREIRA, Roberto. Folkauthority : A Aplicação do Conceito de Autoridade Cognitiva por meio de FOLKAUTHORITY : A APLICAÇÃO DO CONCEITO DE. 2008. 2008.

PAZZANI, M.J.; BILLSUS, D. Content-Based Recommendation Systems. The Adaptive Web. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. p. 325–341.

PEREIRA, R.; BARANAUSKAS, M.C.; DA SILVA, S.R.P. A Discussion on Social Software: Concept, Building Blocks and Challenges. International Journal for Infonomics, v. 3, n. 4, p. 533–542, 2010.

PEREIRA, Roberto; BARANAUSKAS, Maria Cecilia; DA SILVA, Sergio R P. A Discussion on Social Software: Concept, Building Blocks and Challenges. International Journal for Infonomics, v. 3, n. 4, p. 533–542, 2010.

PÉREZ, Luis G.; MONTES-BERGES, Beatriz; DEL ROSARIO CASTILLO-MAYEN, Maria. Boosting social networks in social network-based recommender system. International Conference on Intelligent Systems Design and Applications, ISDA, p. 426–431, 2011.

PETERSEN, K.; FELDT, R.; MUJTABA, S.; MATTSSON, M. Systematic Mapping Studies in Software Engineering. In: EASE, 2008, v. 8, p. 68-77.

PHAM, M. C.; KOVACHEV, D.; CAO, Y.; MBOGOS, G. M.; KLAMMA, R. Enhancing Academic Event Participation With Context-Aware And Social Recommendations. In: Advances In Social Networks Analysis And Mining (Asonam), 2012 Ieee/Acm International Conference On. Ieee, 2012. P. 464-471.

RANGANATHAN, Anand; CAMPBELL, Roy H. An Infrastructure For Context-Awareness Based On First Order Logic. Personal and Ubiquitous Computing, 2003, v. 7, n. 6, p. 353–364.

RICCI, F; ROKACH, L; SHAPIRA, B. Recommender Systems: Introduction And Challenges. 2. ed. Boston, MA: Springer, 2015.

RICCI, Francesco; ROKACH, Lior; SHAPIRA, Bracha. Introduction to Recommender Systems Handbook. Recommender Systems Handbook. Boston, MA: Springer US, 2011. p. 1–35.

RIEH, Soo Young. Credibility and Cognitive Authority of Information. Encyclopedia of Library and Information Sciences, v. Third Edit, n. 919687867, p. 1337 — 1344, 2010.

ROHANI, Vala Ali; KASIRUN, Zarinah Mohd; RATNAVELU, Kuru. An enhanced content-based recommender system for academic social networks. Proceedings - 4th IEEE International Conference on Big Data and Cloud Computing, BDCloud 2014 with the 7th IEEE International Conference on Social Computing and Networking, SocialCom 2014 and the 4th International Conference on Sustainable Computing and C, p. 424–431, 2015.

RONALDO GOLDSCHMIDT EMMANUEL PASSOS. Data mining: um guia prático. Gulf Professional Publishing, 2005.

ROSA, R.; RODRÍGUEZ D.; DE SOUSA JUNIOR V.; BRESSAN G. Recommendation system based on user profile extracted from an IMS network with emphasis on social network and digital TV. Proceedings of the 6th Latin America Networking Conference, p. 40–47,



2011.

SALTON, Gerard; A. Wong; C. S. Yang. A vector space model for information retrieval. *Journal of the American Society for Information Science*, 1975, v. 18, n. 11, p. 613–620.

SALTON, G. A Document Retrieval System For Man-Machine Interaction. In: *ACM. Proceedings of the 1964 19th ACM national conference*, 1964. p. 122–301.

SARWAR, B., KARYPIS, G., KONSTAN, J., & RIEDL, J. (2001, April). Item-based collaborative filtering recommendation algorithms. In *Proceedings of the 10th international conference on World Wide Web*. Hong Kong: ACM, 2001, p. 285-295.

SCHALL, D. Overview Social Recommender Systems. *Social Network-Based Recommender Systems*. Cham: Springer International Publishing, 2015. p. 1–6.

SCHMIDT, L.; OHIRA, M.L.B. *Revista ACB*. *Revista ACB*, 2002, v. 7, n. 1, p. 73–97, 25.

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

SCOTT, J. Social Network Analysis: Developments, Advances, And Prospects. *Social Network Analysis and Mining*, 2011 v. 1, n. 1, p. 21–26.

SCOTT, J. *Social network analysis*. Sage, 2017.

SETH, A.; ZHANG, J. A Social Network Based Approach to Personalized Recommendation of Participatory Media Content. In: *ICWSM*. 2008.

SEVERINO, A.J. *Metodologia Do Trabalho Científico*. Cortez editora, 2017.

SHIRKY, C. A group is its own worst enemy: Social structure in social software. In *O'Reilly Emerging Technology conference*. Santa Clara CA, 2003.

SMITH, G. Social Software Building Blocks. 2007. Disponível em: <<http://nform.com/ideas/social-software-building-blocks/>> Acessado em: 8 maio. 2018, 15:30:30.

SUN, Jimeng; TANG, Jie. A survey of models and algorithms for social influence analysis. *Social Network Data Analytics*. Springer, 2011. p. 177–214.

SUN, Z.; HAN L.; HUANG W.; WANG X.; ZENG X.; WANG M.; YAN H. Recommender systems based on social networks. *Journal of Systems and Software*, v. 99, p. 109–119, 2015.

TANG, Jiliang; HU, Xia; LIU, Huan. Social recommendation: a review. *Social Network Analysis and Mining*, v. 3, n. 4, p. 1113–1133, 2013.

TOLEDO, Douglas F.; PEREIRA, Roberto; OLIVEIRAJR, Edson. Identifying cognitive authority in social networks: a conceptual framework. 2015, 2015. p. 409–418.

TORRES, R. *Personalização Na Internet: Como Descobrir Os Hábitos De Consumo De Seus Clientes, Fidelizá-los E Aumentar O Lucro De Seu Negócio*. São Paulo: Novatec, 2004.

WILSON, Patrick. *Second-Hand Knowledge: An Inquiry into Cognitive Authority*. Westport:

Greenwood Press, 1983.

TRAMONTIN, A. P. A.; GASPARINI, I. ; PEREIRA, R. Sistemas de Recomendação com Elementos Sociais: Um Mapeamento Sistemático. In: XIV Simpósio Brasileiro de Sistemas de Informação (SBSI), 2018, Caxias do Sul.

WASSERMAN, Stanley; FAUST, Katherine. Social Network Analysis: Methods And Applications. Cambridge University Press, 1994.

XIA, F.; ASABERE, N.Y.; RODRIGUES, J.J.; BASSO, F.; DEONAUTH, N.; WANG, W. Socially-Aware Venue Recommendation For Conference Participants. In: Ubiquitous Intelligence And Computing, 2013 IEEE 10th International Conference on and 10th International Conference on Autonomic and Trusted Computing (UIC/ATC). IEEE, 2013. p. 134-141.

YIN, Bin; YANG, Yujiu; LIU, Wenhua. Exploring social activeness and dynamic interest in community-based recommender system. Proceedings of the 23rd International Conference on World Wide Web - WWW '14 Companion, n. 1, p. 771–776, 2014.

ZHANG, R.; SUN B.; KANG W.; ZHU T. GLOSS: A social networks-based recommender system. 2010, 2010.

ZHANG, Y.; WU, H.; SORATHIA, V. S.; PRASANNA, V. K. Event Recommendation In Social Networks With Linked Data Enablement. Proceedings of the 15th International Conference on, Enterprise Information Systems, p. 371–379, 2013.

ZHAO, S; ZHOU M.; YUAN Q.; ZHANG X.; ZHENG W.; FU R.. Who is Talking about What : Social Map-based Recommendation for Content-Centric Social Websites. 4th ACM Conference on Recommender Systems, p. 143–150, 2010.

## APÊNDICE – QUESTIONÁRIO DE AVALIAÇÃO DA RECOMENDAÇÃO

Sobre a Pesquisa e o Termo de Consentimento

### Avaliação da Recomendação Social de Sessões do IHC 2018

Prezado(a) participante,

Este questionário faz parte de uma dissertação de mestrado que criou um Modelo para Recomendação de Sessões Técnicas de Eventos Científicos com base em Elementos Sociais. Como uma experimentação do modelo, capturamos os dados do aplicativo do evento, ApplHC2018. Como você participou do IHC e usou o ApplHC, verificamos que o sistema de recomendação poderia sugerir sessões à você. Deste modo, encaminhamos a você um email com um arquivo .pdf contendo as recomendações geradas.

Este questionário tem como objetivo avaliar a recomendação social que lhe foi enviada por e-mail, e não o uso do aplicativo durante o IHC 2018 (Belém, Pará).

O formulário é composto por 3 seções relacionadas as recomendações. Por gentileza, responda a seção de questões de acordo com as recomendações que você recebeu.

- 1 - Sessões em que há coautores seus;
- 2 - Sessões em que há trabalhos de autores que você segue;
- 3 - Sessões que outros pesquisadores favoritaram (baseado em seus tópicos de interesse).

Muito obrigado por sua participação!

Aline de Paula Araújo Tramontin (mestranda, PPGCA - UDESC)

Isabela Gasparini (orientadora, PPGCA - UDESC)

Roberto Pereira (coorientador, Depto. Informática - UFPR)

Contato: [aline.tramontin@gmail.com](mailto:aline.tramontin@gmail.com)

**\*Obrigatório**

#### Termo de Consentimento \*

Aceito participar da pesquisa e entendo que todos meus dados individuais serão sigilosos. Apenas os pesquisadores deste projeto terão acesso aos dados brutos. Solicitamos a sua autorização para o uso de seus dados para a produção de textos técnicos e científicos. A sua privacidade será mantida.

☐ Aceito participar desta pesquisa

## Sobre a Recomendação por Foça do Laço

### 1 - Sessões em que há coautores seus:

Se você não recebeu recomendações baseadas em 'Coautores', siga para as próximas seções do formulário!

#### 1.1 - As recomendações são relevantes:

(1) Totalmente irrelevante (2) Irrelevante (3) Indiferente (4) Relevante (5) Totalmente relevante

1      2      3      4      5

Totalmente Irrelevante   ☐   ☐   ☐   ☐   ☐   Totalmente Relevante

#### 1.2 - Se você achou as recomendações relevantes, mesmo que parcialmente, aponte-nos o(s) motivo(s):

- ☐ Tenho interesse na linha de pesquisa em que meus coautores trabalham atualmente
- ☐ Gosto de prestigiar as apresentações de meus coautores
- ☐ Acho interessante saber que meus coautores estão presentes no evento
- ☐ Outro: \_\_\_\_\_

#### 1.3 - Se você não achou as recomendações relevantes, diga-nos o(s) motivo(s):

Sua resposta \_\_\_\_\_

#### 1.4 Você assistiu a alguma das sessões recomendadas?

- ☐ Nenhuma sessão recomendada
- ☐ Menos de 30% das sessões recomendadas
- ☐ Entre 30% até 50% das sessões recomendadas
- ☐ Mais de 50% das sessões recomendadas
- ☐ Outro: \_\_\_\_\_

## Sobre a Recomendação por Autoridade Cognitiva

### 2 - Sessões em que há trabalhos de 'autores que você segue':

Se você não recebeu recomendações por 'Autores que você segue', siga para a próxima seção do formulário!

#### 2.1 - As recomendações são relevantes:

(1) Totalmente irrelevante (2) Irrelevante (3) Indiferente (4) Relevante (5) Totalmente relevante

	1	2	3	4	5	
Totalmente Irrelevante	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Totalmente Relevante

#### 2.2 - Se você achou as recomendações relevantes, mesmo que parcialmente, aponte-nos o(s) motivo(s):

- ☐ Atuo ou tenho interesse em atuar na mesma linha de pesquisa em que os autores que sigo
- ☐ Tenho interesse na mesma linha de pesquisa em os autores que sigo
- ☐ São autores renomados e/ou prestigiados pela comunidade do IHC no Brasil
- ☐ São meus coautores e gostaria de encontrá-los no evento
- ☐ Outro:

#### 2.3 - Se você não achou as recomendações relevantes, diga-nos o(s) motivo(s):

Sua resposta

---

#### 2.4 - Você assistiu a alguma das sessões recomendadas?

- ☐ Nenhuma sessão recomendada
- ☐ Menos de 30% das sessões recomendadas
- ☐ Entre 30% até 50% das sessões recomendadas
- ☐ Mais de 50% das sessões recomendadas
- ☐ Outro:

## Sobre a Recomendação por Favoritos do Usuário Similar

**3 - Sessões que outros pesquisadores 'favoritaram':**

Baseado em seus tópicos de interesse

**3.1 - As recomendações são relevantes:**

(1) Totalmente irrelevante (2) Irrelevante (3) Indiferente (4) Relevante (5) Totalmente relevante

1 2 3 4 5

Totalmente Irrelevante

☐ ☐ ☐ ☐ ☐

Totalmente Relevante

**3.2 - Se você achou as recomendações relevantes, mesmo que parcialmente, aponte-nos o(s) motivo(s):**☐ As sessões recomendadas possuem trabalhos relacionados aos meus tópicos de interesse☐ As sessões recomendadas possuem trabalhos de autores do meu interesse☐ Outro: \_\_\_\_\_**3.3 - Se você não achou as recomendações relevantes, diga-nos o(s) motivo(s):**

Sua resposta \_\_\_\_\_

**3.4 - Você assistiu a alguma das sessões recomendadas?**

- ☐ Nenhuma sessão recomendada
- ☐ Menos de 30% das sessões recomendadas
- ☐ Entre 30% até 50% das sessões recomendadas
- ☐ Mais de 50% das sessões recomendadas