UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

Extração de contexto de reviews para sistemas de recomendação utilizando mineração de textos e opiniões

Camila Vaccari Sundermann

Tese de Doutorado do Programa de Pós-Graduação em Ciências de Computação e Matemática Computacional (PPG-CCMC)

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Camila Vaccari Sundermann

Extração de contexto de reviews para sistemas de recomendação utilizando mineração de textos e opiniões

Tese apresentada ao Instituto de Ciências Matemáticas e de Computação – ICMC-USP, como parte dos requisitos para obtenção do título de Doutor em Ciências – Ciências de Computação e Matemática Computacional. *VERSÃO REVISADA*

Área de Concentração: Ciências de Computação e Matemática Computacional

Orientadora: Profa. Dra. Solange Oliveira Rezende

USP – São Carlos
Fevereiro de 2020

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. As opiniões, hipóteses e conclusões ou recomendações expressas neste material são de responsabilidade dos autores e não necessariamente refletem a visão da CAPES.

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

S958e Sundermann, Camila Vaccari
Extração de contexto de reviews para sistemas de
recomendação utilizando mineração de textos e
opiniões / Camila Vaccari Sundermann; orientadora
Solange Oliveira Rezende. -- São Carlos, 2020.
157 p.

Tese (Doutorado - Programa de Pós-Graduação em
Ciências de Computação e Matemática Computacional) --
Instituto de Ciências Matemáticas e de Computação,
Universidade de São Paulo, 2020.

1. Contexto. 2. Sistemas de Recomendação. 3.
Mineração de Textos. 4. Mineração de Opiniões. I.
Rezende, Solange Oliveira, orient. II. Título.

Camila Vaccari Sundermann

Extraction of context from reviews for recommender systems using text and opinion mining

Doctoral dissertation submitted to the Institute of Mathematics and Computer Sciences – ICMC-USP, in partial fulfillment of the requirements for the degree of the Doctorate Program in Computer Science and Computational Mathematics. *FINAL VERSION*

Concentration Area: Computer Science and Computational Mathematics

Advisor: Profa. Dra. Solange Oliveira Rezende

USP – São Carlos
February 2020

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Finance Code 001. The opinions, hypotheses and conclusions or recommendations expressed in this material are the authors' own and do not necessarily reflect the views of CAPES.

Pelo carinho, afeto, dedicação e cuidado que meus pais me deram durante toda a minha existência, dedico esta tese a eles. Com muita gratidão.

AGRADECIMENTOS

Agradeço a Deus por tantas oportunidades e pessoas maravilhosas colocadas em minha vida.

Agradeço a minha família: meus pais Arnaldo e Cidinha, meu filho Kauê e meu noivo Ferison, pela força e motivação para nunca desistir, mesmo com todas as adversidades enfrentadas nesse período. E com tudo, agradeço pela paciência infinita.

Agradeço as minhas amigas, quase irmãs, que só pela presença me confortam e me incentivam a não desanimar. Ivone, Roberta e Jéssica, foram muitos risos, choros, cafés e jogos para distrair. Além do inesquecível show do *Coldplay*.

Agradeço imensamente minha orientadora. Sempre muito amiga e compreensível. Orientando além da vida acadêmica, também a vida pessoal. Dando conselhos e me motivando nas horas mais difíceis. Agradeço pela primeira aula na disciplina de Tópicos Avançados em IA. Foi nesse momento que descobri minha paixão por IA e ganhei uma orientadora de TCC, mestrado e doutorado.

Agradeço ao Anand pelas orientações e ensinamentos profissionais e pessoais, além das revisões de artigos em inglês.

Não poderia deixar de agradecer ao meu co-orientador Marcos Domingues. Devo muitos agradecimentos pela orientação, pelos ensinamentos e pelas parcerias.

Agradeço aos parceiros e colaboradores: Roberta Sinoara, Ivone Matsuno, João Antunes, Ricardo Marcacini, Renan de Pádua, Vítor Tonon, entre outros que foram pessoas relevantes para a realização deste trabalho.

Agradeço a todos os amigos do Labic pelos vários anos dividindo tantos momentos. Pelas parcerias, ajudas e risadas compartilhadas.

Agradeço à Itera (Val e Marco) pela oportunidade e confiança e a todos meus amigos de trabalho que deixam meus dias mais leves.

Agradeço ao ICMC - USP, funcionários e professores pelos quase 13 anos de estudos, aprendizados e crescimento pessoal e profissional.

Por fim, mas não menos importante, agradeço à CAPES pelo auxílio financeiro que possibilitou o desenvolvimento deste doutorado e os resultados obtidos.

*“Não conheço nenhuma fórmula infalível para obter o sucesso,
mas conheço uma forma infalível de fracassar: tentar agradar a todos.”*
(John F. Kennedy)

RESUMO

SUNDERMANN, C. V. **Extração de contexto de reviews para sistemas de recomendação utilizando mineração de textos e opiniões**. 2020. 153 p. Tese (Doutorado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2020.

Atualmente, com a grande sobrecarga de informações, serviços e produtos disponíveis na *Web*, os usuários tem encontrado dificuldades em identificar o que de fato é relevante para seus interesses e preferências. Sendo assim, sistemas de recomendação estão sendo desenvolvidos e implantados em um número cada vez maior de sites e aplicações com o objetivo de auxiliar os usuários sugerindo itens que atendam às suas preferências e necessidades. A tendência nessa área é a utilização de informações relevantes com o objetivo de gerar recomendações mais personalizadas e precisas aos usuários. Estudos comprovam que o uso de informação contextual tem viabilizado a obtenção de bons resultados na recomendação. Um dos grandes desafios encontrados na área de sistemas de recomendação sensíveis ao contexto refere-se à carência de métodos automáticos para a extração desse tipo de informação. Por outro lado, com o avanço da Web 2.0 e a crescente popularidade de redes sociais e comércio eletrônico, usuários têm sido cada vez mais encorajados a escrever *reviews* descrevendo suas opiniões sobre os itens. Dessas *reviews* podem ser extraídas informações importantes a serem utilizadas em sistemas de recomendação como contexto e opiniões. Com isso, o propósito geral deste trabalho de doutorado é avançar as pesquisas da área de sistemas de recomendação sensíveis ao contexto, em especial na extração automática de informações contextuais. Para atender aos objetivos do trabalho, foi realizada uma revisão sistemática da literatura de sistemas de recomendação sensíveis ao contexto que utilizam mineração de opiniões. Levando em consideração a carência de métodos automáticos de extração de contexto assim como a relevância das informações extraídas de *reviews* de usuários para os sistemas de recomendação, neste trabalho de doutorado foram propostos: (i) um método de recomendação sensível ao contexto, *CARM-TOM*, que executa desde o pré-processamento das *reviews* até a geração das recomendações utilizando informações contextuais; (ii) *CIET.5_{embed}*, uma técnica de extração de contexto baseada em *word embeddings*; (iii) uma técnica de extração de contexto baseada em regras de associação, a *RulesContext*; e (iv) uma técnica de extração de contexto baseada em mineração de opiniões no nível dos aspectos, a *CEOM*. Essas propostas foram avaliadas considerando a base de *reviews* *Yelp*, sistemas de recomendação baseados nos vizinhos mais próximos, sistemas de recomendação baseados em fatoração de matrizes e diferentes *baselines*. Os resultados demonstraram que o uso das informações extraídas pelas técnicas propostas levaram a geração de recomendações mais precisas.

Palavras-chave: Contexto, Sistemas de Recomendação, Mineração de Textos, Mineração de Opiniões.

ABSTRACT

SUNDERMANN, C. V. **Extraction of context from reviews for recommender systems using text and opinion mining**. 2020. 153 p. Tese (Doutorado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2020.

Today, with the information, service and product overload on the Web, users have found it difficult to identify what is really relevant to their interests and preferences. Thus, recommender systems are being developed and deployed on an increasing number of websites and applications to assist users in suggesting items that meet their preferences and needs. The trend in this area is the use of relevant information in order to generate more personalized and accurate recommendations to users. Studies show that the use of contextual information has made it possible to obtain good results in the recommendation. One of the major challenges encountered in the context of context-aware recommender systems is the lack of automatic methods for extracting this type of information. On the other hand, with the advancement of Web 2.0 and the growing popularity of social networking and e-commerce, users have been increasingly encouraged to write reviews describing their opinions about the items. From these reviews important information can be extracted for use in recommender systems such as context and opinions. Thus, the general purpose of this doctoral work is to advance research in the area of context-aware recommender systems, especially in the automatic extraction of contextual information. To meet the objectives of the work, a systematic review of context-aware recommender systems using opinion mining has been performed. Taking into account the lack of automatic context extraction methods as well as the relevance of information extracted from user reviews to recommender systems, this doctoral work proposes: (i) a context-aware recommender method, *CARM-TOM*, which runs from preprocessing reviews to generating recommendations using contextual information; (ii) *CIET.5_{embed}*, a context extraction technique based on word embeddings; (iii) a context-extraction technique based on association rules, the *RulesContext*; and (iv) a context extraction technique based on aspect-level opinion mining, the *CEOM*. These proposals were evaluated using the *Yelp* review dataset, nearest neighbor-based recommender systems, matrix factorization-based recommender systems, and different baselines. The results showed that the use of the information extracted by the proposed techniques led to the generation of more accurate recommendations.

Keywords: Context, Recommender Systems, Text Mining, Opinion Mining.

LISTA DE ILUSTRAÇÕES

Figura 1 – Classificação das técnicas de recomendação	31
Figura 2 – Classificação dos sistemas de recomendação sensíveis ao contexto	33
Figura 3 – Processo de mineração de textos	39
Figura 4 – Exemplo de mensagem de opinião	48
Figura 5 – Etapas da mineração de opiniões baseada em aspectos	49
Figura 6 – Publicação de trabalhos por ano em mineração de opiniões baseada em aspectos.	52
Figura 7 – Evolução das áreas de pesquisa relacionadas com a revisão sistemática.	57
Figura 8 – Grafo de relação de similaridade entre os artigos selecionados na revisão sistemática (organizados em grupos de tópicos). Cada artigo é um nó do grafo e os artigos similares são conectados por uma aresta. As cores definem os grupos de artigos.	63
Figura 9 – Visão geral do método <i>CARM-TOM</i>	84
Figura 10 – Visão geral da técnica <i>CIET.5_{embed}</i>	87
Figura 11 – Exemplo de extração de contexto utilizando a técnica <i>CIET.5_{embed}</i>	88
Figura 12 – Visão geral da técnica <i>RulesContext</i>	90
Figura 13 – Exemplo de extração de contexto utilizando a técnica <i>RulesContext</i>	91
Figura 14 – Visão geral da técnica <i>CEOM</i>	93
Figura 15 – Exemplo de extração de contexto utilizando a técnica <i>CEOM</i>	94
Figura 16 – Exemplo Ex1	94
Figura 17 – Exemplo Ex2	95
Figura 18 – Exemplo Ex3	95
Figura 19 – Exemplo Ex4	95
Figura 20 – Exemplo Ex5	96
Figura 21 – Exemplo Ex6	96
Figura 22 – Exemplo Ex7	96
Figura 23 – Gráfico com os resultados do método <i>EntityAsContext</i> utilizando a base <i>Yelp</i> e considerando o “Contexto das Reviews”	110
Figura 24 – Gráfico com os resultados do método <i>EntityAsContext</i> utilizando a base <i>YelpNormal</i> e considerando o Contexto das Reviews	111
Figura 25 – Gráfico com os resultados do método <i>EntityAsContext</i> utilizando a base <i>Yelp</i> e considerando o Contexto dos Itens	112

Figura 26 – Gráfico com alguns dos melhores resultados do método <i>TopicAsContext</i> utilizando a base <i>Yelp</i> e considerando o “Contexto das Reviews”	115
Figura 27 – Gráfico com alguns dos melhores resultados do método <i>TopicAsContext</i> utilizando a base <i>YelpNormal</i> e considerando o “Contexto das Reviews” . . .	116
Figura 28 – Gráfico com alguns dos melhores resultados do método <i>TopicAsContext</i> utilizando a base <i>Yelp</i> e considerando o “Contexto dos Itens”	117
Figura 29 – Os melhores valores de <i>MAP@10</i> para “Contexto das Reviews”	118
Figura 30 – Os melhores valores de <i>MAP@10</i> para o “Contexto dos Itens”	120
Figura 31 – Valores de <i>MAP@10</i> para a técnica <i>CIET.5_{embed}</i>	123
Figura 32 – Valores de <i>MAP@10</i> para a técnica <i>RulesContext</i>	124
Figura 33 – Comparando os valores de <i>MAP@10</i> entre as técnicas <i>CIET.5_{embed}</i> , <i>RulesContext</i> e o <i>baseline MF</i>	125
Figura 34 – Gráfico com os valores de <i>MAP@10</i> da técnica <i>CEOM</i> comparando com o <i>baseline IBCF</i>	126
Figura 35 – Gráfico com os valores de <i>MAP@10</i> da técnica <i>CEOM</i> comparando com o <i>baseline MF</i>	127
Figura 36 – Gráfico com os valores de <i>MAP@10</i> das técnicas e combinações utilizando a base <i>YelpRest</i> e o <i>baseline IBCF</i>	129
Figura 37 – Gráfico com os valores de <i>MAP@10</i> das técnicas e combinações utilizando a base <i>YelpRest</i> e o <i>baseline MF</i>	131

LISTA DE TABELAS

Tabela 1 – Estudos identificados com a busca realizada em março de 2015	52
Tabela 2 – Distribuição dos artigos por Indicador Qualis-CAPES	52
Tabela 3 – Distribuição de trabalhos por domínio de aplicação de mineração de opiniões baseada em aspectos.	53
Tabela 4 – Distribuição de trabalhos por classe de sentimento.	53
Tabela 5 – Distribuição de trabalhos por tipo de texto.	53
Tabela 6 – Estudos identificados com a busca realizada em outubro de 2018	56
Tabela 7 – Resumo dos 17 trabalhos sobre sistemas de recomendação sensíveis ao contexto que usam mineração de opiniões.	59
Tabela 8 – Respostas para as questões de pesquisa relacionadas às informações contextuais (questões 1 e 2)	60
Tabela 9 – Respostas das questões de pesquisa relacionadas às informações de opinião (questões 3 e 4).	61
Tabela 10 – Respostas para a questão de pesquisa relacionada às fontes textuais das informações contextuais e de opinião (questão 5).	62
Tabela 11 – Pontos fortes e fracos dos estudos analisados na revisão sistemática.	78
Tabela 11 – Pontos fortes e fracos dos estudos analisados na revisão sistemática. (continuação)	79
Tabela 11 – Pontos fortes e fracos dos estudos analisados na revisão sistemática. (continuação)	80
Tabela 12 – Características da informação contextual extraída pelo método <i>EntityAsContext</i> . 107	
Tabela 13 – Características da informação contextual extraída pelo método <i>TopicAsContext</i> . 107	
Tabela 14 – Comparando os algoritmos de recomendação sensíveis ao contexto, utilizando os contextos do método <i>EntityAsContext</i> , com o <i>baseline</i> IBCF (considerando “Contexto das Reviews”). Os valores que são estatisticamente diferentes que o <i>baseline</i> ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o <i>baseline</i> ficam em negrito	108
Tabela 15 – Comparando os algoritmos de recomendação sensíveis ao contexto, utilizando os contextos extraídos pelo método <i>EntityAsContext</i> , com o <i>baseline</i> IBCF (considerando “Contexto dos Itens”). Para a apresentação dos resultados em tabelas foi utilizado o seguinte padrão: os valores que são estatisticamente diferentes que o <i>baseline</i> ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o <i>baseline</i> ficam em negrito . 109	

Tabela 16 – Comparando os algoritmos de recomendação sensíveis ao contexto, utilizando os contextos do método <i>TopicAsContext</i> , com o <i>baseline</i> IBCF (considerando “ <i>Contextos das Reviews</i> ”). Para a apresentação dos resultados em tabelas foi utilizado o seguinte padrão: os valores que são estatisticamente diferentes que o <i>baseline</i> ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o baseline ficam em negrito	111
Tabela 17 – Número de casos nos quais os resultados para o conjunto de dados <i>Yelp-Normal</i> foram piores, melhores ou equivalentes aos resultados do conjunto <i>Yelp</i>	111
Tabela 18 – As melhores configurações e valores de <i>MAP@10</i> (entre parênteses) para cada informação privilegiada, considerando o método <i>TopicAsContext</i> e o “ <i>Contexto das Reviews</i> ”.	113
Tabela 19 – Comparando os algoritmos de recomendação, utilizando contextos do método <i>TopicAsContext</i> , com o <i>baseline</i> IBCF (considerando o “ <i>Contexto dos Itens</i> ”). Para a apresentação dos resultados em tabelas foi utilizado o seguinte padrão: os valores que são estatisticamente diferentes que o <i>baseline</i> ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o baseline ficam em negrito	114
Tabela 20 – As melhores configurações e valores de <i>MAP@10</i> (entre parênteses) para cada informação privilegiada, considerando o método <i>TopicAsContext</i> e o “ <i>Contexto dos Itens</i> ”.	114
Tabela 21 – Características da informação contextual extraída pela técnica <i>CIET.5_{embed}</i> .	116
Tabela 22 – Comparando o método <i>CARM-TOM</i> , utilizando os contextos extraídos pela técnica <i>CIET.5_{embed}</i> , considerando <i>MAP@10</i> . Os valores que são estatisticamente diferentes que o <i>baseline</i> ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o baseline ficam em negrito .	118
Tabela 23 – Comparando a técnica <i>CIET.5_{embed}</i> com o <i>baseline EntityAsContext</i> . Os valores que são estatisticamente diferentes que o <i>baseline</i> ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o baseline ficam em negrito	119
Tabela 24 – Características dos contextos extraídos pela técnica <i>RulesContext</i>	121
Tabela 25 – Comparando os resultados de (<i>MAP@10</i>) do algoritmo de recomendação CAMF utilizando os contextos extraídos pela técnica <i>CIET.5_{embed}</i> , com os resultados do <i>baseline</i> MF. Os valores que são estatisticamente diferentes que o <i>baseline</i> ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o baseline ficam em negrito	122

Tabela 26 – Comparando os resultados ($MAP@10$) do algoritmo de recomendação sensível ao contexto CAMF utilizando os contextos extraídos pela técnica <i>RulesContext</i> , com os resultados do <i>baseline</i> MF. Os valores que são estatisticamente diferentes que o <i>baseline</i> ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o baseline ficam em negrito .	122
Tabela 27 – Características da informação contextual extraída pela técnica <i>CEOM</i>	124
Tabela 28 – Comparando os resultados de $MAP@10$ dos algoritmos de recomendação baseados no IBCF utilizando os contextos extraídos pela técnica <i>CEOM</i> , com os resultados do <i>baseline</i> IBCF. Os valores que são estatisticamente diferentes que o <i>baseline</i> ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o baseline ficam em negrito	125
Tabela 29 – Comparando os resultados de $MAP@10$ do algoritmo de recomendação CAMF utilizando os contextos extraídos pela técnica <i>CEOM</i> , com os resultados do <i>baseline</i> MF. Os valores que são estatisticamente diferentes que o <i>baseline</i> ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o baseline ficam em negrito	126
Tabela 30 – Comparando os resultados de $MAP@10$ dos algoritmos de recomendação baseado no IBCF utilizando os contextos extraídos pelas técnicas <i>EntityAsContext</i> e <i>TopicAsContext</i> , com os resultados do <i>baseline</i> IBCF. Os valores que são estatisticamente diferentes que o <i>baseline</i> ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o baseline ficam em negrito	127
Tabela 31 – Comparando os resultados de $MAP@10$ dos algoritmos de recomendação baseados no IBCF utilizando os contextos extraídos pela técnica <i>CIET.5_{embed}</i> , com os resultados do <i>baseline</i> IBCF, para a base <i>YelpRest</i> . Os valores que são estatisticamente diferentes que o <i>baseline</i> ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o baseline ficam em negrito	128
Tabela 32 – Comparando os resultados de $MAP@10$ dos algoritmos de recomendação baseados no IBCF utilizando os contextos extraídos pela técnica <i>RulesContext</i> , com os resultados do <i>baseline</i> IBCF, para a base <i>YelpRest</i> . Os valores que são estatisticamente diferentes que o <i>baseline</i> ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o baseline ficam em negrito	128

Tabela 33 – Comparando os resultados de $MAP@10$ dos algoritmos de recomendação baseados no IBCF utilizando as combinações dos contextos extraídos pelas técnicas <i>CEOM</i> , <i>CIET.5_{embed}</i> e <i>RulesContext</i> , com os resultados do <i>baseline</i> IBCF, para a base <i>YelpRest</i> . Os valores que são estatisticamente diferentes que o <i>baseline</i> ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o baseline ficam em negrito	128
Tabela 34 – Comparando os resultados de $MAP@10$ do algoritmo de recomendação CAMF utilizando os contextos extraídos pelas técnicas <i>EntityAsContext</i> e <i>TopicAsContext</i> , com os resultados do <i>baseline</i> MF, para a base <i>YelpRest</i> . Os valores que são estatisticamente diferentes que o <i>baseline</i> ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o baseline ficam em negrito	129
Tabela 35 – Comparando os resultados de $MAP@10$ do algoritmo de recomendação CAMF utilizando os contextos extraídos pela técnica <i>CIET.5_{embed}</i> , com os resultados do <i>baseline</i> MF, para a base <i>YelpRest</i> . Os valores que são estatisticamente diferentes que o <i>baseline</i> ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o baseline ficam em negrito	130
Tabela 36 – Comparando os resultados de $MAP@10$ do algoritmo de recomendação CAMF utilizando os contextos extraídos pela técnica <i>RulesContext</i> , com os resultados do <i>baseline</i> MF, para a base <i>YelpRest</i> . Os valores que são estatisticamente diferentes que o <i>baseline</i> ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o baseline ficam em negrito	130
Tabela 37 – Comparando os resultados de ($MAP@10$) do algoritmo de recomendação CAMF utilizando a combinação dos contextos extraídos pelas técnicas <i>CEOM</i> , <i>RulesContext</i> e <i>CIET.5_{embed}</i> , com os resultados do <i>baseline</i> MF, para a base <i>YelpRest</i> . Os valores que são estatisticamente diferentes que o <i>baseline</i> ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o baseline ficam em negrito	130

SUMÁRIO

1	INTRODUÇÃO	23
1.1	Contextualização e Motivação	23
1.2	Questões de Pesquisa e Objetivos	26
1.3	Principais resultados	27
1.4	Organização da Tese	27
2	FUNDAMENTAÇÃO TEÓRICA E REVISÃO SISTEMÁTICA	29
2.1	Sistemas de Recomendação Sensíveis ao Contexto	29
2.2	Mineração de Textos	38
2.3	Extração de Informação Contextual utilizando Mineração de Textos	41
2.4	Mineração de Opiniões	46
2.5	Revisão Sistemática sobre Sistemas de Recomendação Sensíveis ao Contexto que Utilizam Mineração de Opiniões	54
2.5.1	<i>Planejando a Revisão</i>	54
2.5.2	<i>Conduzindo a revisão</i>	56
2.5.3	<i>Resultados e Discussão</i>	56
2.5.3.1	<i>Estudos Seleccionados e Vínculo com as Questões de Pesquisa</i>	56
2.5.3.2	<i>Detalhes dos Estudos Seleccionados</i>	64
2.6	Considerações Finais	80
3	RECOMENDAÇÃO SENSÍVEL AO CONTEXTO BASEADA EM MINERAÇÃO DE TEXTOS E DE OPINIÕES	83
3.1	Pré-processamento e Limpeza	84
3.2	Normalização dos Textos	85
3.3	Extração de Contexto	86
3.3.1	<i>Técnica de Extração de Contexto baseada em Word Embeddings (CIET.5_{embed})</i>	86
3.3.2	<i>Técnica de Extração de Informação Contextual baseada em Regras de Associação (RulesContext)</i>	90
3.3.3	<i>Técnica de Extração de Contexto utilizando Mineração de Opiniões (CEOM)</i>	93
3.4	Sistemas de Recomendação Sensíveis ao Contexto	97
3.5	Considerações Finais	100

4	AVALIAÇÃO EXPERIMENTAL	101
4.1	Base de <i>reviews</i> utilizada na avaliação experimental	102
4.2	Ferramentas e Métodos Utilizados	102
4.3	Configuração Experimental e Medida de Avaliação	104
4.4	Avaliação Experimental de Métodos de Extração de Contexto para a Construção de Baselines para o Domínio de Reviews	105
4.4.1	<i>Extração de Informações Contextuais</i>	105
4.4.2	<i>Resultados com algoritmos baseados no IBCF</i>	107
4.4.2.1	<i>EntityAsContext considerando o “Contexto das Reviews”</i>	108
4.4.2.2	<i>EntityAsContext considerando o “Contexto dos Itens”</i>	109
4.4.2.3	<i>TopicAsContext considerando “Contextos das Reviews”</i>	110
4.4.2.4	<i>TopicAsContext considerando o “Contexto dos Itens”</i>	112
4.5	Avaliação Experimental da Técnica CIET.5 _{embed} com algoritmos baseados no IBCF	115
4.5.1	<i>Extração de Informações Contextuais</i>	115
4.5.2	<i>Resultados</i>	117
4.5.2.1	<i>Contexto das Reviews</i>	117
4.5.2.2	<i>Contexto dos Itens</i>	119
4.6	Avaliação Experimental das Técnicas CIET.5 _{embed} e RulesContext com o algoritmo CAMF	120
4.6.1	<i>Extração de Informações Contextuais</i>	120
4.6.2	<i>Resultados “Contexto dos Itens”</i>	121
4.7	Avaliação Experimental da Técnica de Extração de Contextos baseada em Mineração de Opiniões no Domínio de Restaurantes	123
4.7.1	<i>Extração de Informações Contextuais</i>	124
4.7.2	<i>Resultados com algoritmos baseados no IBCF</i>	124
4.7.3	<i>Resultados com algoritmos baseados no CAMF</i>	125
4.8	Avaliação experimental das técnicas de extração de contexto no domínio de restaurantes	127
4.9	Considerações finais	131
5	CONCLUSÃO	133
5.1	Contribuições Científicas	133
5.2	Publicações	135
5.3	Limitações e Trabalhos Futuros	138
	REFERÊNCIAS	141

INTRODUÇÃO

1.1 Contextualização e Motivação

Atualmente, com o crescimento do universo digital, do comércio eletrônico e das redes sociais, uma grande diversidade de informações, produtos e serviços é disponibilizada na Web. Os usuários encontram, enquanto navegam, notícias, produtos, filmes e pessoas nas redes sociais. Com tantas opções, o grande desafio está em identificar o que é realmente relevante e que atenda aos reais interesses e preferências dos usuários. Assim, sistemas de recomendação surgiram com o propósito de auxiliar usuários em suas escolhas. Um sistema de recomendação é uma tecnologia de filtragem de informação que pode ser utilizada para prever valores de *ratings* para itens (produtos, serviços, filmes, entre outros), e/ou gerar um *ranking* personalizado de itens que podem ser do interesse do usuário alvo (RICCI; ROKACH; SHAPIRA, 2015; AGGARWAL, 2016). Dessa maneira, esse tipo de sistema pode auxiliar em decisões como qual produto comprar, qual filme assistir e qual hotel reservar.

Um dos principais domínios que atualmente utilizam sistemas de recomendação é o domínio de comércio eletrônico, no qual sites interagem diretamente com os clientes sugerindo produtos de interesse com o objetivo de aumentar suas vendas. Por exemplo, o site da *Amazon*¹, que foi um dos precursores nessa área, faz recomendações a usuários na forma: “Clientes que compraram esse item também compraram...” ou “Clientes que visualizaram esse item também visualizaram...” (LINDEN; SMITH; YORK, 2003). Sites de diversos domínios como *Netflix*², *Last.fm*³, *TripAdvisor*⁴ e *Facebook*⁵ também utilizam sistemas de recomendação. O uso de tais sistemas pode representar uma vantagem competitiva considerável na Web.

¹ <<https://www.amazon.com/>>

² <<https://www.netflix.com>>

³ <<http://www.last.fm>>

⁴ <<https://www.tripadvisor.com>>

⁵ <<https://www.facebook.com>>

Os sistemas de recomendação tradicionais focam em dados de usuários e itens para gerar as recomendações. Como exemplo de técnicas desse tipo podem ser citadas a filtragem colaborativa, a filtragem baseada em conteúdo e as abordagens híbridas. A filtragem colaborativa é uma técnica de recomendação que encontra correlações entre usuários para gerar as recomendações. Essa técnica tem por objetivo fazer recomendações baseando-se nas similaridades entre as avaliações de itens ou usuários. As técnicas de filtragem baseadas em conteúdo fazem recomendações considerando os atributos dos itens pertencentes ao histórico de acessos do usuário. E as abordagens híbridas combinam ambas as técnicas. Essas técnicas, em suas formas tradicionais, consideram apenas o conjunto de *ratings*, ou o conjunto de acessos dos usuários. Entretanto, estudos empíricos indicam que abordagens baseadas em contexto podem produzir recomendações mais precisas (KHARRAT; ELKHLEIFI; FAIZ, 2016; MISSAOUI *et al.*, 2017; BARAL *et al.*, 2018). Um sistema de recomendação de pacotes de viagem, por exemplo, pode melhorar o desempenho da recomendação considerando o contexto “estação do ano” no qual o usuário deseja viajar, já que alguns lugares são mais recomendados no contexto “verão” enquanto outros são mais recomendados no contexto “inverno”. Existem muitas definições de contexto na literatura, dependendo da área de aplicação. Neste trabalho, o termo contexto é definido como qualquer informação que pode ser utilizada para caracterizar a situação de uma entidade (item ou usuário) (DEY, 2001).

Sistemas de recomendação sensíveis ao contexto estão sendo amplamente investigados tanto na área acadêmica quanto em empresas. Porém alguns desafios ainda são enfrentados por esse tipo de sistema. Um dos principais desafios é a dificuldade encontrada na aquisição de informações contextuais para serem consideradas na geração das recomendações. Existe uma carência de métodos automáticos para realizarem a extração desse tipo de informação. Com isso, são buscados métodos e estratégias eficazes para essa finalidade e formas de identificar quais contextos podem ser extraídos com sucesso. Por outro lado, com o avanço da Web 2.0 e a crescente popularidade de redes sociais e comércio eletrônico, usuários têm sido cada vez mais encorajados a escrever *reviews* descrevendo suas opiniões sobre os itens. Essas *reviews* são geralmente na forma de comentários textuais, nos quais os usuários, baseados em suas experiências, explicam porque gostaram ou não de um determinado item. Existe um crescente esforço para incorporar em sistemas de recomendação as informações importantes que podem ser extraídas de *reviews*. De acordo com Chen, Chen e Wang (2015), essas informações podem beneficiar os sistemas de recomendação nas seguintes formas: (i) elas podem auxiliar no problema de esparsidade dos dados; e (ii) elas podem auxiliar a resolver o problema *cold-start* para novos usuários.

Ainda de acordo com Chen, Chen e Wang (2015), algumas das informações interessantes que podem ser extraídas de *reviews* e que podem ser utilizadas para melhorar o desempenho da recomendação são: (i) **aspectos**, os quais são os atributos de um item que um usuário discute na *review*; (ii) **opiniões gerais**, que podem ser representadas pelas orientações dos sentimentos de um usuário para um item; (iii) **opiniões dos aspectos**, que são opiniões sobre características

específicas de um item; e (iv) **informações de contexto**, pois usuários geralmente oferecem algumas dicas de contexto em seus comentários (BARAL *et al.*, 2018).

Desse modo, as *reviews* podem oferecer informações relevantes para serem consideradas por sistemas de recomendação, como informações contextuais e de opiniões (YUGOSHI, 2018). Por exemplo, o usuário pode mencionar nas *reviews* que esteve em um determinado hotel durante uma viagem com sua família ou durante uma viagem a negócios e pode expressar suas opiniões sobre os serviços do hotel que foram importantes para ele naquele contexto específico. Na *review* a seguir, extraída do site *TripAdvisor*, apresentada em Chen, Chen e Wang (2015) e adaptada como exemplo para este trabalho, é possível observar as opiniões dos aspectos do hotel em negrito e as informações contextuais sublinhadas.

*“First trip to Asia, first visit to company’s Hong Kong offices and the Four Seasons HK provided a great base for all of it. **Rooms are spacious and luxuriously appointed. Bed was comfortable. In-hotel food options were solid** and not as overpriced/-marked up as I would have expected”.*

Como o volume de *reviews* é geralmente muito grande e a maioria delas é gerada em formato de texto, é necessário utilizar técnicas de mineração de opiniões para inferir a opinião do usuário em relação a um determinado item ou em relação a um atributo do item. A mineração de opiniões pode ser executada em três níveis: (i) nível do documento, no qual é analisada a opinião geral do documento; (ii) nível da sentença, no qual é determinada a opinião presente em cada sentença do documento; e (iii) nível do aspecto, é o nível que considera mais detalhes já que são inferidas as opiniões de cada aspecto relacionado ao item (YUGOSHI, 2018).

Como observado na *review* mencionada anteriormente, considerar as opiniões no nível dos aspectos permite um melhor entendimento da preferência do usuário. Existem métodos de sistemas de recomendação sensíveis ao contexto que modelam as preferências dos usuários no nível do item e não consideram os aspectos do mesmo, isto é, eles consideram a informação contextual relacionada à avaliação geral do item (COLACE *et al.*, 2015a; YANG *et al.*, 2015; MISSAOUI *et al.*, 2017; ZANGERLE *et al.*, 2018). Entretanto, as preferências também podem ser modeladas no nível dos aspectos e tais preferências podem ser influenciadas por fatores contextuais (LEVI *et al.*, 2012; CHEN; CHEN, 2015; BARAL *et al.*, 2018; SULTHANA; RAMASAMY, 2018). Por exemplo, um usuário pode dar mais importância para a “localização” quando seu contexto é “viagem a trabalho”, mas no contexto “viagem em família”, o aspecto “quarto” pode tornar-se mais importante. Além disso, alguns métodos que consideram tanto informações contextuais quanto informações de opiniões, não utilizam métodos automáticos para extrair ambos tipos de informação. Dessa forma, considera-se muito relevante a proposta de métodos automáticos para extração de informações contextuais e de opiniões no nível dos aspectos. Além disso, a maioria dos trabalhos atuais utilizam *reviews* de usuários como fonte de informações contextuais e de opinião.

Portanto, levando em consideração a carência de métodos automáticos de extração de contexto assim como a relevância das informações possivelmente extraídas de *reviews* de usuários para os sistemas de recomendação, este trabalho de doutorado tem como foco atender às necessidades existentes na área de sistemas de recomendações sensíveis ao contexto, propondo técnicas automáticas para extração de contexto utilizando mineração de textos e mineração de opiniões.

1.2 Questões de Pesquisa e Objetivos

O propósito geral deste trabalho de doutorado é avançar as pesquisas da área de sistemas de recomendação sensíveis ao contexto, em especial na extração automática de informações contextuais. Dessa forma, o desenvolvimento deste trabalho foi guiado por questões de pesquisa referentes ao impacto das minerações de textos e de opiniões na extração automática de informações contextuais, assim como ao impacto do uso dessas informações na precisão dos sistemas de recomendação.

- Q1. Abordagens de mineração de textos facilitam o processo de extração de informações contextuais de *reviews*, assim como o uso de tais informações resulta em recomendações mais precisas?
- Q2. O uso de informações de opiniões baseadas em aspectos extraídas de *reviews* resulta em recomendações mais precisas?
- Q3. O uso combinado de informações de contexto e de opiniões baseadas em aspectos, ambas extraídas de forma automática de *reviews*, resultam em recomendações mais precisas?

De acordo com as questões de pesquisa estabelecidas, foram definidos os seguintes objetivos para o desenvolvimento deste trabalho.

- O1. Mapear os trabalhos realizados na comunidade de Sistemas de Recomendação Sensíveis ao Contexto que utilizam tanto informações contextuais quanto informações de opiniões para gerar recomendações.
- O2. Propor, desenvolver e avaliar técnicas automáticas para extração de informações contextuais de *reviews* de usuários utilizando mineração de textos. Esse objetivo está relacionado à questão de pesquisa **Q1**.
- O3. Propor, desenvolver e avaliar uma técnica para extração de informações de opiniões de usuários de *reviews* utilizando mineração de opiniões baseada em aspectos. Esse objetivo está relacionado à questão de pesquisa **Q2**.
- O4. Avaliar o uso combinado das informações contextuais extraídas pelas técnicas propostas em sistemas de recomendação sensíveis ao contexto. Esse objetivo está relacionado à questão de pesquisa **Q3**.
- O5. Construir *baselines* para os experimentos deste trabalho de doutorado avaliando o uso de informações contextuais extraídas de *reviews* por meio de métodos propostos na literatura

em sistemas de recomendação sensíveis ao contexto. Esse objetivo dá suporte às avaliações relacionadas aos objetivos **O2**, **O3** e **O4**

1.3 Principais resultados

Os principais resultados que foram obtidos com o desenvolvimento deste projeto, visando atingir os objetivos propostos e responder as questões de pesquisa, são listados a seguir.

- R1. Mapeamento sistemático da literatura sobre Sistemas de Recomendação que utilizam informações contextuais e informações de opinião. Foi conduzida uma revisão sistemática da literatura desse tema. Seguindo um protocolo bem definido, foram selecionados 17 estudos os quais foram mapeados. Este resultado atende ao objetivo **O1**.
 - R2. Proposta, desenvolvimento e avaliação de um método de recomendação sensível ao contexto que utiliza mineração de textos e de opiniões, o *CARM-TOM*. Este resultado possibilitou a avaliação das técnicas propostas, atendendo aos objetivos **O2**, **O3** e **O4**.
 - R3. Proposta, desenvolvimento e avaliação de técnicas automáticas de extração de informações contextuais que utilizam abordagens de mineração de textos. Foram propostas duas técnicas:
 - *CIET.5_{embed}*, uma técnica baseada em *word embeddings*.
 - *RulesContext*, uma técnica baseada em regras de associação.
- A partir desse resultado respondeu-se a questão de pesquisa **Q1**. Este resultado atende ao objetivo **O2**.
- R4. Proposta, desenvolvimento e avaliação de uma técnica automática de extração de informações contextuais que utiliza mineração de opiniões. Foi proposta a técnica *CEOM*. A partir desse resultado respondeu-se a questão de pesquisa **Q2**. Este resultado atende ao objetivo **O3**.
 - R5. Avaliação experimental da combinação das técnicas *CIET.5_{embed}*, *RulesContext* e *CEOM*. A partir desse resultado respondeu-se a questão de pesquisa **Q3**. Este resultado atende ao objetivo **O4**.
 - R6. Construção de dois *baselines* para serem utilizados nas avaliações experimentais das técnicas propostas neste trabalho de doutorado. Os *baselines* avaliados foram:
 - *EntityAsContext* (DOMINGUES *et al.*, 2014b), um método de extração de informações contextuais que extrai entidades nomeadas de textos e utiliza essas entidades como informações de contexto.
 - *TopicAsContext* (SUNDERMANN *et al.*, 2016), um método de extração de informações contextuais que constrói hierarquias de tópicos dos textos e utiliza os tópicos como informações de contexto.

Este resultado deu suporte às avaliações relacionadas com as questões de pesquisa **Q1**, **Q2** e **Q3** e atende ao objetivo **O5**.

1.4 Organização da Tese

O restante desta tese está organizado como se segue.

Capítulo 2 - Fundamentação Teórica e Revisão Sistemática. Nesse capítulo são apresentados conceitos essenciais para o entendimento deste trabalho e o posicionamento do mesmo na área de pesquisa na qual ele está inserido. Assim, primeiramente é apresentada uma visão geral sobre sistemas de recomendação sensíveis ao contexto e na seção seguinte sobre a mineração de textos. São apresentados alguns trabalhos de sistemas de recomendação que utilizam mineração de textos para extrair informações contextuais. Além disso, também é apresentada uma visão geral sobre mineração de opiniões, abordando os diferentes níveis dessa mineração. Por fim, nesse capítulo, é apresentada a revisão sistemática realizada, desde o planejamento da revisão até os resultados da mesma.

Capítulo 3 - Recomendação Sensível ao Contexto baseada em Mineração de Textos e de Opiniões. Nesse capítulo são apresentados: o método de recomendação sensível ao contexto baseado em mineração de textos e de opinião proposto neste trabalho (*CARM-TOM*) e as técnicas propostas para extração automática de contexto. Entre essas técnicas estão: a *CIET.5_{embed}*, que é uma técnica baseada em *word embeddings*; a *RulesContext*, uma técnica baseada em regras de associação; e a *CEOM*, uma técnica baseada em mineração de opiniões.

Capítulo 4 - Avaliação Experimental. A avaliação experimental do método *CARM-TOM* e das técnicas *CIET.5_{embed}*, *RulesContext* e *CEOM* é apresentada nesse capítulo. Mais detalhadamente, são apresentados a base de dados utilizada (*Yelp*), a construção dos baselines *EntityAsContext* e *TopicAsContext*, os métodos e ferramentas utilizadas como apoio e a métrica de avaliação considerada. Nesse capítulo também são discutidos os resultados das avaliações experimentais das técnicas propostas e das combinações das técnicas.

Capítulo 5 - Conclusão. Nesse capítulo são apresentadas as considerações finais desta tese. As questões de pesquisa apresentadas nesta introdução são retomadas, sendo sintetizadas as contribuições deste trabalho. Na sequência são apresentadas as publicações originadas deste trabalho, as limitações e direções para trabalhos futuros.

FUNDAMENTAÇÃO TEÓRICA E REVISÃO SISTEMÁTICA

Como apresentado no Capítulo 1, o propósito geral deste trabalho de doutorado é avançar as pesquisas da área de sistemas de recomendação sensíveis ao contexto, em especial na extração automática de informações contextuais. Para atender aos objetivos do trabalho, foi realizada uma revisão da literatura tanto de sistemas de recomendação sensíveis ao contexto, quanto de mineração de opiniões. Desse modo, neste capítulo será apresentada uma visão geral sobre essas áreas (Seções 2.1 e 2.4). Para identificar técnicas, ferramentas e abordagens que estão sendo propostas e aplicadas na área de mineração de opiniões baseada em aspectos, foi realizado um mapeamento sistemático, apresentado na Seção 2.4. Além disso, foi realizada uma revisão sistemática na área de sistemas de recomendação sensíveis ao contexto que utilizam mineração de opiniões. Essa revisão, apresentada na Seção 2.5, permitiu a seleção e o estudo dos principais trabalhos relacionados a este doutorado e foi publicada na revista Information (SUNDERMANN *et al.*, 2019a).

2.1 Sistemas de Recomendação Sensíveis ao Contexto

Um sistema de recomendação é uma tecnologia de filtragem de informação que pode ser usada para prever os *ratings* dos itens e/ou gerar um *ranking* de itens que podem ser do interesse dos usuários (RICCI; ROKACH; SHAPIRA, 2015; AGGARWAL, 2016). De acordo com Adomavicius e Tuzhilin (2005), sistemas de recomendação se tornaram uma área independente em meados de 1990 e desde então esses sistemas estão sendo cada vez mais utilizados em diversos setores de aplicação. Tais sistemas auxiliam usuários indicando quais itens eles podem se interessar, facilitando a busca desses usuários. Os itens podem ser produtos, serviços, pessoas, entre outros.

Os sistemas de recomendação podem ser não personalizados ou personalizados. Os

sistemas não personalizados são os mais simples, que não consideram as preferências dos usuários para fazer as recomendações. Eles se baseiam nos itens mais populares, nos itens mais bem avaliados e até mesmo em itens recém lançados para gerar a lista de recomendações (PORIYA *et al.*, 2014). A vantagem desse tipo de sistema é que ele é simples e pode ser facilmente implementado. Porém, a desvantagem é que os itens apresentados aos usuários são sempre os mesmos, sem recomendações dedicadas aos interesses pessoais de cada usuário (PORIYA *et al.*, 2014; HAMMAR; KARLSSON; NILSSON, 2013). Já a recomendação personalizada pode ser resumida como a tarefa de, baseando-se em informações pré-coletadas, estimar preferências (*ratings*) dos usuários ou, também, recomendar um conjunto de itens com base nessa estimativa (RICCI; ROKACH; SHAPIRA, 2015; AGGARWAL, 2016). Neste trabalho serão abordadas as recomendações personalizadas.

Os sistemas de recomendação podem resolver o problema da sobrecarga de informações e assim beneficiar tanto usuários quanto provedores de serviços (KONSTAN; RIEDL, 2012). De acordo com Ricci, Rokach e Shapira (2015), existem várias razões pelas quais provedores de serviços podem explorar sistemas de recomendação, como aumentar o número de itens vendidos, vender itens mais diversificados, aumentar a satisfação do usuário e melhorar a compreensão dos interesses e necessidades do usuário.

Os sistemas de recomendação utilizam vários tipos de dados para gerar recomendações. Nos sistemas tradicionais esses dados são relacionados aos itens que serão sugeridos e aos usuários que receberão as recomendações (RICCI; ROKACH; SHAPIRA, 2015; AGGARWAL, 2016). Esses dados são geralmente as preferências ou interesses dos usuários sobre os itens. O interesse de um usuário em um item é tradicionalmente medido por um *rating* que pode ser obtido de forma explícita ou implícita. Na forma explícita o usuário diz ao sistema qual sua opinião sobre o item selecionando um certo número de estrelas (SCHAFER *et al.*, 2007). Na forma implícita, o interesse do usuário pode ser coletado enquanto ele navega pelo *site*. Em outras palavras, se um usuário acessou um item, o sistema pode inferir que ele está interessado nesse item (CLAYPOOL *et al.*, 2001; RICCI; ROKACH; SHAPIRA, 2015).

Na Figura 1 está ilustrada a classificação das diferentes técnicas de recomendação (ISINKAYE; FOLAJIMI; OJOKOH, 2015). Essas técnicas são divididas em três grandes grupos: filtragem colaborativa, filtragem baseada em conteúdo e abordagens híbridas.

Na **filtragem colaborativa** (HILL *et al.*, 1995; KONSTAN *et al.*, 1997; CANNY, 2002; LINDEN; SMITH; YORK, 2003; DESHPANDE; KARYPIS, 2004; BELL; KOREN; VOLINSKY, 2007; KOREN, 2008; ABADI *et al.*, 2014; ABDELBAR *et al.*, 2018) os métodos são divididos em dois tipos principais (KOREN, 2008), métodos baseados em memória e métodos baseados em modelo. Os **métodos baseados em memória** são também conhecidos como algoritmos de filtragem colaborativa baseados em vizinhança. Eles são baseados no princípio que usuários que preferiram itens similares no passado tendem a preferir itens similares no futuro. Esses métodos podem ser **baseados no usuário** ou **baseados no item**. Na filtragem colaborativa

Figura 1 – Classificação das técnicas de recomendação

Fonte: Adaptada de Isinkaye, Folajimi e Ojokoh (2015).

baseada no usuário, os itens recomendados a um usuário são aqueles que outros usuários, com preferências similares, escolheram anteriormente. Métodos de filtragem colaborativa baseados no usuário, primeiramente, encontram os usuários mais próximos de cada usuário, isto é, aqueles com preferências mais similares. E então, somente os itens que são da preferências desses usuários são recomendados ao usuário alvo. Na filtragem colaborativa **baseada no item**, são calculadas as similaridades entre os diferentes itens da base, e então esses valores de similaridade são usados para prever os *ratings* ausentes da base.

Nas abordagens baseadas em modelo são utilizados métodos de aprendizado de máquina e mineração de dados em modelos preditivos. Alguns exemplos desses métodos incluem árvores de decisão, redes neurais, redes bayesianas e métodos de fatores latentes. Os métodos dos **fatores latentes** são destinados a explicar as preferências dos usuários, caracterizando usuários e itens por fatores latentes, que são características e padrões inferidos a partir de dados de avaliações existentes. Alguns dos algoritmos de fatores latentes mais bem-sucedidos são baseados na fatoração de matrizes, que caracteriza usuários e itens por meio de vetores fatoriais. A alta correspondência entre os fatores de itens e usuários leva a uma recomendação (KOREN, 2009). Embora os sistemas de recomendação que usam filtragem colaborativa sejam precisos e eficientes, eles podem apresentar um problema conhecido como *cold start*. Esse problema ocorre quando o sistema não consegue fazer recomendações confiáveis devido à falta de *ratings* iniciais. Outro problema enfrentado pela filtragem colaborativa é a escassez dos dados, uma vez que o número de

ratings disponíveis é geralmente muito pequeno comparado ao número de *ratings* que precisam ser fornecidas.

Na **filtragem baseada em conteúdo** (PAZZANI; BILLSUS, 1997; BILLSUS; PAZZANI, 2000; MOONEY; ROY, 2000; AHN *et al.*, 2007; ALANAZI; BAIN, 2013; ALBATAYNEH; GHAUTH; CHUA, 2014; ADNAN *et al.*, 2014) os itens recomendados a um usuário têm conteúdo semelhante aos itens que esse usuário escolheu no passado, ou seja, apenas os itens de alta similaridade com as preferências anteriores do usuário são recomendados. Os métodos de filtragem baseados em conteúdo têm a vantagem de não depender das avaliações de outros usuários. Eles podem ser transparentes, porque as explicações sobre as recomendações são facilmente geradas. Além disso, eles funcionam bem com novos itens. No entanto, esses métodos também podem apresentar problemas, e os dois principais são: (i) análise limitada de conteúdo, que é a dificuldade em extrair informações confiáveis automaticamente de vários tipos de conteúdo, como imagens, vídeos, áudios e textos; e (ii) super-especialização, como o sistema recomenda itens por meio da análise do perfil do usuário, isso faz com que os itens sejam muito semelhantes aos itens que foram acessados anteriormente pelo usuário.

As **abordagens híbridas** (BALABANOVIC; SHOHAM, 1997; WASFI, 1999; CLAYPOOL *et al.*, 1999; MELVILLE; MOONEY; NAGARAJAN, 2002; CAMPOS *et al.*, 2010; AKEHURST *et al.*, 2011; CREMONESI; TURRIN; AIROLDI, 2011; AGUILAR; PORTILLA; PUERTO, 2016; AGRAWAL; GONÇALVES; QUARESMA, 2017) visam se beneficiar das vantagens de cada tipo de abordagem, reduzindo os problemas que elas apresentam. Assim, as abordagens híbridas combinam métodos colaborativos e baseados em conteúdo. A combinação pode ser feita de diferentes maneiras. Por exemplo, um tipo de combinação é implementar esses métodos separadamente e combinar os resultados para produzir as recomendações finais. Outra maneira é usar ambos em um único modelo de recomendação.

O processo de recomendação tradicional descrito anteriormente é conhecido como bidimensional, pois considera apenas duas dimensões *Usuario* $\times$ *Item* para gerar as recomendações. Entretanto, em muitas aplicações também é importante incorporar informação contextual no processo de recomendação (ADOMAVICIUS *et al.*, 2005). Por exemplo, um pacote de viagens recomendado para o verão pode ser diferente de um pacote recomendado no inverno, ou seja, o contexto “estação do ano” neste exemplo pode interferir na preferência do usuário; uma pessoa pode preferir ler notícias de política e economia durante a semana e notícias de esportes e entretenimento no final de semana (contexto “período da semana”); o filme indicado para uma pessoa pode depender do contexto “companhia”, ou seja, quem irá assistir com ela.

Contexto é um conceito que pode ter diversas definições dependendo da área na qual ele aparece. A definição mais utilizada foi sugerida por Dey (2001): “Contexto é qualquer informação que pode ser utilizada para caracterizar a situação de uma entidade. Uma entidade pode ser uma pessoa, um lugar, ou um objeto que é considerado relevante para a interação entre um usuário e uma aplicação, incluindo o próprio usuário e as próprias aplicações”.

Sistemas de recomendação sensíveis ao contexto são sistemas que fazem recomendações considerando, além das informações de usuários e itens, também informações contextuais. A importância da informação contextual tem sido reconhecida por pesquisadores e profissionais em muitas áreas, como personalização de *sites* de *e-commerce*, recuperação de informação e computação móvel (ADOMAVICIUS; TUZHILIN, 2011). Os sistemas de recomendação sensíveis ao contexto modelam e preveem as preferências dos usuários incorporando informação contextual disponível no processo de recomendação.

De acordo com Adomavicius e Tuzhilin (2011), a informação contextual pode ser aplicada em vários estágios do processo de recomendação e seguindo esse critério os sistemas podem ser divididos em três categorias como ilustrado na Figura 2: (i) **pré-filtragem contextual**, (ii) **modelagem contextual** e (iii) **pós-filtragem contextual**.

Figura 2 – Classificação dos sistemas de recomendação sensíveis ao contexto

Fonte: Adaptada de Panniello e Gorgoglione (2012).

Na **pré-filtragem contextual** a informação contextual é utilizada para selecionar o conjunto de dados que será utilizado para o aprendizado do modelo de recomendação. As recomendações podem ser feitas utilizando um sistema de recomendação tradicional e considerando como entrada os dados selecionados. Uma vantagem dessa abordagem é que ela permite a utilização de qualquer uma das técnicas de recomendação tradicionais. Por exemplo, se uma pessoa quer assistir um filme em um sábado, o sistema de recomendação de filmes sensível ao contexto pode considerar, para gerar as recomendações, uma das técnicas tradicionais e, como dados de entrada, as avaliações feitas somente nos sábados (ADOMAVICIUS; TUZHILIN, 2011).

Adomavicius *et al.* (2005) propuseram uma abordagem que reduz o espaço multidimensional dos dados de entrada, considerando apenas os dados relevantes para o contexto.

mensional dos sistemas de recomendação sensíveis ao contexto em um espaço bidimensional tradicional $Usuário \times Item$:

“Seja $R_{Usuário \times Item}^D : U \times I \longrightarrow Ratings$ uma função para estimar *ratings* que, dados os *ratings* existentes D , pode estimar um valor para qualquer *rating*. Então, uma função de predição de *rating* tri-dimensional que aceita informação de tempo (informação contextual) pode ser definida como $R_{Usuário \times Item \times Tempo}^D : U \times I \times T \longrightarrow Ratings$. Tal função pode ser expressa por uma função de predição bidimensional de várias formas, e uma dessas formas é:

$$\forall (u, i, t) \in U \times I \times T, R_{Usuário \times Item \times Tempo}^D(u, i, t) = R_{Usuário \times Item}^{D[Tempo=t]}(Usuário, Item, Rating)(u, i),$$

em que $[Tempo = t]$ denota um pré-filtro contextual simples, e $D[Tempo = t](Usuário, Item, Rating)$ denota um conjunto de *ratings* D selecionando apenas os registros nos quais a dimensão T possui valor t e guardando somente os valores para as dimensões $Usuário$ e $Item$, assim como o próprio valor da avaliação”.

De acordo com [Adomavicius et al. \(2005\)](#), essa abordagem de redução de dimensionalidade pode ser melhor que as abordagens tradicionais em algumas situações, enquanto em outras situações isso pode não ocorrer. Por exemplo, pode ser melhor utilizar a abordagem baseada em redução para recomendar filmes no cinema em finais de semana e utilizar filtragem colaborativa tradicional para recomendar filmes para serem vistos em casa. Isso porque a abordagem baseada em redução, por um lado, constrói um modelo de recomendação para um segmento particular, e com isso, por outro lado, faz recomendações baseando-se em um menor número de acessos limitados ([ADOMAVICIUS et al., 2005](#)). Os dados considerados podem ser mais relevantes, mas eles podem crescer em um número muito pequeno, o que causa o problema de esparsidade. Como uma solução para esse problema, [Adomavicius et al. \(2005\)](#) também propuseram uma combinação da abordagem baseada em redução com as abordagens tradicionais de filtragem colaborativa (*cReduction*). Para combinar os dois métodos é necessário utilizar alguma medida de desempenho para determinar qual método é melhor em vários segmentos. Existem várias medidas que podem ser usadas para avaliar o desempenho de um sistema de recomendação, como *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), Precisão, Revocação e Medida F1. A abordagem *cReduction* é executada em duas fases:

- Utilizando o conjunto de treino, um método de recomendação é executado para cada segmento para determinar qual segmento apresenta melhor desempenho que o modelo de recomendação tradicional.
- Considerando o contexto da sessão atual, o melhor modelo contextual é selecionado para gerar as recomendações, isto é, o modelo que é melhor avaliado pela medida de desempenho.

Na abordagem de **pós-filtragem contextual** a informação de contexto é usada depois da construção de um modelo de recomendação tradicional para filtrar ou reordenar as recomendações, isto é, o contexto é inicialmente ignorado. Quando as recomendações são geradas, a abordagem de pós-filtragem contextual ajusta a lista de recomendações obtidas para cada usuário considerando a informação contextual. De acordo com [Adomavicius e Tuzhilin \(2011\)](#), os ajustes na lista de recomendações podem ser feitos:

- **Filtrando** as recomendações que são irrelevantes em um dado contexto; ou
- **Ajustando** a classificação das recomendações na lista baseando-se em um certo contexto.

Por exemplo, se uma pessoa quer ver um filme no domingo e é conhecido que nos domingos ela só assiste filmes de terror, então o sistema pode considerar somente as recomendações de filmes de terror para exibir ao usuário.

[Panniello e Gorgoglione \(2012\)](#) propuseram duas abordagens de pré-filtragem contextuais conhecidas como *Weight PoF* e *Filter PoF*. Ambas analisam os dados para um determinado usuário em um contexto específico calculando a probabilidade do usuário escolher um item particular nesse contexto. Depois de obter as recomendações utilizando uma abordagem tradicional, tais recomendações são contextualizadas utilizando as probabilidades calculadas.

A probabilidade contextual $P_C(u, i)$, em que o usuário u acessa o item i no contexto C , é calculada como o número de vizinhos (usuários similares a u) que acessaram o mesmo item no mesmo contexto, dividido pelo número total de vizinhos. As abordagens *Weight PoF* e *Filter PoF* se diferem na forma que as recomendações são contextualizadas. Em particular, na abordagem *Weight PoF* cada *rating* é multiplicado pela probabilidade $P_C(u, i)$:

$$Rating_C(u, i) = Rating(u, i) \times P_C(u, i) \quad (2.1)$$

Enquanto que a abordagem *Filter PoF* filtra os *ratings* utilizando um valor P^* de limiar de $P_C(u, i)$:

$$Rating_C(u, i) = \begin{cases} Rating(u, i) & \text{if } P_C(u, i) \geq P^* \\ 0 & \text{if } P_C(u, i) < P^* \end{cases} \quad (2.2)$$

Na abordagem de **modelagem contextual** o contexto é usado nos modelos de recomendação, isto é, a informação contextual faz parte do modelo juntamente com os dados de itens e usuários. Enquanto nas abordagens de pré-filtragem e pós-filtragem contextuais podem ser utilizadas funções bi-dimensionais tradicionais, a abordagem de modelagem contextual usa, geralmente, funções verdadeiramente multidimensionais. Essas funções podem representar modelos preditivos como árvores de decisão, regressão, modelos probabilísticos ou outros, ou podem representar cálculos heurísticos que incorporam informação contextual.

[Domingues, Jorge e Soares \(2013\)](#) propuseram uma abordagem que usa o atributo

contextual como um item virtual, isto é, esse atributo é tratado como um item comum para construir o modelo de recomendação. Então, essa abordagem chamada *DaVI* (*Dimensions as Virtual Item*), permite o uso de algoritmos tradicionais de recomendação. Formalmente, seja $U = \{u_1, u_2, \dots, u_m\}$ o conjunto de usuários e $I = \{i_1, i_2, \dots, i_n\}$ o conjunto de itens, existem outras dimensões, por exemplo, informação contextual, $D = \{D_1, D_2, \dots, D_t\}$, em que cada dimensão D inclui um conjunto de valores, i.e., $D = \{d_1, d_2, \dots, d_f\}$. Seja j o número de sessões multidimensionais $S' = \{s'_1, s'_2, \dots, s'_j\}$. Cada sessão s' é uma tupla definida por um usuário $u \in U$, um conjunto de itens acessados $I_{s'} \subset I$ e um conjunto $D_{s'} \subseteq D_1 \cup D_2 \cup \dots \cup D_t$ contendo todos os valores da dimensão associados com a sessão s' , i.e., $s' = \langle u, I_{s'}, D_{s'} \rangle$.

A abordagem *DaVI* consiste em converter cada sessão multidimensional $s' = \langle u, I_{s'}, D_{s'} \rangle$ em uma sessão bi-dimensional estendida $s'' = \langle u, I_{s''} \cup D_{s''} \rangle$, na qual os valores da dimensão adicional $D_{s''}$ são usados como itens virtuais juntamente com os itens reais de $I_{s''}$.

É importante determinar quais dimensões devem ser incluídas no modelo de recomendação, como algumas dimensões são mais informativas que outras. Por essa razão, [Domingues, Jorge e Soares \(2013\)](#) propuseram diferentes algoritmos para a abordagem *DaVI*. O algoritmo *DaVI-BEST* avalia e seleciona a melhor dimensão de um conjunto de dados para construir o modelo de recomendação multidimensional. Para determinar a melhor dimensão para um sistema de recomendação, o algoritmo *DaVI-BEST* primeiro aplica a abordagem *DaVI* em cada dimensão candidata e constrói seu respectivo modelo de recomendação multidimensional. A abordagem então avalia o modelo e seleciona a melhor dimensão, aquela cujo modelo de recomendação apresenta o melhor desempenho.

Sistemas de recomendação têm sido avaliados de várias formas. Para fazer uma avaliação boa e confiável desse tipo de sistema é importante entender seus objetivos e tarefas. De acordo com [Shani e Gunawardana \(2011\)](#), existem três tipos diferentes de avaliação de sistemas de recomendação: (i) **avaliação offline** - é, geralmente, a avaliação mais fácil de ser conduzida utilizando conjunto de dados pré-coletados e um protocolo que modela o comportamento do usuário para estimar medidas de desempenho da recomendação; (ii) **estudos com usuários** - opção mais cara que o teste *offline* e requer que um grupo de pessoas execute um conjunto de tarefas utilizando o sistema; e (iii) **avaliação online** - mede o impacto das recomendações quando estas são apresentadas a um usuário real. A avaliação online é um experimento de grande escala, deve ser executado em um sistema já implantado e analisa a mudança no comportamento do usuário quando ele interage com diferentes sistemas de recomendação.

Para [Herlocker et al. \(2004\)](#), [Shani e Gunawardana \(2011\)](#), [Aggarwal \(2016\)](#), a acurácia da previsão é a propriedade mais utilizada e mencionada na literatura de sistemas de recomendação. As métricas de acurácia medem o quanto os *rankings* previstos pelos sistemas de recomendação se diferem dos *rankings* verdadeiros das preferências do usuário. Elas também podem medir o quão bem um sistema pode prever o valor da avaliação para um item específico. Geralmente assume-se que um sistema de recomendação que fornece previsões mais precisas

será o preferido pelos usuários.

Aggarwal (2016) classificam as métricas da acurácia da recomendação em duas classes: **acurácia da previsão** e **acurácia do ranking**. As métricas de **acurácia da previsão** medem o quão similares são as avaliações previstas pelo sistema de recomendação das avaliações verdadeiras do usuário. Os avaliadores que desejam medir a acurácia da previsão podem utilizar uma métrica que calcula a diferença entre a avaliação prevista e a verdadeira avaliação. Exemplos de métricas para este contexto são: *Mean Absolute Error* (MAE) e *Mean Square Error* (MSE).

Já as métricas de **acurácia do ranking** medem a habilidade do sistema recomendar itens ordenados ou *rankings* que correspondem às preferências dos usuários. Exemplos de métricas dessa classe são: medidas de correlação como o coeficiente ρ de Spearman e o coeficiente Tau de Kendall, a medida Utilidade *Half-Life* (HERLOCKER *et al.*, 2004; SHANI; GUNAWARDANA, 2011), a métrica *Mean Reciprocal Rank* (MRR) e a métrica *Mean Average Precision* (MAP).

A medida MRR vem sendo muito utilizada na literatura (CHEN; CHEN, 2014; CHEN; CHEN, 2015; ORELLANA-RODRIGUEZ; DIAZ-AVILES; NEJDL, 2015) e avalia a posição do *ranking* de um item da preferência do usuário na lista de recomendações geradas (CHEN; CHEN, 2015). A MRR é formalmente definida como:

$$MRR = \frac{\sum_{u=1}^{|U|} \frac{\delta_{rank_u \leq N}}{rank_u}}{|U|}, \quad (2.3)$$

em que $|U|$ é o número de usuários, $rank_u$ é a posição do item no *ranking* de itens do usuário u e $\delta_{rank_u \leq N}$ é uma função indicadora que é igual a 1 se $rank_u \leq N$, isto é, se o item estiver na lista de recomendações, e é igual a 0 caso contrário.

Uma outra abordagem para avaliar a acurácia do *ranking* em sistemas de recomendações é calcular a precisão média em vários níveis diferentes de revocação ou a precisão média na posição de cada item relevante no *ranking*. A métrica MAP calcula a precisão considerando a respectiva posição na lista ordenada de itens recomendados. Com essa medida é calculado um único valor de acurácia para um conjunto U de usuários:

$$MAP(U) = \frac{1}{|U|} \sum_{u=1}^{|U|} AP(R_u), \quad (2.4)$$

em que $|U|$ é o tamanho do conjunto de usuários, ou seja, o número total de usuários, R_u é o *ranking* de itens para cada usuário u e $AP(R_u)$ é a precisão média (Average Precision - AP) para o *ranking* R_u . A precisão média é calculada como:

$$AP(R) = \frac{1}{|I_{RR}|} \sum_{i \in I_{RR}} Precisão(i), \quad (2.5)$$

em que I_{RR} é o conjunto dos itens recomendados que são de fato relevantes, $|I_{RR}|$ é o tamanho desse conjunto e $Precisão(i)$ é a precisão do item i em sua posição do *ranking*.

Sendo RR o conjunto de itens disponíveis que são relevantes e R o conjunto de itens recomendados, a Precisão é a fração das recomendações feitas que são relevantes ao usuário com relação ao número total de recomendações feitas. Ela representa a probabilidade de um item selecionado ser relevante e é calculada como:

$$Precisão = \frac{|RR \cap R|}{R} \quad (2.6)$$

De acordo com Ekstrand, Riedl e Konstan (2011), Herlocker *et al.* (2004), Shani e Gunawardana (2011), a acurácia não é o único critério de interesse na avaliação de um sistema de recomendação, e em alguns casos pode não ser o mais importante. Muitos outros critérios de avaliação podem ser considerados, alguns deles são:

- **Serendipidade** — serendipidade mede a habilidade de um sistema de recomendação recomendar itens que o usuário ainda não conhece e o quão surpreendente é uma recomendação bem sucedida.
- **Cobertura** — mede a porcentagem do conjunto de itens que o sistema de recomendação é capaz de recomendar.
- **Taxa de aprendizagem** — mede a quantidade de dados de treino que é necessária para o sistema tornar-se um previsor efetivo e gerar boas recomendações.
- **Confiança** — mede o quão certo está o sistema de recomendação de que suas recomendações ou previsões são precisas. Medir a confiança de um sistema é uma tarefa difícil, porém sistemas que não incluem algumas medidas de confiança são prováveis de conduzir os usuários a tomarem decisões mais pobres do que os sistemas que incluem confiança. Se a confiança das previsões pode ser calculada, ela pode ser exibida aos usuários para ajudá-los a decidir se a relação risco-retorno é apropriada.
- **Avaliação do usuário** — mede a reação do usuário utilizando um sistema de recomendação.

Como observado nesta seção, os sistemas de recomendação podem utilizar informações adicionais, como informações de contexto, para melhorar a acurácia da recomendação. Apesar de existirem muitos estudos na área de sistemas de recomendação sensíveis ao contexto, existe uma carência de métodos automáticos para a aquisição de informação contextual. Dessa forma, este trabalho de doutorado busca contribuir para o estado da arte da área de extração automática de informações contextuais, propondo técnicas que utilizam mineração de textos e mineração de opiniões. Nas próximas seções são apresentadas as áreas de mineração de textos e de opiniões.

2.2 Mineração de Textos

A mineração de textos é um processo que tem como objetivo descobrir padrões desconhecidos em dados não-estruturados ou semi-estruturados. É uma área interdisciplinar que engloba: aprendizado de máquina, recuperação de informação, estatística, visualização de informação e

processamento de linguagem natural. Além disso, a mineração de textos pode ser utilizada em várias áreas aplicações, como: recuperação de informação, fiscalização e filtragem de *e-mails*, detecção de anomalias e sistemas de recomendação (BERRY; CASTELLANOS, 2007; RICCI *et al.*, 2011).

Assim como a mineração de dados, o processo de mineração de textos pode ser dividido em cinco etapas principais (REZENDE, 2003), como pode ser observado na Figura 3, sendo elas: Identificação do problema, Pré-processamento, Extração de padrões, Pós-processamento e Utilização do conhecimento.

Figura 3 – Processo de mineração de textos

Fonte: Rezende (2003).

Na **identificação do problema**, o especialista do domínio realiza um estudo do problema e define os objetivos e metas da mineração de textos. Além disso, ele identifica e seleciona a coleção de textos que será utilizada na extração de conhecimento e algum conhecimento prévio que pode ser utilizado durante o processo, caso exista. A identificação do problema é uma etapa muito importante para o decorrer da mineração, pois ela guia as etapas seguintes e produz reflexos positivos ou negativos no desempenho global.

O **pré-processamento** visa estruturar os textos de maneira a torná-los processáveis por algoritmos de aprendizado de máquina. É a etapa mais importante dentro do processo de mineração de textos, pois a qualidade da representação da coleção influencia o resultado final da extração de conhecimento. A partir da coleção de textos, é feita a preparação dos textos para viabilizar a extração dos termos importantes da coleção. Estes termos devem ser relevantes e devem discriminar a coleção.

O primeiro passo do pré-processamento é a preparação do texto, que consiste na padronização e na limpeza dos textos da coleção. A padronização é necessária para converter textos que estão em formatos como hipertexto, *pdf* ou outros, para o formato de texto plano sem formatação. Feita a padronização, o processo de limpeza é conduzido eliminando-se, em geral, as *stopwords*, que são palavras consideradas irrelevantes para a representação da coleção textual. Normalmente é utilizada nesse processo uma lista de *stopwords*, a *stoplist*. As *stopwords* podem ser divididas em duas categorias: *stopwords* gerais e específicas do domínio (MAKREHCHI; KAMEL, 2008). As gerais incluem as *stopwords* padrões, como artigos, preposições, conjunções e outras. Já as *stopwords* específicas do domínio, são reconhecidas como um conjunto de palavras que não têm valor discriminativo dentro de um domínio ou contexto específico. Como exemplo considera-se o termo “aprendizado”, que pode ser uma *stopword* no domínio da “educação”, mas no domínio de ciência da computação pode ser um termo importante para representar e diferenciar as classes dos textos.

O próximo passo do pré-processamento é a extração de termos. Para essa extração algumas técnicas são utilizadas para buscar padrões que simplifiquem as formas de apresentação dos termos. Entre essas técnicas estão a radicalização, a lematização e a substantivação.

Normalmente os termos são tratados como um conjunto de palavras independentes, conhecido como *bag-of-words*. A estrutura mais utilizada para representar a *bag-of-words* é conhecida como Matriz Documento-Termo ou Matriz Atributo-Valor (SALTON; MCGILL, 1983; WEISS *et al.*, 2005). Essa matriz possui m linhas e n colunas. As m linhas representam os documentos d_1 a d_m da coleção e as n colunas representam os termos t_1 a t_n que discriminam os documentos. Quando os documentos possuem classes ou rótulos, eles aparecem na matriz como uma coluna especial Y . Os elementos da matriz a_{11} a a_{mn} são os valores dos atributos calculados na terceira etapa e que relacionam os termos aos documentos, ou seja, são pesos que indicam o quanto o termo é relevante para representar o documento. Assim, por exemplo, o peso a_{11} é o valor atribuído ao termo t_1 no documento d_1 . Esses valores de pesos podem ser calculados considerando pesos binários, isto é, atribuindo-se 0 quando o termo não está presente no documento ou 1 quando o termo está presente ou pode-se usar medidas como: frequência do termo TF (*Term Frequency*), frequência do documento DF (*document frequency*) e $TF-IDF$ (*Term Frequency - Inverse Document Frequency*). A frequência do termo, $TF(t_x, d_y)$, é o número de vezes que o termo t_x aparece no documento d_y , a frequência do documento, $DF(t_x)$, é o número de documentos nos quais o termo t_x está presente e a $TF-IDF$ é uma ponderação da frequência dos termos.

Na **extração de padrões** são cumpridos os objetivos definidos na identificação do problema. Esta etapa consiste em escolher a tarefa de mineração de dados a ser empregada, escolher o algoritmo a ser aplicado e, por fim, extrair os padrões. A tarefa é escolhida de acordo com o objetivo do processo e pode ser preditiva ou descritiva (REZENDE, 2003).

Tarefas preditivas generalizam exemplos ou experiências passadas, com respostas co-

nhecidas, em um modelo capaz de identificar a classe de um exemplo novo. Entre as tarefas preditivas estão: *classificação* e *regressão*. O objetivo da *classificação* é, a partir de um conjunto de exemplos, que consistem de um conjunto de atributos e um atributo classe, encontrar relacionamentos entre os atributos e a classe e prever a classe de um exemplo novo e desconhecido. A *regressão* é similar à classificação, com a diferença de que o atributo a ser predito é contínuo e não discreto como na classificação.

Já as tarefas descritivas consistem na identificação de comportamentos presentes no conjunto de dados, sendo que esses dados não apresentam rótulos especificados. Dentre elas estão: *regras de associação*, *sumarização* e *agrupamento (clustering)*. O objetivo das *regras de associação* é encontrar associações entre os itens de dados. Sua aplicação tradicional está na análise das cestas de mercados, que tem como objetivo descobrir como os itens comprados por clientes em um supermercado estão associados. As regras podem nos dizer que um cliente que compra um produto y em uma determinada situação, tende a comprar também o produto x . A sumarização envolve métodos para encontrar uma descrição compacta para um subconjunto de dados (FAYYAD; PIATETSKY-SHAPIO; SMYTH, 1996), como, por exemplo, definição da média e desvio padrão dos dados. A tarefa de agrupamento, ou *clustering* tem o objetivo de formar grupos com itens muito similares entre si e muito diferentes dos itens de outros grupos.

O **pós-processamento** é a etapa na qual todas as descobertas feitas na etapa de extração de padrões são simplificadas, avaliadas, visualizadas ou apenas documentadas para o usuário final. É nesta etapa que o conhecimento extraído é validado por meio de avaliações. Nessas avaliações devem estar presentes o especialista do domínio e o especialista de mineração de textos para, juntos, verificarem se o objetivo do processo foi realmente atingido.

O conhecimento, após ser avaliado e validado na etapa de pós-processamento, é consolidado e pode ser utilizado. Ele é então aplicado para apoiar algum processo de tomada de decisão, conforme o objetivo definido na etapa de identificação do problema.

Nesta seção foram descritas as etapas do processo de mineração de textos. Na próxima seção são apresentados os trabalhos de sistemas de recomendação que utilizam mineração de textos para extração de informações contextuais.

2.3 Extração de Informação Contextual utilizando Mineração de Textos

Como já mencionado, o conceito de contexto pode assumir diversas definições, sendo a definição proposta por Dey (2001) a mais utilizada na literatura e, portanto, adotada neste trabalho. De acordo com Adomavicius e Tuzhilin (2011), a informação contextual pode ser obtida de três formas:

- **Explícita** — os métodos de extração explícita coletam informações de contexto por meio

de questões direcionadas, ou seja, o usuário pode informar seu contexto por meio de, por exemplo, preenchimento de formulários.

- **Implícita** — métodos de extração implícita acessam a informação contextual diretamente de dados do ambiente Web. Esses métodos não precisam interagir com o usuário, eles conseguem, por exemplo, extrair essas informações como tempo e localização do *log* de acessos dos usuários.
- **Inferida** — para inferir informação contextual, podem ser utilizadas técnicas de mineração de dados ou mineração de textos. Por exemplo, técnicas de mineração de textos podem ser aplicadas em *reviews* de usuários em busca de informações contextuais como tempo e local.

Nos métodos explícitos, os usuários geralmente não se interessam em preencher formulários se não houver uma motivação para isso. Nos métodos implícitos a informação obtida dos *logs* de acessos são normalmente valores que não podem ser diretamente utilizados por sistemas de recomendação sensíveis ao contexto. Dessa maneira, os métodos de inferência podem ser mais efetivos na busca pela informação contextual para ser utilizada diretamente pelos sistemas de recomendação. Técnicas de mineração de dados/textos podem ser aplicadas em *logs* de acessos e conteúdos de páginas da Web para extrair informação contextual de forma automática (LEE *et al.*, 2010).

Li, Nie e Zhang (2010) investigaram *reviews* de restaurantes e quatro tipos de informação contextual: (i) “tempo”, em qual horário do dia ocorreu; (ii) “ocasião”, a refeição foi para qual ocasião; (iii) “localização”, em qual cidade ocorreu o evento; e (iv) “companhia”, quais pessoas participaram da refeição. Os autores desenvolveram algoritmos com auxílio de ferramentas de processamento de língua natural como GATE¹ (CUNNINGHAM *et al.*, 2002). Os procedimentos utilizados por Li, Nie e Zhang (2010) para extrair cada tipo de informação contextual foram:

- **Tempo** — os horários das refeições foram classificados nos tipos “*breakfast*”, “*lunch*”, “*dinner*”, “*brunch*”, “*morning tea*” e “*afternoon tea*”. Li, Nie e Zhang (2010) utilizaram um dicionário para tais tipos de refeição e um método de correspondência de *strings* para encontrar refeições contidas nas *reviews*. O tempo foi extraído utilizando o reconhecedor de entidades nomeadas ANNIE² que é um módulo do *software* GATE.
- **Ocasião** — o módulo ANNIE reconhece algumas datas especiais nos textos. Dessa forma, Li, Nie e Zhang (2010) utilizaram esse reconhecedor de entidades também para extrair ocasiões das *reviews*. Além das ocasiões já inseridas no ANNIE, os autores complementaram com uma lista de feriados dos Estados Unidos extraídos da *Wikipedia*³ e com algumas ocasiões como aniversários.
- **Localização** — normalmente os usuários, ao escreverem as *reviews*, não especificam

¹ <<http://gate.ac.uk>>

² <<https://gate.ac.uk/ie/annie.html>>

³ <<https://www.wikipedia.org/>>

nomes de cidades, portanto essa informação foi extraída do perfil do usuário.

- **Companhia** — Li, Nie e Zhang (2010) utilizaram dois métodos: (i) “*company reference*”, no qual eles geraram um dicionário de diferentes tipos de palavras ou frases relacionadas a companhias utilizando padrões de preposição como “com meu...”, e, utilizando esse dicionário, executaram correspondência de *strings*. Os autores extraíram dessas frases substantivos como termos de companhia, o que resultou em um dicionário com 167 entradas. Essas entradas foram agrupadas em seis grupos de atributos de companhia: “*family*”, “*friend*”, “*couple*”, “*colleague*”, “*meal company*” e “*pet*”. Então, utilizando esse dicionário, as *reviews* foram rotuladas dentro dessas categorias; (ii) “*company classifier*”, 1000 sentenças com termos de companhia foram extraídas para construir três classificadores - um classificador com atributos da *bag-of-words*, um classificador baseado em regras e um classificador híbrido. Para o classificador baseado em regras, foram analisados os aspectos estruturais da janela em que os termos complementares ocorreram, especificamente os verbos e preposições adjacentes associados a esses termos. Dessa forma, foram coletados termos e expressões com alta frequência, incluindo verbos, combinações de proposição de verbos e combinações de genitivo de verbos de todo o corpus, e então foi construída uma lista de regras para decidir se existe um contexto complementar com base nessas estruturas. Para o classificador híbrido, Li, Nie e Zhang (2010) usaram os padrões identificados pelo classificador baseado em regras como recursos para o Modelo MaxEnt (RATNAPARKHI, 1998). Para treinar o classificador, também incluíram recursos como POS tags do verbo e do candidato candidato a termo, a ocorrência de um termo de refeição, como “almoço”, a ocorrência de pronomes e o genitivo do termo associado. Na avaliação realizada, o classificador híbrido apresentou os melhores resultados entre os três classificadores.

Para integrar o contexto nos sistemas de recomendação, Li, Nie e Zhang (2010) consideraram duas formas: uma abordagem de pré-filtragem conhecida como “*Boolean model*” e uma abordagem conhecida como “*probabilistic-based approach*” proposta por eles. Os autores avaliaram o desempenho das duas abordagens e compararam os resultados com a filtragem colaborativa tradicional. De acordo com Li, Nie e Zhang (2010), os resultados mostraram que o contexto é um fator importante que afeta a escolha dos usuários.

Aciar (2010) propôs uma técnica para detectar sentenças das *reviews* que possuem informação contextual. Nessa técnica foram aplicadas ferramentas de mineração de textos para definir um conjunto de regras que permitem identificar as sentenças. As sentenças são classificadas em duas categorias: “Contextual” e “Preferências”. A categoria “Contextual” reúne sentenças que contêm informação sobre o contexto que a *review* foi escrita. Já a categoria “Preferências” reúne sentenças que contêm informação sobre os atributos que os consumidores avaliaram.

Para obter as regras de classificação, Aciar (2010) utilizou “*Text-Miner Software Kit*” (TMSK) e “*Rule Induction Kit for Text*” (RIKTEXT). Foram utilizadas 100 *reviews* do domínio

de turismo do *site TripAdvisor*⁴ para treino e teste no processo de geração de regras. Além disso, 50 novas *reviews* foram utilizadas nos experimentos para avaliar a acurácia das regras de classificação nas duas classes. Os resultados foram considerados bons, por causa dos altos valores apresentados de Precisão, Revocação e Medida F1.

Hariri *et al.* (2011) introduziram um sistema de recomendação sensível ao contexto que obtém informação contextual minerando *reviews* de hotéis escritas por usuários. A informação contextual é combinada com o histórico de *ratings* do usuário para calcular uma função de preferência em um conjunto de itens. O conjunto de dados utilizado foi um conjunto de *reviews* de hotéis do *site TripAdvisor*.

No conjunto de dados, o atributo “*kind of trip*”, atribuído a uma *review*, mostra os tipos de viagens que os usuários sugerem ao hotel. Esse atributo pode ser selecionado pelo usuário dentro de um conjunto de 5 opções: “*family*”, “*couple*”, “*sole trip*”, “*business*” e “*with friends*”. Quando essa informação é passada pelo usuário, ela pode ser facilmente utilizada no algoritmo de recomendação. Caso contrário, é necessário utilizar um método de inferência para saber a probabilidade de cada tipo de viagem (contexto). Sendo assim, Hariri *et al.* (2011) adotaram uma forma de inferir contexto que utiliza um classificador que é treinado pela amostra de descrição e seus respectivos contextos. Por se tratar de um problema de classificação multirrótulo, Hariri *et al.* (2011) utilizaram *Labeled Latent Dirichlet Allocation (Labeled-LDA)* como método de classificação. Dessa forma, o contexto é exibido como uma distribuição de probabilidades no conjunto de categorias de viagem.

A avaliação do sistema consistiu em duas partes principais. No primeiro experimento, Hariri *et al.* (2011) focou em avaliar a acurácia do módulo de inferência de contexto. No segundo experimento foi comparado o desempenho do sistema de recomendação utilizando o contexto extraído pelo método proposto com o sistema de recomendação *kNN* tradicional. A medida de desempenho utilizada foi *Hit Ratio* e foi executada a validação cruzada *leave-one-out*. Os autores concluíram que utilizando informações contextuais, a medida *Hit Ratio* apresentou valores mais altos.

Bauman e Tuzhilin (2014) apresentaram um método para encontrar informações de contexto relevantes em *reviews* de usuários. Nesse método, as *reviews* são classificadas como “específicas” e “genéricas”. Os autores perceberam que a informação contextual está contida principalmente em *reviews* específicas, que são aquelas que descrevem visitas de um usuário a um estabelecimento. A informação contextual raramente aparece nas *reviews* genéricas, pois em *reviews* desse tipo são expressas impressões gerais sobre algum estabelecimento. Dessa forma, o contexto é extraído das *reviews* específicas utilizando dois métodos: (i) “*word-based*”, no qual são identificadas as palavras mais importantes relacionadas ao contexto; e (ii) “*LDA-based*”, método que é baseado em *LDA*.

⁴ <<http://www.tripadvisor.com>>

O primeiro passo da abordagem proposta consiste em separar as *reviews* genéricas das *reviews* específicas. Para isso, Bauman e Tuzhilin (2014) identificaram certas características que prevalecem em um tipo de *review* mas não fazem parte do outro tipo. De acordo com os autores, usuários que descrevem experiências em restaurantes tendem a escrever *reviews* longas e usam muitos verbos no passado, enquanto que nas *reviews* genéricas os usuários tendem a utilizar verbos no presente com mais frequência. Assim, para separar os dois tipos de *reviews*, Bauman e Tuzhilin (2014) identificaram várias características como: tamanho da *review*, número total de verbos utilizados e o número de verbos no passado. Por fim, para separar as *reviews* foi utilizado o método de agrupamento *K-means*. O passo seguinte consiste em aplicar os métodos “*word-based*” e “*LDA-based*” nas *reviews* agrupadas em duas classes. A ideia do método “*word-based*” é identificar os substantivos que ocorrem com maior frequência nas *reviews* específicas do que nas *reviews* genéricas. No método “*LDA-based*”, a principal ideia é gerar uma lista de tópicos utilizando o método *LDA* e identificar, entre esses tópicos, aqueles que correspondem à informação contextual. O terceiro passo consiste em percorrer as listas de palavras e tópicos gerados e selecionar informações contextuais dessas listas.

Para validar a abordagem, Bauman e Tuzhilin (2014) utilizaram um conjunto de dados do site *Yelp*⁵, que foi oferecido para a competição *RecSys 2013*⁶. A abordagem foi aplicada em três domínios (*Restaurants*, *Hotels* and *Beauty & Spas*). As *reviews* foram divididas em “específicas” e “genéricas”. Para avaliar o agrupamento das *reviews*, os autores rotularam manualmente 900 *reviews* (300 *reviews* de cada domínio). A acurácia do método de separação ficou em torno de 0.9, o que indica um bom desempenho. Após a separação, foi executada a extração de informações contextuais. Os resultados mostraram que os dois métodos (“*word-based*” e “*LDA-based*”) são complementares, pois quando um deles não identificou um contexto específico, o outro método identificou e ambos identificaram todos os tipos de contexto dos diferentes domínios.

A informação contextual pode ser representada e estruturada de várias formas. Uma forma de organizar esse tipo de informação é utilizando estruturas hierárquicas. Adomavicius *et al.* (2005), Panniello e Gorgoglione (2012) representaram o contexto como árvores. Dada essa possibilidade de organização hierárquica do contexto, foram utilizadas, em trabalhos anteriores, hierarquias de tópicos como forma de organizar e extrair o contexto do conteúdo textual de páginas Web (DOMINGUES *et al.*, 2014a; DOMINGUES *et al.*, 2014b; SUNDERMANN *et al.*, 2014; SUNDERMANN *et al.*, 2015; SUNDERMANN *et al.*, 2016).

Em Domingues *et al.* (2014a), foram construídas hierarquias de tópicos das páginas da Web e os tópicos foram utilizados como informação contextual dessas páginas (itens) em sistemas de recomendação sensíveis ao contexto. Para construir as hierarquias de tópicos foi utilizado um método não-supervisionado chamado BC² (*Buckshot Consensus Clustering*) (MARCACINI; HRUSCHKA; REZENDE, 2012).

⁵ <www.yelp.com>

⁶ <<https://www.kaggle.com/c/yelp-recsys-2013>>

Domingues *et al.* (2014b) estenderam o trabalho Domingues *et al.* (2014a) utilizando também entidades nomeadas das páginas da Web como informações contextuais (*EntityAsContext*). O reconhecimento de entidades foi executado utilizando o REMBRANDT (CARDOSO, 2008), um sistema que reconhece classes de entidades nomeadas, como coisas, localizações, organizações, pessoas e outras, em textos escritos em português.

Muitos dos métodos na literatura para construir hierarquias de tópicos representam os textos como uma *bag-of-words* tradicional, isto é, esses métodos consideram os textos como um conjunto desordenado de termos únicos. Entretanto, Marcacini e Rezende (2013) propuseram um método, chamado *LUPI-based Incremental Hierarchical Clustering* (LIHC) para construir hierarquias de tópicos que utilizam além da informação técnica (*bag-of-words*), também informação privilegiada, que é um tipo de informação mais valiosa extraída dos textos. Em Sundermann *et al.* (2014) (*TopicAsContext*), as hierarquias de tópicos das páginas da Web foram construídas utilizando o método LIHC. Foram consideradas a *bag-of-words* como informação técnica e as entidades nomeadas, extraídas das páginas pelo REMBRANDT, como informações privilegiadas.

O método LIHC original usa somente um tipo de informação privilegiada para construir as hierarquias de tópicos. Em Sundermann *et al.* (2015), o método LIHC foi estendido para ser capaz de trabalhar com dois tipos de informação privilegiada, isto é, para construir hierarquias de tópicos utilizando além da informação técnica, também outros dois tipos de informação privilegiada. Dessa forma, foi proposto utilizar, como informação contextual, as hierarquias de tópicos construídas utilizando três tipos de informação: *bag-of-words* (informação técnica), entidades nomeadas (informação privilegiada I) e termos do domínio (informação privilegiada II). Os termos do domínio foram extraídos utilizando o método *MATE-ML (Automatic Term Extraction based on Machine Learning)* (CONRADO; PARDO; REZENDE, 2013; CONRADO, 2014). Esse método utiliza aprendizado de máquina para a extração de fortes candidatos a termos relevantes para a representação dos textos.

Por fim, em Sundermann *et al.* (2016), foi apresentado o método para extração de contexto que utiliza hierarquias de tópicos construídas com o uso da LIHC. Como informações privilegiadas foram considerados os termos do domínio e as entidades nomeadas de forma separada.

Nos experimentos dos trabalhos Domingues *et al.* (2014a), Domingues *et al.* (2014b), Sundermann *et al.* (2014), Sundermann *et al.* (2015), Sundermann *et al.* (2016) foi utilizado o protocolo *All But One* (BREESE; HECKERMAN; KADIE, 1998) com *10-fold cross validation* e as medidas Precisão e *Mean Average Precision* (MAP). Para analisar o efeito do número de tópicos como contexto nos sistemas de recomendação, foram selecionados subconjuntos de tópicos utilizando diferentes configurações de granularidade. As avaliações consistiram em comparar as abordagens *cReduction*, *DaVI-BEST*, *Weight PoF* e *Filter PoF* (descritas na Seção 2.1) com o método *Item-Based Collaborative Filtering* (DESHPANDE; KARYPIS, 2004),

que não utiliza contexto. O objetivo de tais comparações foi demonstrar o quanto os resultados são influenciados quando são adotadas as informações contextuais extraídas pelo método proposto em cada trabalho. Para as avaliações foram utilizadas duas bases de dados: (i) uma base de *logs* de um *site* brasileiro de agronegócio que consiste em 4659 usuários, 15037 acessos e 1543 páginas da *Web* escritas em português; e (ii) uma base de *logs* do *site* do Dicionário Informal⁷, que é um dicionário *online* de Português no qual as palavras são definidas pelos usuários. Esta base é formada por 2440830 usuários, 2456948 acessos e 20435 páginas (itens) e foi utilizada apenas em Sundermann *et al.* (2016).

Com o surgimento da *Web* 2.0 e o crescimento das redes sociais, cada vez mais usuários podem discutir abertamente suas impressões e experiências sobre os mais variados produtos, temas e serviços. Isso significa um aumento significativo em conteúdos gerados por usuários na forma de *reviews*, *blogs*, fóruns de discussões, redes sociais, entre outros. Uma informação muito importante encontrada nesses conteúdos é a opinião, que pode ser inferida por meio de um processo chamado mineração de opiniões, apresentado na próxima seção.

2.4 Mineração de Opiniões

De acordo com Liu (2015), a mineração de opiniões é o campo de estudo que analisa as opiniões das pessoas, sentimentos, avaliações, atitudes, e emoções relacionadas a entidades como produtos, serviços, organizações, indivíduos, assuntos, eventos, tópicos, e seus atributos. Ou seja, a mineração de opiniões tem como objetivo inferir a atitude do autor da opinião em relação a um determinado item, que pode ser, por exemplo, um tópico, um produto, um serviço, uma entidade ou mesmo uma propriedade de um desses itens. A opinião é expressa em certo tempo e contexto e, normalmente, em forma de texto. A opinião pode ser expressa tanto em relação ao item como um todo, quanto a quaisquer de seus componentes ou atributos, incluindo atributos dos componentes.

O termo “mineração de opiniões” apareceu pela primeira vez em Dave, Lawrence e Pennock (2003). Entretanto, a pesquisa em sentimentos e opiniões surgiu anteriormente (PANG; LEE; VAITHYANATHAN, 2002; WIEBE, 2000). A mineração de opiniões normalmente implica no uso de técnicas de análise de texto, processamento de língua natural e linguística computacional para identificar, extrair e compreender conteúdo subjetivo (que possui opinião). De acordo com Liu (2015), a mineração de opiniões é muitas vezes também conhecida como análise de sentimentos. Isso deve-se à dificuldade dos pesquisadores em diferenciar os termos “sentimento” e “opinião”. Para uma melhor compreensão, segue abaixo alguns conceitos e definições importantes para a mineração de opiniões, baseando-se em Liu (2015).

- **Opinião** — Liu (2015) cita a definição de opinião do dicionário *Merriam-Webster*⁸ na

⁷ <<http://www.dicionarioinformal.com.br/>>

⁸ <<http://www.merriam-webster.com>>

qual opinião é “uma visão, julgamento, ou avaliação formada na mente sobre um assunto específico”.

- **Sentimento** — seguindo a definição do mesmo dicionário (*Merriam-Webster*), sentimento é “uma atitude, pensamento ou julgamento causado por percepção”. Liu (2015) chama a atenção dos leitores de seu livro para a grande similaridade entre as definições de opinião e sentimento, mas conclui que uma opinião é melhor definida como uma visão concreta de uma pessoa sobre alguma coisa, enquanto que o sentimento é uma percepção. O sentimento é considerado como uma percepção positiva, negativa e algumas vezes neutra sobre um determinado assunto.
- **Documento** (d) — é um texto em língua natural que relata sobre um determinado assunto, tema, problema, produto, organização, entre outros.
- **Conjunto de documentos** (D) — conjunto de documentos d sobre um ou mais assuntos específicos.
- **Entidade** (e) — é um produto, tópico, serviço, pessoa, organização, acontecimento ou evento que está sendo referenciado nos documentos. Uma entidade é descrita por um conjunto de componentes e seus aspectos (LIU, 2015). As entidades podem ser mencionadas em alguns trabalhos como objetos.
- **Aspecto** (a) — é uma propriedade, componente ou característica de uma entidade. Exemplos de aspectos são: tamanho do produto, preço do produto, qualidade de atendimento de um serviço. Na literatura, os aspectos podem ser denominados como características ou atributos.

Existem diferentes níveis de mineração de opiniões, de acordo com Liu (2015): (i) **nível do documento**, no qual a tarefa é classificar se todo o documento de opinião expressa um sentimento, ou seja, identifica-se o sentimento geral do documento; (ii) **nível da sentença**, nível em que as sentenças são analisadas e é identificada a opinião expressa em cada uma; e (iii) **nível da entidade e do aspecto**, este nível é também conhecido como nível da característica. Ao invés de analisar as construções como documentos, parágrafos, sentenças e frases, são analisadas diretamente as próprias opiniões, ou seja, o sentimento associado a cada aspecto (alvo).

A mineração de opiniões feita no nível do documento ou no nível da sentença falha em encontrar o que o autor da opinião gosta ou não gosta. Um documento positivo sobre uma entidade não significa que o autor da opinião tenha opiniões positivas sobre todos os aspectos dessa entidade. Assim como, um documento negativo não significa que o autor da opinião não gosta de nada sobre a entidade. Por exemplo: “A qualidade da chamada do iPhone é boa, mas a bateria dura pouco”. Neste exemplo, retirado de Liu (2012), a entidade é o iPhone e são expressas opiniões sobre dois de seus aspectos, que são: chamada e duração da bateria. A chamada é avaliada com um sentimento positivo e a duração da bateria com um sentimento negativo. Análises desse tipo são obtidas por meio da mineração de opiniões no nível dos aspectos.

De acordo com Liu (2015), uma opinião é uma quintupla: $(e_i, a_{ij}, s_{ijkl}, h_k, t_l)$, em que e_i é o nome de uma entidade, a_{ij} é um aspecto de e_i , s_{ijkl} é o sentimento no aspecto a_{ij} de e_i , h_k é o autor da opinião, e t_l é o tempo no qual a opinião foi expressa. O sentimento s_{ijkl} pode ser positivo, negativo ou neutro, ou pode ser expresso com diferentes níveis de intensidade, por exemplo, de 1 a 5 estrelas como utilizado por vários *sites*. O objetivo da mineração de opiniões é, dado um documento de opiniões d , descobrir todas as quintuplas das opiniões. Na Figura 4, é dado um exemplo de documento de opinião. Trata-se de uma review escrita por um usuário sobre uma câmera fotográfica.

Figura 4 – Exemplo de mensagem de opinião

Posted by: bigJohn Date: 15/set/2011
 "(1) Eu comprei uma câmera Samsung e meu amigo pegou uma câmera Canon ontem. (2) Na semana passada, nós usamos muito as câmeras. (3) As fotos da minha Samy não são tão grandes, e a duração da bateria é curta demais. (4) O meu amigo estava muito feliz com a câmera dele e amou a qualidade de suas imagens. (5) Eu quero uma câmera que possa tirar boas fotos. (6) Eu vou devolvê-la amanhã."

Fonte: Adaptada de Liu (2012).

A mineração de opiniões baseada em aspectos consiste em um processo complexo que envolve técnicas de diversas áreas de pesquisa. Na Figura 5, esse processo é ilustrado, identificando as tarefas envolvidas. Essas tarefas são descritas a seguir e relacionadas ao exemplo da Figura 4, ou seja, são mostrados os resultados das tarefas considerando o exemplo dado.

Figura 5 – Etapas da mineração de opiniões baseada em aspectos

Fonte: Yugoshi (2018).

- **Extração e Categorização das Entidades** — identificar todas as expressões de entidades em d e categorizar as expressões de entidades sinônimas em categorias de entidade e_i .

No exemplo: são identificadas as expressões “Samsung”, “Samy” e “Canon”, sendo que as duas primeiras representam a mesma entidade “Câmera Samsung”.

- **Extração e Categorização dos Aspectos** — identificar todas as expressões de aspectos das entidades e categorizar essas expressões em categorias (a_{ij}).

No exemplo: são identificadas as expressões “imagem”, “foto” e “duração da bateria”, sendo que as duas primeiras representam o mesmo aspecto “imagem”.

- **Identificação do Titular da Opinião** — identificar quem emitiu a opinião e os dados do emissor.

No exemplo: na sentença (3), o autor da opinião pode ser bigJohn e na sentença (4) pode ser o amigo de bigJohn.

- **Extração e Padronização do Tempo** — identificar quando as opiniões foram publicadas e padronizar os formatos de tempo diferentes.

No exemplo: a mensagem foi postada em 15 de setembro de 2011. Um formato padrão poderia ser 2001-09-15.

- **Classificação dos Sentimentos dos Aspectos** — determinar a polaridade do sentimento sobre um aspecto a_{ij} , ou seja, classificar o sentimento em positivo, negativo ou neutro.

No exemplo: a sentença (3) emite uma opinião negativa da qualidade da imagem da câmera Samsung e da duração da bateria. A sentença (4) emite uma opinião positiva para a câmera Canon como um todo e também da sua qualidade de imagem. Para gerar as quintuplas de opinião contidas na sentença (4), é necessário conhecer a qual câmera referem-se as expressões: “a câmera dele” e “suas”.

- **Geração das Quintuplas de Opinião** — gerar todas as quintuplas de opinião $O = (e_i, a_{ij}, s_{ijkl}, h_k, t_l)$ expressas nos documentos da coleção.

No exemplo: $O_1 = (\text{Samsung}, \text{qualidade_imagem}, \text{negativo}, \text{bigJohn}, \text{2001-09-15})$

No exemplo: $O_2 = (\text{Canon}, \text{geral}, \text{positivo}, \text{Amigo de bigJohn}, \text{2001-09-15})$

- **Sumarização** — as opiniões são ordenadas, categorizadas e sumarizadas de forma que as entidades, seus aspectos e respectivos sentimentos, sobre o objeto alvo, sejam apresentados, possibilitando uma melhor interpretação dos dados.

De acordo com Liu (2015), existem quatro tipos de abordagens para a identificação de aspectos:

- **Baseada na frequência** — um aspecto pode ser expresso por um substantivo, adjetivo, verbo ou advérbio, porém estudos mostram que de 60 a 70% dos aspectos explícitos são substantivos (LIU, 2006). Os aspectos costumam ser substantivos frequentes, já que em comentários de opinião, em geral, as pessoas são mais propensas a falar sobre os aspectos relevantes. Porém, existem substantivos que não são aspectos e aspectos que não são substantivos. Dessa forma, diferentes técnicas de seleção são aplicadas a substantivos frequentes para identificar quais deles são aspectos. Em geral, os métodos baseados na frequência geram um conjunto de candidatos a aspectos e utilizam um critério de seleção que podem ser baseados em coocorrência, padrão sintático, medida *Point-wise Mutual Information* (PMI), entre outros (HU; LIU, 2004; POPESCU; ETZIONI, 2005; LONG; ZHANG; ZHUT, 2010).
- **Baseada nas relações sintáticas** — normalmente existem muitas relações sintáticas entre as expressões de sentimento e os alvos da opinião. Tais relações são possíveis de serem exploradas quando as palavras e frases de sentimento são conhecidas. Se a sentença não tem um aspecto frequente, mas tem algumas palavras de sentimento, o substantivo mais próximo a uma palavra de sentimento é extraído como um aspecto (HU; LIU, 2004; BLAIR-GOLDENSOHN *et al.*, 2008).
- **Por meio de aprendizado supervisionado** — em geral, os métodos para identificação de aspectos são baseados em rotulação sequencial (*sequential labeling*). Os métodos mais utilizados são: *Conditional Random Field* (CRF) (LAFFERTY; MCCALLUM; PEREIRA, 2001) e *Hidden Markov Model* (HMM) (RABINER, 1989).
- **Por meio de modelos de tópicos** — a modelagem de tópicos é um método de aprendizado não supervisionado que assume que cada documento é composto por um conjunto de tópicos e cada tópico tem uma distribuição de probabilidade sobre as palavras. Os principais modelos de tópicos utilizados para a extração de aspectos são: *Latent Dirichlet Allocation* (LDA) (BLEI; NG; JORDAN, 2003) e *Probabilistic Latent Semantic Indexing* (PLSI) (HOFMANN, 1999).

Para a tarefa de classificação de sentimentos dos aspectos, existem duas abordagens (LIU, 2015):

- **Baseada em aprendizado de máquina** — para classificação de sentimentos relacionados aos aspectos, os algoritmos de aprendizado de máquina tradicionais, como SVM e *Naive Bayes*, que são utilizados para a classificação de sentimentos em nível de sentença e documento, não são suficientes (LIU, 2012). O principal motivo é que esses algoritmos não consideram um alvo de opinião (entidade e/ou aspecto) e, portanto, são incapazes de determinar a que se refere o sentimento classificado. Para resolver esse problema, é necessário adequar os algoritmos para que sejam capazes de considerar um alvo da opinião no processo de aprendizado. Para isso, a principal abordagem atual é usar análise sintática para determinar a dependência e as demais informações pertinentes.

- **Baseada em léxico** — os classificadores baseados em léxico são geralmente não supervisionados. Em geral, uma abordagem baseada em léxico para classificação de sentimentos em relação aos aspectos (DING XIAOWEN; YU, 2008; LIU, 2010) usa os seguintes recursos:
 - um léxico de expressões de sentimento incluindo palavras de sentimento, frases, expressões idiomáticas e regras de composição;
 - um conjunto de regras para lidar com diferentes construções de linguagem (por exemplo, modificadores de sentimento e cláusulas-mas) e tipos de frases; e,
 - uma função de agregação de sentimento ou um conjunto de sentimento e de alvo das relações derivadas da árvore sintática para determinar a orientação do sentimento em cada destino em uma frase.

Devido ao fato de um dos objetivos deste trabalho de doutorado ser a proposta de um método automático de extração de informações de *reviews* utilizando mineração de opiniões baseada em aspectos, foi realizado um mapeamento sistemático em parceria com a pesquisadora Ivone Penque Matsuno. Tal mapeamento ocorreu em março de 2015 com o objetivo de se obter uma visão geral sobre os trabalhos realizados em Mineração de Opiniões Baseada em Aspectos e como são tratadas as diversas tarefas desse processo, dando suporte ao desenvolvimento de parte deste trabalho de doutorado.

Em um primeiro levantamento foram encontrados aproximadamente 600 artigos. Após a eliminação de artigos duplicados e que estavam fora do tema, restaram 116 artigos para leitura completa e extração das informações. Foram extraídos de todos os artigos de forma automática os seguintes dados: ano, base de consulta e classificação Qualis-CAPES. Já as informações de domínio de aplicação, tipos de texto, classes de sentimentos e técnicas utilizadas, foram extraídas com a leitura completa dos artigos. Foram observados os seguintes algoritmos, técnicas e ferramentas, para identificação de aspectos: WordNet (conceitos), ontologias específicas de domínio, frequência de substantivos, LDA (*Latent Dirichlet Allocation*), LSA (*Latent Semantic Analysis*) e regras de associação. Para a classificação dos sentimentos dos aspectos, os algoritmos, técnicas e ferramentas identificados foram: léxico para análise de sentimentos, WordNet (sentimentos), SentiWordNet, ontologias (sentimentos), Maximum Entropy, Naive Bayes e SVM (*Support Vector Machine*).

Dos trabalhos encontrados 78% são artigos de conferência e 22% são artigos publicados em periódicos. Na Tabela 1 é apresentada a distribuição por bases digitais de pesquisa. Na Tabela 2 é apresentada a distribuição dos artigos por classificação utilizando o indicador Qualis CAPES⁹. A distribuição em relação a esse indicador foi dividida em estratos: superior (A1, A2, B1, B2) e inferior (B3, B4, B5, C). Além disso, também foram identificados as conferências e periódicos não classificados.

Na Figura 6 é apresentada a distribuição dos artigos publicados por ano em relação ao tema. Como pode ser observado, o tema pesquisado vem crescendo ao longo dos últimos anos.

⁹ Classificação Qualis CAPES: <qualis.capes.gov.br>

Tabela 1 – Estudos identificados com a busca realizada em março de 2015

Fonte	Quantidade
ACM Digital Library	13 (11%)
IEEE Xplore	43 (37%)
Science Direct	9 (8%)
Scopus	45 (39%)
Web of Science	6 (5%)
Total	116 (100%)

Tabela 2 – Distribuição dos artigos por Indicador Qualis-CAPES

Indicador	Quantidade
Superior	65 (56%)
Inferior	22 (19%)
Não Classificado	29 (25%)
Total	116 (100%)

As publicações referentes ao ano de 2015 são apenas dos artigos publicados e indexados nos dois primeiros meses do mesmo ano.

Figura 6 – Publicação de trabalhos por ano em mineração de opiniões baseada em aspectos.

Na Tabela 3 é apresentada a distribuição dos artigos por domínio de aplicação, na Tabela 4 por classe de sentimento e na Tabela 5 por tipo de texto. Observa-se que grande parte dos trabalhos são sobre avaliações de produtos e consideram as classes de sentimentos positivo e negativo.

Tabela 3 – Distribuição de trabalhos por domínio de aplicação de mineração de opiniões baseada em aspectos.

Domínio de Aplicação	Quantidade
Produtos	47 (%)
Aplicativos	5 (%)
Turismo (Hotéis e Restaurantes)	10 (%)
Filmes	8 (%)
Diversos	23 (%)
Outros	7 (%)
Total	100 (%)

Tabela 4 – Distribuição de trabalhos por classe de sentimento.

Classe de Sentimento	Quantidade
Positivo e Negativo	57 (%)
Positivo, Negativo e Neutro	25 (%)
1 a 5	7 (%)
Não Informado	11 (%)
Total	100 (%)

Tabela 5 – Distribuição de trabalhos por tipo de texto.

Tipo de Texto	Quantidade
<i>Reviews</i>	87 (%)
<i>Tweets</i>	7 (%)
Outros	6 (%)
Total	100 (%)

Como observado na Tabela 5, as *reviews* são as mais exploradas na mineração de opiniões baseada em aspectos, já que são ricas em opiniões de usuários sobre os mais variados assuntos. Dessa forma, neste trabalho, o foco são as *reviews*. De acordo com [Chen, Chen e Wang \(2015\)](#), o interesse em incorporar informações extraídas de *reviews* em sistemas de recomendação vem aumentando nos últimos anos. A informação extraída das *reviews* podem beneficiar os sistemas de recomendação das seguintes formas: (i) tais informações podem resolver o problema da esparsidade dos dados, já que são informações adicionais sobre as preferências dos usuários; e (ii) elas podem resolver o problema “cold-start” para novos usuários.

Alguns trabalhos aplicam mineração de opiniões em *reviews* em busca de melhorar o desempenho dos sistemas de recomendação sensíveis ao contexto, entretanto a informação contextual nesses trabalhos é relacionada à avaliação geral do item e não aos seus múltiplos aspectos. Pesquisadores passaram a estudar as preferências dos usuários no nível dos aspectos para sistemas de recomendação de produtos ([CHEN; WANG, 2013](#)), de filmes ([WANG; LIU; YU, 2012](#)), de hotéis ([LIU; MEHANDJIEV; XU, 2011](#)) e de restaurantes ([GANU; KAKODKAR; MARIAN, 2013](#)), porém não consideram que as preferências podem ser influenciadas pelo contexto. Assim sendo, este mapeamento deu sustentação à área de mineração de opiniões e, portanto, o foco deste trabalho é utilizar tanto a mineração de opiniões baseada em aspectos, quanto informações contextuais extraídas das *reviews*, em sistemas de recomendação sensíveis ao contexto. Na próxima seção serão apresentados os trabalhos de sistemas de recomendação sensíveis ao contexto que utilizam mineração de opiniões.

2.5 Revisão Sistemática sobre Sistemas de Recomendação Sensíveis ao Contexto que Utilizam Mineração de Opiniões

Conduzir uma revisão sistemática significa conduzir revisões bibliográficas de uma maneira formal, seguindo um protocolo bem definido. Esse tipo de revisão da literatura tem como objetivo especificar questões e revisar estudos relevantes, o que permite que pesquisadores identifiquem lacunas na pesquisa atual, assim como, proponham contribuições para a área. Por

causa dos passos bem definidos do protocolo, os resultados podem ser reproduzidos.

Esta revisão sistemática, publicada em janeiro de 2019 (SUNDERMANN *et al.*, 2019a), foi conduzida baseando-se na metodologia introduzida por Kitchenham e Charters (2007), que envolve três fases principais: planejamento, condução e apresentação e discussão dos resultados. Na fase de planejamento, as necessidades da revisão sistemática e as bases bibliográficas relevantes são identificadas, as questões de pesquisa são especificadas e a expressão de busca, o critério de seleção e a estratégia de extração de informação são definidos. Na fase de condução, a expressão de busca é aplicada e os artigos retornados são selecionados de acordo com o critério definido na fase anterior. Finalmente, na última fase, os resultados são apresentados e discutidos. Cada fase é detalhada nas seções seguintes.

2.5.1 Planejando a Revisão

Durante a fase de planejamento, foram conduzidas as seguintes etapas:

- **Identificação da necessidade para uma revisão**—na primeira fase, foi identificado que não existem revisões sistemáticas na área de sistemas de recomendação sensíveis ao contexto que usam mineração de opiniões. Algumas revisões sistemáticas foram publicadas na área de sistemas de recomendação, com ou sem informação contextual, como Portugal, Alencar e Cowan (2015), Rahayu *et al.* (2017), Kumar e Sharma (2016), Sezgin e Özkan (2013), mas nenhuma delas considera mineração de opiniões e contexto em conjunto. Dessa forma, identificar e analisar os trabalhos que consideram informação contextual e mineração de opiniões em sistemas de recomendação pode auxiliar pesquisadores da área.
- **Especificação das questões de pesquisa**—as questões de pesquisa especificadas foram:
 - Quais informações contextuais foram adotadas para gerar as recomendações?
 - Como as informações contextuais foram extraídas?
 - Quais informações de opinião foram adotadas para gerar as recomendações?
 - Como as informações de opinião foram extraídas?
 - Quais fontes textuais foram utilizadas para a extração de ambas informações?
- **Identificação de bases bibliográficas relevantes**—para encontrar estudos relevantes para a revisão, foram escolhidas as bases bibliográficas que cobrem a maioria dos artigos de periódicos e conferências publicados na área de ciência da computação. As bases bibliográficas selecionadas foram: Scopus¹⁰, ACM Digital Library¹¹, IEEE Xplore Digital Library¹², and ScienceDirect¹³.
- **Definição da expressão de busca**—após definir as questões de busca, foi definida a expressão de busca. A expressão de busca utilizada passou por algumas mudanças quando

¹⁰ <<https://www.scopus.com>>

¹¹ <<http://dl.acm.org>>

¹² <<http://ieeexplore.ieee.org/Xplore/home.jsp>>

¹³ <<http://www.sciencedirect.com>>

estava muito ampla ou muito restritiva. A versão final da expressão é: (context*) AND ((recommender system* OR recommendation system*)) AND ((sentiment*) OR (opinion*)).

- **Definição dos critérios de seleção**—neste passo, os critérios para incluir ou excluir os artigos foram definidos. Os artigos duplicados foram eliminados e o restante foi analisado para a exclusão daqueles que correspondem a pelo menos um dos seguintes critérios de exclusão:

- Estudos secundários, isto é, revisões ou *surveys*.
- Publicações que não abordam sistemas de recomendação sensíveis ao contexto que usam mineração de opiniões. Além disso, os trabalhos sobre sistemas de recomendação que consideram somente informações contextuais ou somente mineração de opiniões, também não foram incluídos.
- Publicações com uma página, pôsteres, apresentações, resumos e editoriais.
- Publicações hospedadas em serviços com acesso restrito e não acessíveis ou publicações não escritas em inglês.

A leitura dos artigos foi executada na seguinte ordem: (i) título, resumo e palavras-chave; (ii) introdução e conclusão; e (iii) artigo completo.

- **Definição da estratégia de extração de informação**—com o objetivo de coletar as informações necessárias para responder às questões de pesquisa, a estratégia de extração de informação foi definida juntamente com a leitura dos textos completos de todos os artigos aceitos na fase de seleção. Foram definidas as seguintes informações para serem extraídas de cada artigo selecionado.

- **Dados bibliográficos:** título, autores, ano de publicação, periódico ou conferência.
- **Dados do estudo:** informações contextuais adotadas, métodos utilizados para extrair as informações contextuais, informações de opinião adotadas na recomendação, método utilizado para a extração das informações de opinião, fontes textuais das informações de contexto e de opiniões, domínio do sistema de recomendação e nível da mineração de opiniões.

2.5.2 Conduzindo a revisão

A condução desta revisão sistemática seguiu o protocolo definido, cujas partes principais foram apresentadas na última subseção. O primeiro passo da condução da revisão sistemática (fase de Identificação) foi a aplicação da expressão de busca em cada base bibliográfica. Essas buscas foram executadas em 10 de outubro de 2018 e resultaram nos dados da Tabela 6.

Na fase de triagem, após a remoção de 42 artigos duplicados, os 195 artigos restantes foram analisados por meio dos títulos, resumos, palavras-chave, introduções e conclusões. Nessa fase, 178 artigos foram excluídos de acordo com os critérios de exclusão apresentados na Section 2.5.1. Entre os artigos excluídos, somente um foi excluído pelo critério de estudo

Tabela 6 – Estudos identificados com a busca realizada em outubro de 2018

Fonte	Quantidade
ACM Digital Library	26 (11%)
IEEE Xplore	32 (13%)
Science Direct	19 (8%)
Scopus	160 (68%)
Total	237 (100%)

secundário. O trabalho de [Chen, Chen e Wang \(2015\)](#) é uma revisão da literatura sobre sistemas de recomendação baseados em *reviews* de usuários. Embora seja uma revisão importante na área, é focada em *reviews* de usuários, enquanto nosso estudo é focado em mineração de opiniões.

Após a fase de triagem, 17 artigos foram incluídos na fase de Extração. Nessa fase, os 17 artigos foram lidos e as informações sobre cada estudo foram extraídas. Os resultados dessa revisão sistemática são apresentados na próxima seção.

2.5.3 Resultados e Discussão

A revisão foi conduzida com os objetivos gerais: (i) identificar as pesquisas em sistemas de recomendação sensíveis ao contexto que também usam informação extraída pela mineração de opiniões; e (ii) mapear como essas pesquisas estão combinando essas duas tecnologias (sistemas de recomendação sensíveis ao contexto e mineração de opiniões). Os resultados da revisão sistemática são apresentados nesta seção. Primeiramente, na Seção 2.5.3.1, é apresentada uma visão geral das áreas de pesquisa e dos artigos selecionados, e também são respondidas as questões de pesquisa. As descrições detalhadas dos artigos selecionados são apresentadas na Seção 2.5.3.2.

2.5.3.1 Estudos Selecionados e Vínculo com as Questões de Pesquisa

A pesquisa sobre sistemas de recomendação que utilizam tanto contexto quanto informação de opinião envolve duas áreas principais: sistemas de recomendação sensíveis ao contexto e mineração de opiniões. Para ilustrar a evolução dessas duas áreas, a Figura 7 apresenta os resultados obtidos pela busca na área de Ciência da Computação da Scopus¹⁴.

Seguindo o protocolo definido, foram identificados e revisados 17 artigos que relatam pesquisas sobre sistemas de recomendação que utilizam tanto informação de contexto quanto de opinião. Esses artigos foram publicados entre 2012 e 2018. Na Tabela 7, estão sumarizados os 17 artigos selecionados. Em alguns campos da tabela, o valor “não mencionado” é observado,

¹⁴ As buscas foram executadas em 12 de dezembro de 2018 e a expressão de busca utilizada foi: TITLE-ABS-KEY((context* AND ("recommender system*"OR "recommendation system*"))) AND (LIMIT-TO(SUBJAREA,"COMP")) and TITLE-ABS-KEY(("opinion mining") OR ("sentiment analysis")) AND (LIMIT-TO(SUBJAREA,"COMP"))

Figura 7 – Evolução das áreas de pesquisa relacionadas com a revisão sistemática.

Fonte: Adaptada de [Sundermann et al. \(2019a\)](#).

o que significa que não foi possível extrair a informação de uma certa coluna para o trabalho correspondente. As colunas da tabela são:

- **Referência**—referências dos estudos sobre sistemas de recomendação sensíveis ao contexto que usam mineração de opiniões.
- **Domínio**—domínio no qual o sistema de recomendação é aplicado, por exemplo, “hotéis” e “turismo”.
- **Informação contextual**—coluna formada por três sub-colunas referentes à informação contextual usada em cada sistema.
 - **Tipo**—tipo de informação contextual, que pode ser “local”, “tempo”, “ocasião”, etc.
 - **Extração automática**—“sim”, se a informação contextual é extraída automaticamente, ou seja, não é necessário que a mesma seja informada pelo usuário; e “não” caso contrário.
 - **Valores pré-definidos**—“sim”, quando é necessário definir valores para as informações contextuais para buscar por esses valores (por exemplo, por correspondência de *strings*); e “não” caso contrário.
- **Mineração de Opiniões**—coluna formada por duas sub-colunas referentes à mineração de opiniões executada em cada trabalho.
 - **Nível do Aspecto**—“sim”, se a mineração de opiniões executada no trabalho foi no nível dos aspectos; e “não” caso contrário.
 - **Valores dos aspectos pré-definidos**—“sim”, se os valores dos aspectos precisam ser pré-definidos para serem buscados (por exemplo, por correspondência de *strings*); “não”, quando os valores não são pré-definidos; e “não se aplica” quando a mineração de opiniões não é executada no nível dos aspectos.

Tabela 7 – Resumo dos 17 trabalhos sobre sistemas de recomendação sensíveis ao contexto que usam mineração de opiniões.

Referência	Domínio	Informação Contextual		Mineração de Opiniões	
		Tipo	Exatidão Automática	Valores Pré-definidos	Nível dos Aspectos
Ho <i>et al.</i> (2012)	eventos espaço-temporais	localização e tempo	sim	não	não se aplica
Levi <i>et al.</i> (2012)	hotéis	tipo de viagem e nacionalidade	não	sim	sim
Meehan <i>et al.</i> (2013)	turismo	localização, tempo, sentimento e personalização	sim	não	não mencionado
Chen e Chen (2014)	restaurantes	tempo, ocasião e companhia	sim	sim	sim
Chen e Chen (2015)	restaurantes e hotéis	tempo, ocasião e companhia	sim	sim	sim
Colace <i>et al.</i> (2015a), Colace <i>et al.</i> (2015b)	geral	atributos dos itens da busca ou localização	não	não	não se aplica
Kothari e Patel (2015)	não mencionado	não mencionado	baseado em Chen e Chen (2014)	baseado em Chen e Chen (2014)	baseado em Chen e Chen (2014)
Orellana-Rodriguez, Diaz-Aviles e Nejdli (2015)	filmes curtos	contexto afetivo (emoção)	sim	sim	não
Yang <i>et al.</i> (2015)	lugares	localização	não tratado	não tratado	não se aplica
Zhao <i>et al.</i> (2016)	restaurantes, vida noturna e filmes	localização e tempo	não mencionado	não	não se aplica
Kharrat, Elkhleifi e Faiz (2016)	filmes	opiniões dos usuário sobre tags dos itens	sim	não	sim
Missaoui <i>et al.</i> (2017)	turismo	localização	sim	não	não se aplica
Jalan e Gawande (2017)	hotéis,	tipo de viagem localização e opinião	não mencionado sim	sim não mencionado não	sim
Baral <i>et al.</i> (2018)	lugares	categoria, localização e opinião	não mencionado não mencionado sim	não mencionado não mencionado não	sim
Sulthana e Ramasamy (2018)	livros	opinião	sim	não	sim
Zangerle <i>et al.</i> (2018)	música	estado emocional (emoção)	sim	não	não

Fonte: Adaptada de Sundermann *et al.* (2019a).

Baseando-se nos 17 artigos selecionados, foram respondidas as questões de pesquisa. As questões 1 (“*Quais informações contextuais foram adotadas para gerar as recomendações?*”) e 2 (“*Como as informações contextuais foram extraídas?*”) são relacionadas às informações contextuais. Na Tabela 8, essas questões foram respondidas de acordo com cada trabalho. Pode-se notar que a localização e o tempo são as informações de contexto mais frequentes. A localização é utilizada como informação contextual em 7 trabalhos e o tempo é utilizado em 4 deles. Outra análise interessante é que tanto opinião quanto emoção aparecem como informações contextuais em dois trabalhos cada uma. Considerando o método de extração, foram encontrados estudos obtendo informação contextual de: (i) sistemas externos, tais como GPS e *WorldWeatherOnline API*; (ii) perfis ou especificações de usuários; e (iii) correspondência de textos com valores pré-definidos ou recursos lexicais.

As questões 3 (“*Quais informações de opinião foram adotadas para gerar as recomendações?*”) e 4 (“*Como as informações de opinião foram extraídas?*”) são relacionadas às informações de opinião. Na Tabela 9, essas questões de pesquisa são respondidas de acordo com cada trabalho revisado. Quatorze (14) dos 17 estudos utilizam sentimento como informação de opinião. Entretanto, somente sete trabalhos aplicam a mineração de opiniões no nível dos aspectos (Tabela 7). Os métodos utilizados para a extração das informações de opinião são variados, incluindo métodos supervisionados e não supervisionados e o uso de recursos lexicais.

A quinta questão de pesquisa é “*Quais fontes textuais foram utilizadas para a extração das informações tanto de contexto quanto de opinião?*”. Essa questão de pesquisa foi respondida na Tabela 10 de acordo com cada artigo revisado. Embora existam muitas fontes disponíveis de conteúdos gerados por usuários, as *reviews* ainda assim são as principais fontes utilizadas por sistemas de recomendação sensíveis ao contexto.

Como mencionado anteriormente, esta revisão sistemática considera os estudos de uma intersecção de dois tópicos de pesquisa. “Contexto e Sistemas de Recomendação” e “Mineração de Opiniões e Análise de Sentimentos” são tópicos de pesquisa recentes, com um número crescente de publicações em Ciência da Computação (Figura 7). Analisando os resultados apresentados nesta seção, observa-se que o número de trabalhos que efetivamente utilizam mineração de opiniões em sistemas de recomendação sensíveis ao contexto é ainda baixo (17 estudos primários).

Na Figura 8, é apresentada uma visão geral dos 17 artigos selecionados por meio de um grafo de relacionamento, no qual cada nó é um artigo e as arestas indicam uma similaridade significativa entre os artigos. Essa análise é importante para identificar tópicos comuns entre os artigos. Para calcular a similaridade, cada artigo foi representado pelos seus termos extraídos do título, do resumo, das palavras-chave e dos tipos de informações contextuais. Foi utilizada a similaridade cosseno e como valor de importância dos termos a TF-IDF (*term frequency - inverse document frequency*), que são técnicas muito utilizadas para análise de dados textuais. Além disso, foi aplicada uma técnica de agrupamento em grafos para identificar grupos de artigos

Tabela 8 – Respostas para as questões de pesquisa relacionadas às informações contextuais (questões 1 e 2)

Referência	Informação Contextual	Como a informação contextual é extraída
Ho <i>et al.</i> (2012)	<ul style="list-style-type: none"> localização tempo 	<ul style="list-style-type: none"> localização: reconhecimento e resolução de topônimos usando marcação POS, reconhecimento de entidades nomeadas e reconhecimento de heurísticas baseado em regras tempo: reconhecimento de características e padrões temporais de passado próximo
Levi <i>et al.</i> (2012)	<ul style="list-style-type: none"> nacionalidade tipo de viagem 	<ul style="list-style-type: none"> definidos pelos usuários nas <i>reviews</i>
Meehan <i>et al.</i> (2013)	<ul style="list-style-type: none"> localização tempo clima sentimento personalização 	<ul style="list-style-type: none"> localização: GPS, GSM e Wi-Fi tempo: a quantidade de tempo que a pessoa fica no lugar é considerada para calcular o nível de interesse nesse lugar clima: <i>WorldWeatherOnline API</i> personalização: dados como idade, gênero, relacionamento e número de filhos são extraídos do perfil do usuário
Chen e Chen (2014) Chen e Chen (2015)	<ul style="list-style-type: none"> tempo ocasião companhia 	<ul style="list-style-type: none"> tipos e valores das informações contextuais são manualmente definidos e um método de correspondência de <i>strings</i> é aplicado
Colace <i>et al.</i> (2015a) Colace <i>et al.</i> (2015b)	<ul style="list-style-type: none"> atributos dos itens da busca ou posição do usuário 	<ul style="list-style-type: none"> informado pelo usuário
Kothari e Patel (2015)	<ul style="list-style-type: none"> não mencionado 	<ul style="list-style-type: none"> baseado em Chen e Chen (2014)
Orellana-Rodriguez, Diaz-Aviles e Nejdl (2015)	<ul style="list-style-type: none"> contexto afetivo (emoção) 	<ul style="list-style-type: none"> o método <i>Automatic Emotion eXtraction</i> utiliza as ferramentas <i>LingPipe</i>, <i>MorphAdorner POS</i> e <i>EmoLex</i>
Yang <i>et al.</i> (2015)	<ul style="list-style-type: none"> localização 	<ul style="list-style-type: none"> a informação contextual não é extraída
Zhao <i>et al.</i> (2016)	<ul style="list-style-type: none"> localização tempo 	<ul style="list-style-type: none"> não mencionado
Kharrat, Elkhleifi e Faiz (2016)	<ul style="list-style-type: none"> opiniões dos usuários sobre as <i>tags</i> dos itens 	<ul style="list-style-type: none"> extraí <i>tags</i> dos itens utilizando <i>tags</i> pré-definidas e as opiniões utilizando <i>WordNet</i>
Missaoui <i>et al.</i> (2017)	<ul style="list-style-type: none"> localização 	<ul style="list-style-type: none"> utilizando GPS
Jalan e Gawande (2017)	<ul style="list-style-type: none"> tipo da viagem localização 	<ul style="list-style-type: none"> não mencionado
Baral <i>et al.</i> (2018)	<ul style="list-style-type: none"> categoria localização 	<ul style="list-style-type: none"> não mencionado
Sulthana e Ramasamy (2018)	<ul style="list-style-type: none"> opinião 	<ul style="list-style-type: none"> substantivos são extraídos como termos de aspectos e as polaridades dos sentimentos são extraídas utilizando <i>SentiWordNet</i>
Zangerle <i>et al.</i> (2018)	<ul style="list-style-type: none"> estado emocional (emoção) 	<ul style="list-style-type: none"> <i>hashtags</i> contendo estado emocional do usuário são consideradas e combinadas com léxicos de sentimentos

Fonte: Adaptada de Sundermann *et al.* (2019a).

Tabela 9 – Respostas das questões de pesquisa relacionadas às informações de opinião (questões 3 e 4).

Referência	Informações de Opinião	Como as informações de opinião são extraídas
Ho <i>et al.</i> (2012)	sentimento do evento	utilizando duas abordagens de classificação: sLDA and SVM
Levi <i>et al.</i> (2012)	sentimentos dos aspectos dos itens	uma técnica não supervisionada de detecção de comunidade baseada em Reichardt e Bornholdt (2006) é utilizada para extrair os aspectos e uma abordagem baseada em léxico (HU; LIU, 2004) é utilizada para extrair os sentimentos dos aspectos
Meehan <i>et al.</i> (2013)	sentimentos relacionados aos pontos turísticos	utilizando AlchemyAPI
Chen e Chen (2014) Chen e Chen (2015)	sentimentos relacionados aos aspectos dos itens	utilizando o método proposto em Wang, Lu e Zhai (2010) para identificar os aspectos e um léxico de opinião para detectar os sentimentos dos aspectos
Colace <i>et al.</i> (2015a) Colace <i>et al.</i> (2015b)	sentimentos das reviews	utilizando uma melhoria da abordagem apresentada em Colace, Santo e Greco (2013), na qual LDA é aplicado
Kothari e Patel (2015)	baseado em Chen e Chen (2014)	baseado em Chen e Chen (2014)
Orellana-Rodriguez, Diaz-Aviles e Nejdl (2015)	contexto afetivo (emoção)	a técnica <i>Automatic Emotion eXtraction</i> utiliza as ferramentas <i>LingPipe</i> , <i>MorphAdorner POS</i> e <i>EmoLex</i>
Yang <i>et al.</i> (2015)	sentimentos das reviews	utilizando os ratings
Zhao <i>et al.</i> (2016)	sentimentos	usando o método de análise de sentimentos proposto em Zhang <i>et al.</i> (2013)
Kharrat, Elkhleifi e Faiz (2016)	palavras de opinião	utilizando WordNet
Missaoui <i>et al.</i> (2017)	sentimentos das reviews	utilizando os ratings
Jalan e Gawande (2017)	sentimentos relacionados aos aspectos dos itens	substantivos são extraídos como termos de aspectos e são agrupados como aspectos. Os sentimentos dos aspectos são extraídos utilizando um léxico e considerando os adjetivos ao redor do aspecto
Baral <i>et al.</i> (2018)	sentimentos relacionados aos aspectos dos itens	os termos de aspectos são extraídos utilizando uma abordagem de frequência de substantivos. Os termos são categorizados em aspectos utilizando WordNet. Os sentimentos são extraídos utilizando os trigramas ao redor dos termos dos aspectos
Sulthana e Ramasamy (2018)	sentimentos relacionados aos aspectos dos itens	os substantivos são extraídos como termos dos aspectos e as polaridades dos sentimentos são extraídas utilizando SentiWordNet
Zangerle <i>et al.</i> (2018)	estado emocional (emoção)	hashtags contendo emoções dos usuários são consideradas e combinadas com léxicos de sentimentos

Fonte: Adaptada de Sundermann *et al.* (2019a).

Tabela 10 – Respostas para a questão de pesquisa relacionada às fontes textuais das informações contextuais e de opinião (questão 5).

Fontes textuais das informações contextuais e de opinião	Referências
artigos de notícias	<ul style="list-style-type: none"> • Ho et al. (2012)
reviews	<ul style="list-style-type: none"> • Levi et al. (2012) • Chen e Chen (2014), Chen e Chen (2015) • Colace et al. (2015a), Colace et al. (2015b) • Kothari e Patel (2015) • Yang et al. (2015) • Zhao et al. (2016) • Kharrat, Elkhleifi e Faiz (2016) • Missaoui et al. (2017) • Jalan e Gawande (2017) • Baral et al. (2018) • Sulthana e Ramasamy (2018)
aplicações móveis	<ul style="list-style-type: none"> • Meehan et al. (2013)
tweets	<ul style="list-style-type: none"> • Meehan et al. (2013) • Zangerle et al. (2018)
comentários de usuários	<ul style="list-style-type: none"> • Orellana-Rodriguez, Diaz-Aviles e Nejdil (2015) • Kharrat, Elkhleifi e Faiz (2016)

Fonte: Adaptada de [Sundermann et al. \(2019a\)](#).

relacionados. Os termos mais relevantes de cada grupo foram utilizados para rotular tópicos comuns entre os artigos.

Figura 8 – Grafo de relação de similaridade entre os artigos seleccionados na revisão sistemática (organizados em grupos de tópicos). Cada artigo é um nó do grafo e os artigos similares são conectados por uma aresta. As cores definem os grupos de artigos.

Fonte: Adaptada de [Sundermann et al. \(2019a\)](#).

É importante enfatizar que, além da organização por tipo de informação contextual e o uso da mineração de opiniões descritos nas Tabelas 7–9, a análise do grafo complementa

a visualização dos trabalhos revisados mostrando as principais características em comum de um ponto de vista estatístico. O grupo com os artigos (1) [Ho et al. \(2012\)](#), (3) [Meehan et al. \(2013\)](#), (10) [Yang et al. \(2015\)](#), (11) [Zhao et al. \(2016\)](#), (15) [Baral et al. \(2018\)](#) tem, como principal característica, o uso da localização e do tempo como informações contextuais, enquanto o grupo com os artigos (9) [Orellana-Rodriguez, Diaz-Aviles e Nejdl \(2015\)](#) e (17) [Zangerle et al. \(2018\)](#) explora mais diretamente emoções e informações afetivas como contexto em sistemas de recomendação. O grupo com os artigos (4) [Chen e Chen \(2014\)](#), (5) [Chen e Chen \(2015\)](#), (6) [Colace et al. \(2015a\)](#), (7) [Colace et al. \(2015b\)](#), (8) [Kothari e Patel \(2015\)](#) foca na análise das preferências extraídas pela mineração de opiniões e no uso dessas informações como preferências dependentes de contexto. O grupo com os artigos (2) [Levi et al. \(2012\)](#), (12) [Kharrat, Elkhleifi e Faiz \(2016\)](#), (14) [Jalan e Gawande \(2017\)](#) tem um diferencial para lidar com o problema cold start em sistemas de recomendação sensíveis ao contexto utilizando mineração de opiniões para obter um modelo inicial quando não há informação suficiente para a filtragem colaborativa. Finalmente, o grupo com os artigos (13) [Missaoui et al. \(2017\)](#), (16) [Sulthana e Ramasamy \(2018\)](#) explora ontologias e modelos de linguagem para dar suporte à mineração de opiniões nos sistemas de recomendação sensíveis ao contexto. Mesmo que os artigos estejam alocados em grupos diferentes, existe uma relação entre eles. Por exemplo, os artigos [Jalan e Gawande \(2017\)](#) e [Zhao et al. \(2016\)](#) estão alocados em grupos diferentes mas estão conectados no grafo por compartilharem alguns tipos de informações contextuais (por exemplo, localização).

Embora esses trabalhos selecionados são relacionados ao mesmo tópico, cada grupo enfatiza aspectos diferentes do tema amplo. Eles são muito relevantes e apresentam avanços importantes no uso da mineração de opiniões para o aperfeiçoamento das recomendações. Entretanto, as vantagens que os sistemas de recomendação podem ter com o uso da mineração de opiniões ainda não estão esgotadas e foram encontradas algumas oportunidades de melhoria para futuras pesquisas.

Na próxima seção são apresentadas análises mais detalhadas de cada artigo selecionado nesta revisão sistemática.

2.5.3.2 Detalhes dos Estudos Selecionados

Nesta seção, são descritos e discutidos, em ordem cronológica, os 17 estudos selecionados. A discussão considera como as informações contextuais de opinião são extraídas e como essas informações são utilizadas e combinadas pelos sistemas de recomendação. Além disso, são apresentadas as abordagens de avaliação e as métricas utilizadas em cada estudo.

[Ho et al. \(2012\)](#) propuseram uma abordagem para minerar eventos espaço-temporais futuros de artigos de notícias e assim fornecer informações a um sistema de recomendação sensível à localização. De acordo com os pesquisadores, um evento é extraído somente quando sua localização e tempo puderem ser identificados ou deduzidos. Além de tais informações, são extraídos os sentimentos dos eventos, ou seja, identifica-se se um evento é positivo, negativo ou

neutro.

De acordo com [Ho et al. \(2012\)](#), um evento é composto por seis atributos: espacial (nome, longitude, latitude), temporal (dia, mês, ano, tempo[intervalo] - se disponível), frase chave (texto antes e depois de um padrão temporal), sentimento, fonte da informação (URL) e título do artigo de notícia. A abordagem proposta para minerar eventos é composta por quatro subtarefas: 1) **Reconhecimento de padrões temporais futuros e de passado próximo**, na qual são tratados os tempos absolutos e relativos usando como referência a *timestamp* da publicação do artigo; 2) **Reconhecimento e resolução de topônimos**, utilizando marcações *Part-Of-Speech* (POS), reconhecimento de entidades nomeadas (NER), reconhecimento de heurísticas baseadas em regras e frases de correspondência que podem ser encontradas em um *gazetteer*¹⁵; 3) **Desambiguação e correspondência espaço-temporal**, em que o processo de correspondência é definido por uma função $f : X \rightarrow Y$, em que X é o conjunto de padrões temporais futuros e Y é o conjunto de topônimos; e 4) **Análise dos sentimentos dos eventos**, nesta tarefa são aplicadas duas abordagens de classificação: *supervised Latent Dirichlet Allocation* (sLDA) e *Support Vector Machine* (SVM) para classificar o sentimento do evento.

Avaliação—a avaliação conduzida por [Ho et al. \(2012\)](#) consistiu na comparação dos valores de acurácia obtidos com cada um dos dois métodos utilizados para classificar sentimentos (sLDA e SVM). O objetivo dos experimentos foi avaliar o desempenho da classificação de sentimentos. Não foram executados experimentos aplicando o método em sistemas de recomendação, o que não permite a análise de resultados nesse contexto.

Considerações—foram observados no método de [Ho et al. \(2012\)](#) os seguintes pontos: (i) a análise de sentimentos executada é no nível do documento, ou seja, se houver mais de um evento na notícia e os mesmos apresentarem diferentes polaridades de sentimento, apenas o sentimento do documento como um todo será considerado - análises no nível de sentenças e aspectos poderiam ser mais eficientes; (ii) não são consideradas as preferências dos usuários apenas sua localização - as preferências dos usuários são muito relevantes em sistemas de recomendação, muitas vezes indispensáveis; e (iii) o contexto analisado inclui apenas localização e tempo - no caso de recomendações de eventos (locais) seria também interessante saber qual a companhia do usuário, o que também pode interferir nas suas escolhas e preferências.

[Levi et al. \(2012\)](#) propuseram um sistema de recomendação de hotéis que utiliza os textos das *reviews* como dados principais na recomendação de hotéis. A informação contextual é minerada dos textos e analisada para traços comuns em grupos contextuais. Os autores utilizaram três tipos de contexto: (i) propósito da viagem; (ii) nacionalidade; e (iii) preferências dos usuários para os diferentes aspectos dos hotéis.

Para encontrar traços comuns em cada contexto (propósito ou nacionalidade), o primeiro passo foi extrair termos candidatos a atributos. Tais termos são substantivos e sintágmata nominais

¹⁵ Um *gazetteer* é uma base de dados de localizações geográficas com coordenadas e metadados associados. O *gazetteer* utilizado foi o GeoNames (<<http://www.geonames.org>>).

presentes nas *reviews*. Para cada termo candidato, um peso foi atribuído por contexto, de acordo com sua frequência nas *reviews* daquele contexto. Os traços comuns de um grupo contextual são os atributos com valores de peso mais altos para tal contexto.

Com relação aos aspectos dos hotéis, *Levi et al. (2012)* utilizaram agrupamento não supervisionado, em específico uma técnica de detecção de comunidades. Nesse agrupamento os pesquisadores detectaram seis grupos (aspectos): localização, serviço, comida, quarto, geral e outros. Em cada grupo são determinados os atributos mais relevantes para o aspecto. Dessa forma são atribuídos pesos para cada atributo considerando a preferência do usuário e o grupo (aspecto) no qual ele está inserido.

Para definir a orientação da opinião relacionada aos atributos são extraídos todos os adjetivos que aparecem na mesma sentença de cada atributo. *Levi et al. (2012)* aplicaram uma abordagem que utiliza léxico de opinião baseada em *Hu e Liu (2004)*. Dessa forma, um *score* de orientação é atribuído a cada atributo em uma sentença específica. Quando há mais de uma palavra de opinião próxima do atributo, tais opiniões são agregadas.

Cada atributo recebe três pesos por usuário, um para o contexto propósito, um para o contexto nacionalidade e outro baseado na preferência do aspecto. O peso final do atributo para um usuário é a multiplicação de todos os pesos. Os atributos, seus pesos e orientações são combinados para definir um *score* para cada sentença. O *score* geral para cada *review* é calculado pela combinação dos *scores* das sentenças. O *score* final para cada hotel é uma média de todas as *reviews*.

Avaliação—*Levi et al. (2012)* executaram dois tipos de avaliações. Na primeira avaliação os autores utilizaram duas bases de dados - uma extraída do *site TripAdvisor*¹⁶ e outra extraída do *site Venere*¹⁷. *Levi et al. (2012)* projetaram um experimento *online* com trabalhadores no *Mechanical Turk*. Na segunda avaliação foi utilizada a metodologia descrita em *Hayes et al. (2002)*. Tal metodologia não mede a satisfação absoluta do usuário, mas a sua satisfação relativa de um sistema comparando com outro. *Levi et al. (2012)* disponibilizaram *online* o sistema proposto e pediram para amigos e colegas o avaliarem.

Considerações—um ponto observado no trabalho de *Levi et al. (2012)* refere-se à forma de obtenção da informação contextual. Tal informação precisa ser informada pelo usuário. Como já é de conhecimento, nem sempre o usuário está disposto a preencher formulários, responder perguntas ou informar seus dados. Dessa forma, seria mais interessante para esse sistema utilizar algum método automático para extração de informação contextual. Além disso, a forma com que o método foi avaliado se mostrou muito subjetiva. Seria interessante uma avaliação empírica, seguindo algum protocolo de avaliação para obter dados mais objetivos.

Meehan et al. (2013) investigaram a hipótese de que toda informação relevante dispo-

¹⁶ <<http://www.tripadvisor.com>>

¹⁷ <<http://www.venere.com>>

nível, o que inclui informação de contexto, deve ser considerada na recomendação. Os autores estudam a proposta de um método para sistemas de recomendação sensíveis ao contexto para o domínio do turismo. As informações contextuais consideradas no trabalho são: **Localização**, extraída por meio das tecnologias GPS, GSM, e Wi-Fi; **Clima**, extraído com auxílio da *WorldWeatherOnline API*¹⁸; **Tempo**, o tempo que o usuário fica em cada atração pode ser utilizado para determinar seu nível de interesse na atração; **Sentimento**, a análise de sentimentos é executada pela *API Alchemy* em *tweets* de tempo real para determinar o sentimento atual sobre o ponto turístico; e **Personalização**, são extraídos alguns dados das redes sociais como idade, gênero, status do relacionamento e número de filhos.

O modelo de sistema híbrido de Meehan *et al.* (2013) utiliza várias técnicas inteligentes para gerar as recomendações: (i) redes neurais, para determinar o peso de cada tipo de contexto para cada usuário; (ii) lógica fuzzy, para representar o interesse do usuário em cada item nas condições climáticas atuais; e (iii) análise do componente principal (PCA), para reduzir a dimensionalidade de qualquer distância percorrida que tenha uma pequena contribuição para a variância.

Avaliação—Meehan *et al.* (2013) planejam utilizar o método proposto na aplicação móvel VISIT (*Virtual Intelligent System for Informing Tourist*), sendo seu artigo uma apresentação do método. Dessa forma, não é detalhada a forma na qual o método é implantado no sistema de recomendação nem mesmo é apresentada alguma avaliação empírica.

Considerações—analisando as etapas do método, nota-se que a personalização pode não ser bem sucedida devido ao fato dos usuários nem sempre disponibilizarem seus dados nas redes sociais.

Chen e Chen (2014) consideram dois tipos de preferências: a) dependentes de contexto; e b) independentes de contexto. Chen e Chen (2014) propuseram um método para extrair tuplas de opiniões contextuais das *reviews*. Uma tupla é formalmente denotada como $\{\langle i, rev_{u,i}, a_k, Con_{i,k} \rangle | 1 \leq k \leq K\}$, em que i é o item, $rev_{u,i}$ é a *review* escrita pelo usuário u sobre o item i , a_k é a opinião do usuário u sobre o aspecto k e $Con_{i,k}$ é o vetor de contexto cujos elementos são iguais a 1 quando o contexto associado ocorre e 0 caso contrário. Depois de extrair as tuplas de opiniões contextuais, os dois tipos de preferências são detectados.

O método de Chen e Chen (2014) para extrair as tuplas de opiniões das *reviews* consiste em 4 etapas: 1) **Identificação dos aspectos**, na qual são identificados os termos relevantes para cada aspecto. Os autores adotaram o método proposto por Wang, Lu e Zhai (2010); 2) **Deteção da opinião**, nesta tarefa são extraídos das *reviews* os adjetivos utilizando um anotador POS. A polaridade do sentimento desses adjetivos é determinada consultando um léxico de opinião (WILSON, 2005). Utilizando um *score* baseado em distância, Chen e Chen (2014) resumem todas as opiniões expressas em uma sentença; 3) **Extração de contexto**, nesta etapa é empregado

18 <https://developer.worldweatheronline.com/api>

um método de correspondência de palavras chaves. [Chen e Chen \(2014\)](#) consideram que as variáveis de contexto são “Tempo”, “Ocasião” e “Companhia”; e 4) **Construção da relação aspecto-contexto**, [Chen e Chen \(2014\)](#) seguem as regras (i) a opinião no nível do aspecto e o contexto estão relacionados se ambos ocorrem na mesma sentença; e (ii) se na sentença não for mencionado contexto, a opinião é relacionada aos valores de contexto que ocorrem na sentença anterior mais próxima. A opinião a_k na tupla $\langle i, rev_{u,i}, a_k, Con_{i,k} \rangle$ é a agregação dos *scores* de opinião dos termos relacionados ao aspecto que estão no mesmo contexto $Con_{i,k}$.

Para detectar as preferências independentes de contexto, [Chen e Chen \(2014\)](#) utilizaram uma função de regressão linear dos mínimos quadrados. Com relação às preferências dependentes de contexto, [Chen e Chen \(2014\)](#) propuseram três variações de um mesmo método para atribuir pesos aos aspectos em diferentes contextos, utilizando: *Informação Mútua*, *Ganho de Informação* e *Estatística Qui-Quadrado*. As preferências independentes de contexto são combinadas com as preferências dependentes de contexto para calcular o *score* da *review*. E, por fim, o *score* de um item é calculado fazendo uma média dos *scores* de todas as suas *reviews*.

Avaliação—[Chen e Chen \(2014\)](#) utilizaram duas bases de dados reais de restaurantes, uma extraída do site *TripAdvisor* e outra extraída do site *Yelp*¹⁹. O procedimento de avaliação adotado foi o esquema de avaliação por usuário, utilizado por [Shani e Gunawardana \(2011\)](#) e [Codina, Ricci e Ceccaroni \(2013\)](#). As métricas utilizadas foram *Hit Ratio* e *Mean Reciprocal Rank* (MRR). O teste *t Student* foi aplicado para calcular a significância estatística da diferença entre os métodos comparados. Foram considerados os *baselines*: **Context Freer**, método proposto por [Adomavicius e Kwon \(2007\)](#) que não considera as preferências dependentes de contexto; **Context Pre-filter**, método que considera somente os *scores* obtidos das *reviews* escritas nos contextos do usuário alvo para calcular o *score* do item; **Default Connector**, método similar ao proposto por [Levi et al. \(2012\)](#); e **Discriminative Connector**, este método é também similar ao método proposto por [Levi et al. \(2012\)](#).

Considerações—os resultados dos experimentos mostraram que o método de [Chen e Chen \(2014\)](#) foi melhor que os *baselines* de forma significativa, sendo o método *Qui-Quadrado* o que apresentou os melhores resultados. Alguns pontos nesse método podem ser melhorados, como: (i) na identificação dos aspectos é necessário definir um conjunto de aspectos chaves, ou seja, é um método dependente do domínio e que necessita de informações prévias sendo interessante algum método automático de identificação de aspectos; e (ii) na extração de contexto são definidos os possíveis valores de contexto manualmente, ou seja, são informações pré-definidas também relacionadas ao domínio - um método automático de extração de contexto pode ser empregado neste caso.

[Chen e Chen \(2015\)](#) é uma extensão de [Chen e Chen \(2014\)](#), descrito anteriormente. [Chen e Chen \(2015\)](#) implementaram um método de aprendizado de gradiente descendente estocástico para integrar de forma automática as preferências contextuais dos usuários no

¹⁹ <<https://www.yelp.com/>>

processo de recomendação. Assim como em [Chen e Chen \(2014\)](#), os autores determinam as preferências dependentes de contexto utilizando *Informação Mútua*, *Ganho de Informação* e *Estatística Qui-Quadrado*. Para extrair as preferências independentes de contexto, [Chen e Chen \(2015\)](#) consideram diferentes propriedades entre novos usuários e usuários recorrentes. Para novos usuários, que são aqueles com poucos dados de histórico gravados no sistema, os autores aplicam modelo de regressão probabilística (*PRM*) que pode detectar as preferências de novos usuários tratando a detecção como um processo de aprendizado bayesiano. Para usuários recorrentes, que são aqueles com muitos dados de histórico, eles comparam a eficácia do *PRM* e do modelo de regressão linear (*LRM*), já que este último pode ser usado para detectar as preferências dos usuários em uma condição de dados ricos. Por fim, [Chen e Chen \(2015\)](#) propuseram um algoritmo baseado em regressão linear que utiliza um procedimento de aprendizado gradiente estocástico para combinar de forma automática os dois tipos de preferências no processo de recomendação.

[Chen e Chen \(2015\)](#) consideram dois modelos de inferência, o modelo de regressão linear e o modelo de regressão probabilística. O modelo de regressão linear assume que a avaliação geral do usuário sobre um item é a soma de todas as opiniões desse usuário sobre os diferentes aspectos do item. Dessa forma a avaliação geral pode ser gerada agregando as opiniões no nível do aspecto. Para utilizar o modelo de regressão probabilística a relação entre a avaliação geral e todas as opiniões dos aspectos deve ser um problema de regressão. O *PRM* modela essa relação por meio de um tratamento bayesiano, dessa forma o conhecimento a priori pode ser incorporado no modelo.

[Chen e Chen \(2015\)](#) utilizam um método baseado em regressão linear para combinar preferências dependentes de contexto e preferências independentes de contexto calculando um *score* para uma *review* escrita pelo usuário alvo. A diferença para o trabalho anterior [Chen e Chen \(2014\)](#) é que [Chen e Chen \(2015\)](#) também propuseram um método de aprendizado de descendente gradiente estocástico para aprender automaticamente o parâmetro de combinação. Esse parâmetro é utilizado para, no cálculo do *score* da *review*, controlar as contribuições relativas das preferências dependentes e independentes de contexto de um usuário para um aspecto em um determinado contexto.

Avaliação—as bases de dados utilizadas na avaliação foram as mesmas adotadas por [Chen e Chen \(2014\)](#). [Chen e Chen \(2015\)](#) consideraram três dos quatro *baselines* utilizados em [Chen e Chen \(2014\)](#): (i) *Context Freer*; (ii) *Context Pre-filter*; e (iii) *Simple Connector*. As métricas de avaliação utilizadas foram *Hit Ratio* e *Mean Reciprocal Rank*. A avaliação foi dividida em três partes: experimento com novos usuários, experimento com usuários recorrentes e experimento com todos os dados. Os resultados levaram os autores a três conclusões: (i) o modelo de regressão probabilística (*PRM*) é adequado para inferir as preferências independentes de contexto tanto dos novos usuários quanto dos usuários recorrentes; (ii) para detectar as preferências dependentes de contexto o método *Qui-Quadrado* é o mais adequado; e (iii) o

método de aprendizado de descendente gradiente estocástico, além de aprender os parâmetros de combinação, melhoram a acurácia da recomendação.

Considerações—por ser o método de [Chen e Chen \(2015\)](#) uma extensão do método de [Chen e Chen \(2014\)](#), a análise crítica é a mesma do trabalho anterior. Observa-se possibilidades de melhoras já discutidas anteriormente nas etapas de identificação dos aspectos e extração de contexto.

[Colace et al. \(2015a\)](#), [Colace et al. \(2015b\)](#) propuseram uma abordagem na qual os itens similares são agrupados utilizando técnicas de coagrupamento *high-order star-structured*. Os grupos de itens mais similares às preferências do usuário alvo são selecionados. Os dados de acessos para esses itens são modelados como um grafo direcionado rotulado e, utilizando esse grafo, [Colace et al. \(2015a\)](#), [Colace et al. \(2015b\)](#) calculam o grau de recomendação de um dado item.

A técnica de análise de sentimentos utilizada por [Colace et al. \(2015a\)](#), [Colace et al. \(2015b\)](#) é um aperfeiçoamento da abordagem apresentada por [Colace, Santo e Greco \(2013\)](#), na qual é adotado o LDA (*Latent Dirichlet Allocation*) para minerar sentimento em documentos. O conjunto de *reviews* é representado utilizando um grafo misto de termos (*mGT* positivo - formado por reviews positivas - e *mGT* negativo - formado por reviews negativas). Cada *review* é analisada e o sistema descarta aquelas cujo valor de “*confiança*” é menor que um determinado valor. As probabilidades positiva e negativa são calculadas e ponderadas. Por fim, [Colace et al. \(2015a\)](#), [Colace et al. \(2015b\)](#) definem uma função para refinar o *ranking* que combina o grau de recomendação de um item e os valores de probabilidades negativas e positivas.

[Colace et al. \(2015a\)](#), [Colace et al. \(2015b\)](#) representam o contexto considerando um modelo de valores chaves ([ADOMAVICIUS et al., 2005](#)) e utilizando como dimensões alguns dos espaços de atributos relacionados aos itens. A lista de recomendações é gerada pela classificação dos itens e todos os itens que não respeitam possíveis restrições contextuais são removidos da lista final.

Avaliação—a avaliação foi executada em duas variações do sistema proposto por [Colace et al. \(2015a\)](#), [Colace et al. \(2015b\)](#) - (i) **utilizando o sistema para recomendar pacotes de viagens**: a base de dados utilizada foi coletada do site *TripAdvisor*. [Colace et al. \(2015a\)](#), [Colace et al. \(2015b\)](#) solicitaram a um grupo de cerca de 50 pessoas para explorar uma coleção de itens de viagem e completar 20 tarefas utilizando *TripAdvisor*. Para avaliar os resultados foram utilizadas duas estratégias: 1) medidas empíricas de complexidade de acesso que consideram clicks do mouse e tempo; e 2) *TLX* (*NASA Task Load Index factor*). (ii) **utilizando o sistema para recomendar filmes**: foram coletados itens do site *IMDB*. [Colace et al. \(2015a\)](#), [Colace et al. \(2015b\)](#) adotaram uma estratégia de avaliação que tem como objetivo medir: a) a satisfação do usuário com relação às tarefas de busca por pacotes de viagens; e b) a eficácia do sistema em termos de acurácia para o problema de recomendação de filmes. As métricas utilizadas foram *Mean Absolute Error* (MAE) e o *Root Mean Square Error* (RMSE). Os *baselines* dos

experimentos foram as abordagens *UPCC* e *IPCC* (SU; KHOSHGOFTAAR, 2009).

Considerações—algumas dificuldades podem ser identificadas na utilização do método proposto por Colace *et al.* (2015a), Colace *et al.* (2015b): (i) é preciso ter as informações de acessos ou compras dos usuários, já que é necessária a informação de qual item foi acessado/comprado antes ou depois de outro item; e (ii) é necessária a informação de “confiança” do usuário.

Kothari e Patel (2015) consideram que contexto é qualquer restrição ou condição passada pelo usuário. De acordo com eles, existem dois tipos de sistemas de recomendação: independentes e dependentes de contexto.

Kothari e Patel (2015) propuseram um sistema de recomendação que consiste na detecção automática das relações contexto-aspecto das *reviews* e que combina as preferências dos usuários independentes e dependentes de contexto. A técnica *Support Vector Machine* (SVM) é incorporada no sistema para classificar as preferências dos usuários em seus respectivos contextos. Os passos da metodologia proposta por Kothari e Patel (2015) são semelhantes aos passos de Chen e Chen (2014), Chen e Chen (2015). Após a seleção dos atributos dependentes de contexto utilizando os métodos *Ganho de Informação* e *Estatística Qui-Quadrado*, os mesmos são aplicados como vetores de entrada no modelo SVM. Os dados classificados são utilizados para o processo de recomendação que consiste em uma técnica de filtragem colaborativa.

Avaliação—foram utilizadas nos experimentos de Kothari e Patel (2015) bases de dados reais extraídas do site *TripAdvisor*. As métricas aplicadas foram: *Hit ratio* and *Mean Reciprocal Rank* (MRR). Foram comparados o uso individual das técnicas *Ganho de Informação*, *Estatística Qui-Quadrado* e *Informação Mútua*, com o uso conjunto dessas técnicas utilizando SVM.

Considerações—no artigo de Kothari e Patel (2015), as etapas do método proposto não estão muito bem detalhadas. Aparentemente os autores utilizam o método proposto por Chen e Chen (2014) com a inclusão do SVM, mas isso não está claro no texto.

Orellana-Rodriguez, Diaz-Aviles e Nejdl (2015) propuseram uma abordagem que extrai automaticamente contexto afetivo dos comentários dos usuários associados a filmes curtos. Os autores exploraram duas abordagens para a associação de emoções a filmes desta categoria: 1) anotações feitas por um grupo de pessoas da *Amazon Mechanical Turk*²⁰; e 2) extração automática de contexto afetivo dos comentários disponíveis no *Youtube*²¹, avaliando sua importância em uma tarefa de recomendação sensível a emoções.

Orellana-Rodriguez, Diaz-Aviles e Nejdl (2015) utilizaram uma coleção de filmes curtos que participaram de dois festivais nos quais o *Youtube* foi utilizado como plataforma de divulgação: *Tropfest* and *Your Film Festival*. A ferramenta *Youtube's Data API* foi utilizada para coletar um conjunto de filmes curtos participantes. Para cada filme foram coletados o

²⁰ <<https://www.mturk.com>>

²¹ <<https://www.youtube.com>>

número de visualizações, *likes*, *dislikes* e os comentários dos usuários sobre o filme. Os usuários que participaram das anotações responderam algumas questões de polaridade que indicam as emoções de cada filme. As emoções consideradas por Orellana-Rodriguez, Diaz-Aviles e Nejdl (2015) foram: alegria-tristeza, raiva-medo, confiança-aversão e antecipação-surpresa. Os autores associaram a cada resposta um valor numérico. Os usuários também indicaram se eles gostaram ou não dos filmes e rotularam cada filme nos contextos: Audiência, Companhia ou Tempo.

Orellana-Rodriguez, Diaz-Aviles e Nejdl (2015) exploraram como as emoções estão distribuídas para ambos, filmes mais curtidos e filmes que os usuários não gostaram e para cada contexto. Além dessa exploração, os autores propuseram a abordagem *Automatic Emotion eXtraction* (AEX) que explora os comentários do *Youtube*, associados a filmes curtos, para detectar as emoções que eles evocam. Os passos da abordagem são: (i) construção de um perfil para cada filme, o qual é formado por todos os comentários dos usuários sobre o filme; (ii) execução da anotação *Part-of-speech* em cada perfil, utilizando *LingPipe*²² e *MorphAdorner*²³, para extrair substantivos e adjetivos; (iii) associação dos termos com valores de emoções e polaridades, utilizando o léxico *NRC Emotion Lexicon* (EmoLex), e uma técnica de correspondência de termos; e (iv) construção do vetor de emoção e polaridade.

Orellana-Rodriguez, Diaz-Aviles e Nejdl (2015) incorporaram o contexto emocional no sistema de recomendação seguindo uma abordagem de *ranking* colaborativo. Foi utilizado o método *LambdaMART* como método de *learning-to-rank*.

Avaliação—os dados foram divididos em treino, validação e teste. Primeiro 20% dos usuários foram selecionados para o grupo de teste. Então, 10% dos usuários formaram o conjunto de validação. E, por fim, o restante dos dados dos usuários são utilizados para treino. As métricas utilizadas foram Precisão e *Mean Reciprocal Rank*. Orellana-Rodriguez, Diaz-Aviles e Nejdl (2015) compararam os resultados da recomendação utilizando o contexto afetivo extraído pelo método proposto AEX com os resultados da recomendação utilizando o contexto afetivo anotado pelos usuários. Os resultados mostraram que o sistema baseado no método AEX é muito competitivo.

Considerações—o método proposto por Orellana-Rodriguez, Diaz-Aviles e Nejdl (2015) considera a emoção detectada como um contexto, não levando em consideração outros tipos de informações contextuais. Além disso, as emoções extraídas são pré-determinadas e específicas para o domínio de filmes.

Yang *et al.* (2015) focaram em sugestões contextuais baseadas em localização e propuseram utilizar opiniões de usuários para construir os perfis. Eles também desenvolveram um novo método de geração de resumo que utiliza perfis de usuários baseados em opinião para gerar os resumos das sugestões. De acordo com Yang *et al.* (2015), o processo de gerar recomendações contextuais baseadas em localização é executado em dois passos: (i) identificar

²² <<http://alias-i.com/lingpipe>>

²³ <<http://morphadorner.northwestern.edu>>

lugares de interesse que sejam próximos do local atual do usuário alvo; (ii) classificar os lugares candidatos considerando o interesse do usuário. Os autores focaram no segundo passo.

Yang *et al.* (2015) modelam o perfil do usuário utilizando opiniões (*rating*, texto da *review*) sobre os exemplos de sugestões. Eles utilizam *reviews* positivas dos exemplos que o usuário gostou para construir seu perfil positivo, e utilizam as *reviews* negativas dos exemplos que o usuário não gostou para construir seu perfil negativo. Quando ocorre a falta de opiniões de um determinado usuário, são utilizadas as opiniões dos usuários similares a ele, isto é, os usuários que avaliaram uma sugestão de forma similar.

Para gerar as representações das sugestões, sendo estas representações baseadas em opiniões, Yang *et al.* (2015) constroem dois perfis: (i) perfil positivo baseado em todas as *reviews* positivas da sugestão; e (ii) perfil negativo baseado em todas as *reviews* negativas da sugestão.

Yang *et al.* (2015) investigaram duas possíveis formas de combinar as similaridades entre os perfis do usuário e as representações dos itens candidatos: 1) **Interpolação linear**, este método combina múltiplos *scores* em um único *score*; e 2) **Learning-to-rank**, este método considera as similaridades como atributos e utiliza métodos *learning-to-rank* para calcular o *score* do ranking.

Avaliação—Yang *et al.* (2015) avaliaram o método proposto utilizando duas bases de dados: (i) a base de dados utilizada em *TREC Contextual Suggestion track* (CS2012, CS2013 e CS2014); e (ii) uma base de dados extraída do *site Yelp*. Para cada usuário, as sugestões foram divididas em dois conjuntos de mesmo tamanho, treino e teste. As *reviews* foram mapeadas para positivas ou negativas de acordo com a avaliação relacionada a ela. Como métricas foram utilizadas Precisão e *Expected Reciprocal Rank* (ERR). O método proposto foi comparado com dois *baselines* que são dois métodos que utilizam diferentes tipos de informação para construir o perfil do usuário (YANG; FANG, 2012). A avaliação utilizando interpolação linear, foi executada com *5-fold cross validation*. Para avaliar os métodos *learning-to-rank*, os modelos foram treinados em 60% dos dados, validados em 20% e testados nos 20% restantes. Os resultados mostraram que o método de Yang *et al.* (2015) supera de forma significativa os *baselines* considerando Precisão e ERR.

Considerações—Yang *et al.* (2015) consideraram como única informação contextual a localização. Além disso, a polaridade do sentimento de cada *review* é definida apenas pelo *rating* dado pelo usuário, não sendo executada análise de sentimento no texto da *review*.

Zhao *et al.* (2016) propuseram um modelo para conduzir avaliação de qualidade de serviço usando o conceito de confiança dos *ratings* dos usuários. Para calcular a confiança dos *ratings* de um usuário, Zhao *et al.* (2016) consideram que, quando os *ratings* são confiáveis, deve haver uma pequena diferença entre eles e o *rating* geral dos itens. Além disso, a entropia do valor dessas diferenças pode ser usada para representar o valor de confiança. Quanto menor é o valor da entropia, mais estável o sistema é, e mais confiante é o *rating* do usuário.

[Zhao et al. \(2016\)](#) calcularam a confiança dos *ratings* considerando os atributos espaço-temporais e atributos de sentimento extraídos das *reviews*. Os autores analisaram a distribuição da confiança dos *ratings* para diferentes distâncias geográficas entre usuários e itens. Eles descobriram que a confiança dos *ratings* é baixa se o usuário está muito perto do item avaliado. Os autores também analisaram a distribuição da confiança em diferentes períodos de tempo, e descobriram que ela diminui com o tempo.

Com relação aos atributos de sentimento, [Zhao et al. \(2016\)](#) utilizaram o método de análise de sentimentos proposto em [Zhang et al. \(2013\)](#). Os autores analisaram a distribuição da diferença média e o número correspondente de *ratings* em diferentes *scores* de sentimento. Eles descobriram que a confiança do usuário aumenta com o *score* de sentimento da *review*.

O modelo de avaliação de qualidade de serviço proposto por [Zhao et al. \(2016\)](#) é um modelo probabilístico que combina confiança do usuário com atributos de contexto, incluindo atributos espaço-temporais e atributos de sentimentos das *reviews*, para calcular o valor de confiança geral de um *rating*.

Avaliação—[Zhao et al. \(2016\)](#) utilizaram duas bases de dados para avaliar a abordagem proposta, bases de *reviews* *Yelp* e *Douban*, sendo a base da *Yelp* dividida em *Restaurantes Yelp* e *Vida noturna Yelp*. Os autores pré-selecionaram alguns itens para serem utilizados no treinamento e outros para teste. Todo item de teste tem no máximo 5 *ratings*. As métricas de avaliação utilizadas foram *Root Mean Square Error*, *Mean Absolute Error*, Precisão, Revocação e AUC (*Area under Curve*). [Zhao et al. \(2016\)](#) utilizaram 9 *baselines* para avaliar a proposta *Service Quality Evaluation* (SQE). Os autores concluíram que a abordagem proposta pode usar poucos *ratings* para prever o *rating* geral dos serviços. Além disso, ela pode ser aplicável para diferentes domínios e bases de dados.

Considerações—analisando o trabalho de [Zhao et al. \(2016\)](#), observa-se que não é mencionado como a informação contextual é obtida. Intuitivamente, observando os tipos de contexto, imagina-se que tal informação foi obtida por meio de logs de acesso ou foi informada pelos próprios usuários nas *reviews*. Dessa forma, não foi utilizada uma abordagem automática de extração de informação contextual. Além disso, a análise de sentimentos executada pelos autores não é no nível dos aspectos.

[Kharrat, Elkhleifi e Faiz \(2016\)](#) propuseram utilizar fontes externas, como comentários do Facebook, para suavizar o problema *cold start* e melhorar a recomendação. A abordagem proposta consiste de 3 partes: (i) **na primeira parte**, os comentários postados pelos usuários são armazenados em uma base de comentários. O conjunto de dados utilizado foi da MovieLens. Usando uma abordagem de correspondência, os autores incluíram todos os usuários do MovieLens na coleção de perfis. Essa correspondência é baseada em informações demográficas sobre os usuários, como idade, sexo, ocupação e país; (ii) **na segunda parte**, a *WordNet* é utilizada para construir um recurso léxico para a mineração de opiniões e um algoritmo de extração de *tags* é usado para anotar todas as *tags* em comentários, *tags* de itens e *tags* de opinião; e (iii) **a**

terceira parte é o algoritmo de recomendação.

O sistema de recomendação aceita como entrada um comentário relacionado a um item específico e fornece *scores* de opinião para as *tags* desse item. Nesta parte, uma pontuação relevante é atribuída a cada *tag* de opinião. Além disso, é feita a integração da dimensão de opinião (contextual) nos algoritmos de recomendação - os novos algoritmos são versões aprimoradas do algoritmo Slope One e do algoritmo SVD de Simon Funk, chamado SemSlope One e SemSVD, respectivamente.

Avaliação—[Kharrat, Elkhleifi e Faiz \(2016\)](#) utilizaram a base da MovieLens com 1000 *ratings* de 943 usuários sobre 1682 itens. Cada usuário avaliou pelo menos 20 filmes. O objetivo da avaliação foi de comparar o SemSlope com o Slope One e o SemSVD com o SVD. As métricas utilizadas foram *Root Mean Square Error*, *normalized Discounted Cumulative Gain*, Precisão e Revocação. A base de dados foi particionada em uma configuração de validação cruzada com *5-folds*. Para cada usuário em cada partição, 20% de seus *ratings* são selecionados como teste e 80% como conjunto de treinamento.

Considerações—embora não esteja claro, a abordagem de mineração de opiniões empregada pelos autores se assemelha à mineração de opiniões baseada em aspectos. Com a diferença de que os aspectos são as *tags* que descrevem os itens. A extração das *tags* depende de uma lista pré-definida de *tags* de itens e a análise de sentimentos para cada *tag* é feita usando um dicionário de palavras de opinião construído com base na *WordNet*. Automatizar a extração das *tags*, que descartaria a necessidade de definir manualmente um conjunto de *tags*, melhoraria o método de [Kharrat, Elkhleifi e Faiz \(2016\)](#). Além disso, a opinião do usuário é considerada como seu contexto, não levando em conta outros tipos de informações contextuais.

[Missaoui et al. \(2017\)](#) tiveram como objetivo prever as preferências dos usuários no domínio do turismo, para fornecer recomendações personalizadas e sensíveis ao contexto. Eles propuseram uma abordagem de Filtragem Baseada em Conteúdo que identifica os serviços relacionados ao turismo mais próximos do usuário e recomenda os mais relevantes, considerando as opiniões que o usuário expressou através de suas *reviews* anteriores.

A abordagem proposta de Filtragem Baseada em Conteúdo consiste em quatro tarefas: (i) **definição dos perfis de usuários**—os autores seguem a idéia de perfis positivos e negativos proposta por [Yang et al. \(2015\)](#); (ii) **definição dos perfis de serviços relacionados ao turismo (R-T)**—além dos perfis de usuário, é construído, para cada serviço R-T, um perfil de serviço representado por um modelo de linguagem positivo e um modelo de linguagem negativo. A abordagem considera as *reviews* escritas pela elite *Yelp*; (iii) **comparação entre os perfis dos serviços e o perfil do usuário alvo**—primeiro, os serviços relacionados ao Turismo mais próximos (considerando a localização geográfica do usuário) são selecionados como o conjunto de possíveis serviços candidatos a serem recomendados. Em seguida, para calcular a pontuação de recomendação para cada serviço, o perfil do usuário é comparado com os perfis de serviço R-T. O problema da recomendação consiste na tarefa de calcular a similaridade entre os componentes

positivos e negativos do perfil do usuário e os mesmos dois componentes do perfil do serviço R-T; e (iv) **recomendação dos serviços relacionados ao turismo** — após o cálculo dos *scores* de recomendação dos serviços mais próximos do usuário alvo, recomenda-se os serviços top-k R-T mais próximos, em ordem decrescente de similaridade.

Avaliação—Missaoui *et al.* (2017) avaliaram a abordagem de recomendação usando as métricas Precisão e *normalized Discounted Cumulative Gain*. Os autores realizaram os experimentos na base de restaurantes da *Yelp*. Eles selecionaram os serviços R-T pertencentes à categoria de restaurante e que receberam avaliações confiáveis. Missaoui *et al.* (2017) seguiram a metodologia *TestItems* descrita by Bellogin, Castells e Cantador (2011), comparando a abordagem proposta em relação a dois *baselines* - UCF rotulada e cat-F rotulado.

Considerações—analisando o trabalho de Missaoui *et al.* (2017), observou-se que apenas um tipo de informação contextual é usada, a localização do usuário, que é obtida automaticamente, mas outros tipos de contextos poderiam ser considerados. Além disso, a análise de opinião é feita no nível do documento e sem qualquer técnica de mineração de opiniões robusta, considerando apenas o valor do *rating* dado pelo usuário. Realizar uma análise no texto da *review* pode fornecer indicações mais precisas e detalhadas sobre a opinião do usuário.

Jalan e Gawande (2017) propuseram um sistema de recomendação sensível ao contexto de hotéis que extrai informações contextuais e sentimentos das *reviews*. Os autores consideraram três tipos de contexto: (i) tipo de viagem; (ii) localização do usuário; e (iii) opinião do usuário sobre diferentes aspectos do hotel.

A ideia principal do sistema de Jalan e Gawande (2017) é que as *reviews* de usuários pertencentes ao mesmo contexto possuem maior importância. O processo de recomendação começa com a coleta e o pré-processamento do conjunto de dados. No pré-processamento, as seguintes tarefas são executadas: (i) tokenização; (ii) remoção das *stopwords*; e (iii) substituição de palavras; (iv) radicalização; (v) marcação *part-of-speech* (POS) usando OpenNLP²⁴; (vi) extração de aspectos, em que substantivos são identificados como aspectos; e (vii) agrupamento de aspectos, um algoritmo de agrupamento semi-supervisionado é usado para encontrar o vocabulário de cada aspecto. Após o pré-processamento, é realizada a identificação de polaridade, onde as polaridades de sentimento são atribuídas aos aspectos. Nesta etapa, os autores utilizaram uma abordagem baseada em léxico, considerando os adjetivos apresentados em torno do aspecto. Depois que a polaridade dos aspectos é identificada, um peso é atribuído a cada aspecto em cada contexto. Esse peso é calculado de acordo com o número de ocorrências dos termos de aspecto nas revisões pertencentes a um determinado contexto. Finalmente, a pontuação final do hotel é calculada. Para este cálculo, uma pontuação é definida para cada sentença, depois para cada revisão e, em seguida, para cada hotel. Hotéis com valores de pontuação mais altos são recomendados para o usuário.

²⁴ <<https://opennlp.apache.org/>>

Avaliação—os experimentos foram conduzidos utilizando uma base de *reviews* de 5 hotéis do site *TripAdvisor*. [Jalan e Gawande \(2017\)](#) não descreveram a avaliação em detalhes; eles somente demonstraram por meio de gráficos o número de aspectos e seus sentimentos extraídos das *reviews*.

Considerações—embora o trabalho de [Jalan e Gawande \(2017\)](#) considere a mineração de opiniões baseada em aspectos, alguns pontos devem ser discutidos. Em primeiro lugar, trata-se de um trabalho próximo ao trabalho de [Levi et al. \(2012\)](#), descrito anteriormente, com algumas semelhanças em relação aos contextos considerados, além da forma de extrair opinião e calcular os *scores*. Assim, o contexto “tipo de viagem” não é extraído automaticamente, mas é informado pelo usuário. A maneira como o contexto de “localização” é extraído ou usado não é discutida no artigo. Por fim, a avaliação apresentada pelos autores não abordou o desempenho do sistema de recomendação.

[Baral et al. \(2018\)](#) propuseram um modelo chamado ReEL (*Review aware Explanation of Location Recommendation*) para a recomendação de Pontos de Interesse (POIs). O foco do artigo está nas explicações da recomendação. [Baral et al. \(2018\)](#) utilizam *Convolutional Neural Networks* (CNN) para formular o problema de correlação de *reviews* e aspectos. Eles mapeiam os sentimentos dos usuários em tuplas (POI, aspecto) e modelam as preferências de aspecto dos usuários, como a relação bipartida aspecto-POI. O relacionamento bipartido é representado usando um grafo bipartido.

Primeiramente, as *reviews* são classificadas. O segundo passo é a extração de aspectos, em que substantivos e frases nominais são filtrados usando uma abordagem baseada em frequência e, em seguida, uma abordagem baseada em regras é usada para capturar outros aspectos. Depois de extrair os termos dos aspectos, os termos são categorizados em aspectos. O texto da *review* é rotulado de acordo com o aspecto mais próximo aos termos dos aspectos da *review*. Esses dados rotulados são usados no treinamento do classificador de sentença-aspecto baseado na CNN. O módulo de classificação classifica uma sentença de *review* em um aspecto relevante.

A entrada da CNN é uma *word embedding* das sentenças das *reviews* construída com a ajuda da *Word2Vec*. A saída do classificador é uma relação bipartida entre *reviews* e aspectos. Para cada usuário, o classificador gera um conjunto de vetores de recursos do usuário (incorporados em seus aspectos preferidos). O mesmo é feito para os POIs. Os sentimentos de cada sentença da *review* são extraídos usando o trigramma em torno dos termos dos aspectos. A *embedding* do termo de sentimento é concatenada ao vetor de atributos da POI.

O recomendador proposto é denominado *Deep Aspect-based POI recommender* (DAP). [Baral et al. \(2018\)](#) adiciona outros tipos de contextos ao vetor do recurso POI, como categórico, espacial e outros. O problema de recomendação é então formulado como uma matriz cujas linhas representam usuário, POI e elementos de diferentes contextos. Desta forma, as recomendações são geradas por uma máquina de fatoração. Os autores propuseram três métodos diferentes para gerar as explicações das recomendações usando um grafo bipartido que representa a relação

aspecto-POI.

Avaliação—[Baral et al. \(2018\)](#) utilizaram três conjuntos de dados *Yelp*, *TripAdvisor* e *AirBnB*²⁵. Foram avaliados quatro modelos: um modelo que não apresenta explicações para as recomendações e três modelos representando cada abordagem proposta por eles para gerar explicações. Além disso, os módulos de extração de aspecto, categorização de aspecto e classificação de aspecto-sentença também foram avaliados. Os autores consideraram oito *baselines*. Nos experimentos, eles usaram *5-fold cross validation* e como métricas de avaliação Precisão, Revocação e *F-score*. Os resultados mostraram que os métodos propostos superaram o método sem explicação e obtiveram melhorias significativas.

Considerações—o trabalho de [Baral et al. \(2018\)](#) é muito interessante, cujo foco está nas explicações das recomendações. Os autores usam informações contextuais, bem como a mineração de opiniões no nível do aspecto. No entanto, eles não informam como os outros tipos de informação contextual, como categórica e espacial, são extraídos/obtidos. Eles demonstraram que o método proposto para explicar as recomendações produziu melhores resultados para a recomendação.

Sulthana e Ramasamy (2018) propuseram um Sistema de Recomendação baseado em Contexto e Ontologias (*Ontology and Context Based Recommendation System - OCBRS*) para o domínio de livros que usa uma abordagem de classificação *Neuro-Fuzzy*, também proposta por eles. Essa abordagem desenvolve um conjunto de regras *fuzzy* para classificar as *reviews* e para extrair informações contextuais.

As etapas do OCBRS são: (i) as *reviews* de livros da *Amazon* são coletadas e armazenadas; (ii) de acordo com [Sulthana e Ramasamy \(2018\)](#), contexto é um termo na *review* que indica os atributos qualitativos do produto ou circunstâncias do revisor. Eles consideram que o contexto é um substantivo que é acompanhado por um adjetivo. Desta forma, o *Stanford Parser*²⁶ é usado para identificar substantivos, adjetivos e advérbios. O sistema usa *SentiWordNet*²⁷ para identificar a polaridade das sentenças da *review*. Para extrair o contexto e sua relação com a palavra de opinião, os autores usam classificação *Neuro-Fuzzy*. O contexto extraído da *review* refere-se ao substantivo ou verbo e sua relação com a palavra de opinião; (iii) a ontologia de contexto das *reviews* é construída para armazenar o contexto dos produtos no domínio; e (iv) o contexto da ontologia é dado como entrada para o sistema de recomendação.

Avaliação—[Sulthana e Ramasamy \(2018\)](#) utilizaram a base de *reviews* de livros da *Amazon*. Essa base foi coletada do site da *Amazon* entre Dezembro de 2010 e Março de 2015. Como *baselines* eles utilizaram dois sistemas, o sistema proposto por [Aciar et al. \(2007\)](#) e o sistema proposto por [Qian et al. \(2014\)](#). De acordo com os resultados, o OCBRS apresentou resultados melhores que os *baselines*.

²⁵ <<https://www.airbnb.com>>

²⁶ <<https://nlp.stanford.edu/software/lex-parser.shtml>>

²⁷ <<https://sentiwordnet.isti.cnr.it/>>

Considerações—a descrição de contexto dada por [Sulthana e Ramasamy \(2018\)](#) é muito relacionada à definição de aspectos e de sentimentos relacionados a eles. Então, os autores consideram somente a opinião como informação contextual.

[Zangerle et al. \(2018\)](#) propuseram métodos para recomendação de música. Para isso, eles utilizaram *tweets* conhecidos como #nowplaying, que são *tweets* nos quais os usuários descrevem a música que eles estão escutando. Geralmente, nesses *tweets*, os usuários usam *hashtags* para descrever seus estados emocionais. Os autores consideram o estado emocional do usuário como informação contextual. Dessa forma, eles utilizaram somente *tweets* contendo *hashtags* que representam emoções.

Para detectar os sentimentos dos *tweets*, [Zangerle et al. \(2018\)](#) utilizaram um método conhecido como léxico de sentimentos. Portanto, eles consideraram quatro léxicos de opinião: *AFINN* ([NIELSEN, 2011](#)), *Opinion Lexicon* ([HU; LIU, 2004](#)), *SentiStrength* ([THELWALL et al., 2010](#)) e *Vader* ([HUTTO; GILBERT, 2014](#)). Primeiramente, a *hashtag* e o léxico são correspondidos. Depois de computar a afeição, os atributos latentes são computados. Para isso, [Zangerle et al. \(2018\)](#) constroem um grafo contendo três tipos de objetos, usuários, faixas e *hashtags*. Portanto, eles usam um algoritmo de *embedding* de rede, o *DeepWalk*, para aprender as representações desses objetos. Para classificar as faixas, [Zangerle et al. \(2018\)](#) usaram representações de atributos latentes construídas pela técnica de incorporação de redes. Os autores propuseram sete métodos para classificar as faixas.

Avaliação—[Zangerle et al. \(2018\)](#) realizaram três experimentos: (i) avaliação da eficácia de atributos latentes; (ii) avaliação da eficácia da informação de emoção; e (iii) avaliação da eficácia de cada léxico de sentimento, já que o conjunto de dados usado foi o conjunto de dados de *tweets* de #nowplaying compilado por [Zangerle et al. \(2018\)](#). O mesmo conjunto de dados foi pré-processado e transformado em dois. Na primeira etapa do pré-processamento, os *tweets* sem sentimento foram removidos. Na segunda etapa, um método de remoção de *outliers* foi aplicado. A métrica *Mean Reciprocal Rank* foi utilizada como métrica de avaliação. Os resultados mostraram que a informação afetiva é capaz de melhorar a recomendação.

Considerações—[Zangerle et al. \(2018\)](#) consideram o estado emocional do usuário como a única informação contextual. A informação é extraída usando uma técnica de análise de sentimentos, mas não é uma técnica baseada em aspectos. Assim, a *hashtag* que demonstra o estado emocional do usuário é extraída e, quando é uma palavra de sentimento, sua polaridade é definida por meio de um léxico de opinião.

Na Tabela 11, são apresentados os pontos fortes e fracos que foram observados nos trabalhos discutidos nesta seção.

Tabela 11 – Pontos fortes e fracos dos estudos analisados na revisão sistemática.

Referência	Pontos fortes	Pontos fracos
Ho <i>et al.</i> (2012)	<ul style="list-style-type: none"> • a informação contextual é extraída automaticamente. 	<ul style="list-style-type: none"> • mineração de opiniões no nível do documento; • não considera as preferências dos usuários; • somente localização e tempo como informações contextuais.
Levi <i>et al.</i> (2012)	<ul style="list-style-type: none"> • utiliza agrupamento não supervisionado para construir o vocabulário dos aspectos dos hotéis; • mineração de opiniões no nível dos aspectos. 	<ul style="list-style-type: none"> • as informações contextuais precisam ser informadas pelos usuários.
Meehan <i>et al.</i> (2013)	<ul style="list-style-type: none"> • a informação contextual é extraída automaticamente; • considera muitos tipos de informações contextuais. 	<ul style="list-style-type: none"> • a etapa de personalização pode não ser bem sucedida devido ao fato dos usuários nem sempre deixarem seus dados disponíveis nas redes sociais.
Chen e Chen (2014) Chen e Chen (2015)	<ul style="list-style-type: none"> • mineração de opiniões no nível dos aspectos; • a informação contextual é extraída automaticamente. 	<ul style="list-style-type: none"> • é necessário definir um conjunto de aspectos chave; • os valores de contexto possíveis são definidos manualmente.
Colace <i>et al.</i> (2015a) Colace <i>et al.</i> (2015b)	<ul style="list-style-type: none"> • considera muitos aspectos relacionados aos usuários juntamente com atributos dos itens e informações contextuais; • pode ser aplicado em domínios diferentes. 	<ul style="list-style-type: none"> • é necessário ter a informação da ordem de acessos e compras dos usuários; • a informação de confiança do usuário é requerida; • a minareção de opiniões não é aplicada no nível dos aspectos.
Kothari e Patel (2015)	<ul style="list-style-type: none"> • mineração de opiniões no nível dos aspectos; • a informação contextual é extraída automaticamente. 	<ul style="list-style-type: none"> • é necessário definir um conjunto de aspectos chave; • os valores de contexto possíveis são definidos manualmente.

Tabela 11 – Pontos fortes e fracos dos estudos analisados na revisão sistemática. (continuação)

Referência	Pontos fortes	Pontos fracos
Orellana-Rodriguez, Diaz-Aviles e Nejdil (2015)	<ul style="list-style-type: none"> • a informação contextual é extraída automaticamente. 	<ul style="list-style-type: none"> • considera somente emoção como contexto; • as emoções precisam ser pré-determinadas; • a mineração de opiniões não é aplicada no nível dos aspectos.
Yang <i>et al.</i> (2015)	<ul style="list-style-type: none"> • o perfil do usuário baseado em opiniões é construído em uma forma colaborativa; • gera sumários personalizados para as recomendações. 	<ul style="list-style-type: none"> • considera somente localização como informação contextual; • o sentimento é definido apenas pelo <i>rating</i> do usuário.
Zhao <i>et al.</i> (2016)	<ul style="list-style-type: none"> • pode utilizar poucos <i>ratings</i> para predizer o <i>rating</i> geral do serviço. 	<ul style="list-style-type: none"> • mineração de opiniões no nível do documento; • a informação contextual não é extraída automaticamente.
Kharrat, Elkhleifi e Faiz (2016)	<ul style="list-style-type: none"> • a informação contextual é extraída automaticamente; • mineração de opiniões no nível dos aspectos. 	<ul style="list-style-type: none"> • os aspectos são extraídos utilizando uma lista pré-definida de <i>tags</i> dos itens.
Missaoui <i>et al.</i> (2017)	<ul style="list-style-type: none"> • a informação contextual é extraída automaticamente; • pode ser aplicado a uma variedade de tarefas de recomendação similares. 	<ul style="list-style-type: none"> • considera somente localização como informação contextual; • o sentimento é definido somente pelo <i>rating</i> do usuário.
Jalan e Gawande (2017)	<ul style="list-style-type: none"> • mineração de opiniões no nível dos aspectos. 	<ul style="list-style-type: none"> • a informação contextual precisa ser informada pelo usuário.
Baral <i>et al.</i> (2018)	<ul style="list-style-type: none"> • mineração de opiniões no nível dos aspectos; • utiliza múltiplos contextos; • gera explicações. 	<ul style="list-style-type: none"> • não explica como a informação contextual foi extraída.
Sulthana e Ramasamy (2018)	<ul style="list-style-type: none"> • a informação contextual é extraída automaticamente; • mineração de opiniões no nível dos aspectos. 	<ul style="list-style-type: none"> • apenas opinião como informação de contexto.

Tabela 11 – Pontos fortes e fracos dos estudos analisados na revisão sistemática. (continuação)

Referência	Pontos fortes	Pontos fracos
Zangerle <i>et al.</i> (2018)	<ul style="list-style-type: none"> • a informação contextual é extraída automaticamente; • é aplicada uma abordagem de análise de sentimentos não supervisionada. 	<ul style="list-style-type: none"> • não aplica a mineração de opiniões no nível dos aspectos; • considera somente o estado emocional como informação contextual.

2.6 Considerações Finais

Neste capítulo foram apresentados alguns conceitos das áreas de sistemas de recomendação sensíveis ao contexto e de mineração de opiniões. Além disso foram apresentados e discutidos os trabalhos de sistemas de recomendação sensíveis ao contexto que utilizam mineração de opiniões encontrados por meio da revisão sistemática realizada. Essa revisão mostrou que sistemas de recomendação sensíveis ao contexto e mineração de opinião são tópicos de pesquisa recentes, com um número crescente de publicações.

As principais contribuições da revisão sistemática executada neste doutorado são: (i) foram identificadas as pesquisas em sistemas de recomendação sensíveis ao contexto que também utilizam informações extraídas pela mineração de opinião; (ii) foi feito um mapeamento de como essas pesquisas estão combinando essas duas tecnologias (sistemas de recomendação sensíveis ao contexto e mineração de opinião); (iii) foram apontadas algumas áreas que podem ser melhoradas em trabalhos primários futuros, assim como desafios abertos de pesquisa; (iv) sua condução seguiu um protocolo de revisão de literatura bem definido; (v) além disso, seus resultados podem ser de grande ajuda para os pesquisadores que trabalham com sistemas de recomendação sensíveis ao contexto e mineração de opiniões.

A revisão sistemática sobre sistemas de recomendação que utilizam mineração de opinião mostrou que existem métodos de sistemas de recomendação sensíveis ao contexto que modelam as preferências dos usuários no nível do item e não consideram os aspectos do mesmo, isto é, eles consideram a informação contextual relacionada à avaliação geral do item (COLACE *et al.*, 2015a; ORELLANA-RODRIGUEZ; DIAZ-AVILES; NEJDL, 2015; YANG *et al.*, 2015) (Tabela 8). Entretanto, as preferências também podem ser modeladas no nível dos aspectos e tais preferências podem ser influenciadas por fatores contextuais (LEVI *et al.*, 2012; CHEN; CHEN, 2014; CHEN; CHEN, 2015; KOTHARI; PATEL, 2015) (Tabelas 7 e 9). Por exemplo, um usuário pode dar mais importância para a “localização” quando seu contexto é “viagem a trabalho”, mas no contexto “viagem em família”, o aspecto “quarto” pode tornar-se mais importante. Além disso, alguns métodos que consideram tanto informações contextuais quanto informações de

opiniões, não utilizam métodos automáticos para extrair ambos tipos de informação. Dessa forma, considera-se muito relevante a proposta de métodos automáticos para extração de informações contextuais e de opiniões no nível dos aspectos. Além disso, a maioria dos trabalhos atuais utilizam *reviews* de usuários como fonte de informações contextuais e de opinião (Tabela 10).

Dessa forma, levando em consideração a carência de métodos automáticos de extração de contexto assim como a relevância das informações possivelmente extraídas de *reviews* de usuários para os sistemas de recomendação, neste trabalho de doutorado são propostos:

1. uma técnica automática de extração de contexto baseada em *word embeddings* (CIET.5_{embed});
2. uma técnica automática de extração de contexto baseada em regras de associação (*Rules-Context*);
3. uma técnica automática de extração de contexto baseada em opiniões (*CEOM*); e
4. um método de recomendação sensível ao contexto que utiliza as técnicas citadas anteriormente (*CARM-TOM*).

As técnicas e o método de recomendação propostos neste doutorado são apresentados com detalhes no próximo capítulo.

RECOMENDAÇÃO SENSÍVEL AO CONTEXTO BASEADA EM MINERAÇÃO DE TEXTOS E DE OPINIÕES

No Capítulo 2 foi apresentada uma revisão sistemática na qual foi observado que sistemas de recomendação sensíveis ao contexto estão sendo extensivamente investigados, mas que ainda existe uma carência de métodos automáticos para a extração de informações contextuais. Essa carência motiva o desenvolvimento de novas abordagens, principalmente considerando o cenário de avanço da Web 2.0 e de crescimento das redes sociais e comércio eletrônico. Nesse cenário, usuários têm registrado comentários e *reviews* nos quais expressam além de suas opiniões sobre produtos e serviços, também informações contextuais que podem enriquecer os sistemas de recomendação.

Com base nesse contexto, este trabalho de doutorado tem como objetivo investigar e propor técnicas automáticas para extração de informações contextuais de *reviews* de usuários. Mas antes de propor uma técnica de extração de contexto, é necessário definir como as *reviews* serão pré-processadas e preparadas. Além disso, é importante planejar como a informação contextual será utilizada pelos sistemas de recomendação. Para isso, foi proposto o método *CARM-TOM* (*Context-Aware Recommender Method based on Text and Opinion Mining*), um método de recomendação que executa desde o pré-processamento das *reviews* e a extração das informações contextuais, até a geração das recomendações utilizando as informações extraídas dessas *reviews*. Para a extração das informações contextuais foram propostas três técnicas: a *CIET.5_{embed}*, a *RulesContext* e a *CEOM*, apresentadas e descritas neste capítulo.

O método *CARM-TOM*, ilustrado na Figura 9, é executado em 4 etapas, sendo a etapa 3 a mais relevante deste trabalho, pois trata-se da extração automática de informações contextuais. Todas as etapas são detalhadas nas próximas seções.

Figura 9 – Visão geral do método *CARM-TOM*

3.1 Pré-processamento e Limpeza

Para inferir informações contextuais de *reviews*, o método *CARM-TOM* recebe como entrada uma coleção de *reviews*, que é normalmente composta pelas identificações dos usuários, identificações dos itens avaliados por eles, conteúdos textuais nos quais os usuários justificam suas opiniões sobre os itens, datas nas quais as avaliações foram feitas, entre outros.

As *reviews* devem ser preparadas tanto para os sistemas de recomendação quanto para as técnicas de extração de contexto. Para os sistemas de recomendação devem ser selecionados os atributos relevantes para a tarefa de recomendação, como identificação do usuário, identificação do item e *rating* atribuído ao item pelo usuário no caso dos sistemas de recomendação que consideram *feedback* explícito. Já para a extração de contexto, devem ser extraídos os textos das *reviews* para que os mesmos possam ser processados pelas técnicas. Com isso, o pré-processamento é responsável por preparar o conjunto de dados para a recomendação e também para a extração de contexto.

Para a recomendação, as *reviews* são filtradas excluindo aquelas sem conteúdo textual ou outras informações importantes como as identificações de usuários e itens. Além disso, para o bom desempenho do sistema de recomendação, os dados utilizados devem apresentar algumas características, que são descritas a seguir. Para isso, é seguido como referência o trabalho de [Chen e Chen \(2014\)](#). Dessa forma, são excluídos: 1) Usuários com 1 *review*, para garantir que o usuário tenha avaliado mais de um item; 2) Itens com menos de 15 *reviews*, garantindo que os itens tenham sido avaliados por no mínimo 15 usuários; e 3) *Reviews* com menos de 3 sentenças, para garantir que o conteúdo textual das *reviews* tenha representatividade suficiente para a extração de possíveis informações contextuais.

Além da filtragem, são executadas as tarefas: 1) Separação do conteúdo textual das *reviews*, construindo uma coleção de textos na qual cada arquivo representa o conteúdo textual de uma *review*; e 2) Seleção dos dados relevantes para os algoritmos de recomendação, isto é, geração de um sub-conjunto dos dados contendo usuários e itens.

Em seguida, a coleção de textos passa por uma limpeza com o objetivo de eliminar alguns caracteres especiais como @, *, # e &. Esses caracteres podem influenciar negativamente no processo de extração de contexto. Dessa forma, os textos limpos podem ser diretamente utilizados pelas técnicas de extração de contextos ou eles podem passar pelo normalizador na próxima etapa do método.

3.2 Normalização dos Textos

A normalização textual é o processo de transformar palavras fora do padrão (NSWs, do inglês *non-standard words*) em palavras consideradas canônicas. Geralmente, NSWs são formas ruidosas de palavras corretas, ou seja, contêm ruídos que as tornam irreconhecíveis pelo padrão estabelecido. Esses ruídos são encontrados em diversas formas, como erros ortográficos, siglas, capitalização inválida e mau uso de pontuação. Textos de *reviews* são fontes de grande quantidade de ruídos, devido principalmente à sua natureza informal. Desse modo, é natural considerar a normalização para melhorar a qualidade dos textos das *reviews* (BERTAGLIA, 2017).

Neste trabalho, foi utilizado o normalizador *TextExpansion*¹ (ALMEIDA *et al.*, 2016) na etapa 2 do método *CARM-TOM*, para normalizar os textos das *reviews* e adquirir atributos melhores. *TextExpansion* é baseado em dicionários semânticos e lexicográficos e utiliza técnicas do estado-da-arte para análise semântica.

O normalizador *TextExpansion* emprega dois dicionários. O primeiro é um dicionário de inglês usado para verificar se um termo é uma palavra em inglês e então o normaliza para sua forma raiz (por exemplo, “*is*” ⇒ “*be*” e “*going*” ⇒ “*go*”). O segundo é o dicionário Lingo, que contém as palavras erradas que geralmente são escritas por usuários. O processo começa procurando por cada palavra da amostra no dicionário de inglês. Nesse caso é utilizado o dicionário de inglês *Freeling*². Se a palavra está nesse dicionário, ela é então normalizada para sua forma raiz. Caso contrário, a palavra é buscada no dicionário Lingo, que neste caso é o dicionário *NoSlang*³. Se o dicionário Lingo não possui uma tradução para a palavra, a original é mantida.

A normalização é uma etapa opcional no método *CARM-TOM*, pois depende da qualidade dos textos, isto é, ela é recomendada para o processamento de textos que apresentam muitos problemas de escrita. No caso de textos com uma boa qualidade, ela pode ser dispensada, já que representa mais processamento e tempo dentro do método geral. Para analisar a influência da normalização na recomendação, neste trabalho de doutorado foi executado o método de recomendação com e sem essa etapa. Os resultados obtidos serão apresentados e discutidos no Capítulo 4 desta tese.

¹ <<http://lasid.sor.ufscar.br/expansion/static/index.html>>

² <<http://devel.cpl.upc.edu/freeling>>

³ <<http://www.noslang.com/dictionary/full>>

3.3 Extração de Contexto

A principal etapa do *CARM-TOM* representa o processo de extração de contexto de *reviews*. Nesta etapa são aplicadas as técnicas de extração de contexto propostas neste trabalho: a técnica *CIET.5_{embed}* (SUNDERMANN *et al.*, 2018) baseada em *word embeddings*, a técnica *RulesContext* (SUNDERMANN *et al.*, 2019b) baseada em regras de associação e a técnica *CEOM* baseada em mineração de opiniões. Essas técnicas são descritas nas próximas subseções.

3.3.1 Técnica de Extração de Contexto baseada em Word Embeddings (*CIET.5_{embed}*)

Como apresentado no Capítulo 2, existe um esforço cada vez maior em incorporar informações importantes extraídas de *reviews* de usuários em sistemas de recomendação. O contexto presente em um texto de *review* pode ser explicitamente informado pelo usuário, como na frase “Nós chegamos no hotel às **15h** para ficar por **3 noites** como a primeira parada de nossa **lua de mel**”, na qual o usuário registra informações de tempo e o objetivo da viagem. Por outro lado, o contexto pode estar implícito no texto do usuário, como no exemplo: “Ficamos na fila por cerca de vinte minutos para fazer o check-in e ser avisados de que nosso quarto não estaria pronto até 16:00.”. Nesse exemplo, o usuário deixa sua insatisfação implicitamente registrada na *review*.

Para lidar com informações contextuais implícitas extraídas diretamente de documentos, podem ser utilizados vários recursos de anotação e descrição de palavras, abordando aspectos linguísticos importantes, como morfologia, morfossintaxe e funções semânticas. Por outro lado, o tratamento de informações contextuais explícitas capturadas indiretamente de documentos pode exigir a aplicação de abordagens de extração mais complexas, suportadas por fontes externas de conhecimento, como enciclopédias, tesouros ou ontologias.

A extração de informações implícitas deve levar em consideração o fato de que o acesso a fontes externas de conhecimento tende a intensificar o volume e a qualidade das informações consideradas, implicando na descoberta e extração de contextos densos e ricos. A abordagem de modelagem ou representação de texto também é um fator importante a ser levada em consideração, pois afeta diretamente a qualidade dos documentos relacionados gerados por meio de suas palavras. Afinal, a maneira como os atributos dos documentos estão relacionados é tão importante quanto a qualidade de seus recursos.

Abordagens de representações de texto baseadas em *word embeddings* foram extensivamente estudadas na área de Mineração de Textos (SOHRAB; MIWA; SASAKI, 2015; WANG *et al.*, 2016; SINOARA; ANTUNES; REZENDE, 2017), destacando as abordagens tradicionais porque representam cada palavra por um vetor único capaz de agregar um grande volume de informações latentes (COLLOBERT; WESTON, 2008). Basicamente, os modelos de incorporação de palavras permitem descobrir a ocorrência de palavras de acordo com o contexto em

que elas ocorrem (BARONI; DINU; KRUSZEWSKI, 2014) e podem ser usados por diferentes ferramentas, como *Word2Vec*⁴ e *GloVe*⁵.

Considerando que a maioria dos métodos tradicionais de representação de texto geralmente trata documentos como combinações de termos independentes, a utilização de técnicas de *word embeddings* possibilita o enriquecimento semântico das representações de texto. Com isso, neste trabalho de doutorado, abordagens de *word embeddings* foram exploradas para a extração de informações contextuais de *reviews*, utilizando fontes externas de conhecimento como *Wikipedia*⁶ e *WordNet*⁷ para intensificar a identificação de informações implícitas. Portanto, foi proposta a técnica *CIET.5_{embed}* (*Contextual Information Extraction Technique based on 5 steps*).

A técnica *CIET.5_{embed}* consiste em combinar duas técnicas de representação (*bag of words* e *word embeddings*) o que permite aumentar o volume e a qualidade da informação e dos relacionamentos latentes entre os termos dos documentos e a interpretabilidade das representações geradas. O principal objetivo é transformar um conjunto de dados em um conjunto de contextos baseados em *word embeddings*. A técnica *CIET.5_{embed}* é formada por cinco etapas complementares (Figura 10), as quais transformam um conjunto de documentos de textos em um conjunto de documentos contextualizados.

Figura 10 – Visão geral da técnica *CIET.5_{embed}*

Diferente das técnicas de representação de textos tradicionais, que utilizam apenas os documentos da base de dados para gerar a representação (documentos internos), a técnica proposta, *CIET.5_{embed}*, utiliza como suporte fontes externas de conhecimento (documentos externos) para potencializar a descoberta de padrões textuais por meio de informações sintetizadas em um modelo de texto. A técnica *CIET.5_{embed}* pode ser dividida em etapas que abrangem a construção do modelo (preparação, delimitação e modelagem) e etapas posteriores que usam as

⁴ <<https://code.google.com/p/word2vec>>

⁵ <<https://nlp.stanford.edu/projects/glove>>

⁶ <<https://www.wikipedia.org>>

⁷ <<https://wordnet.princeton.edu>>

informações desse modelo (contextualização e extração). Essas etapas são descritas a seguir e exemplificadas na Figura 11⁸.

Figura 11 – Exemplo de extração de contexto utilizando a técnica *CIET.5_{embed}*

Na **Preparação**, todos os documentos utilizados durante o processo da *CIET.5_{embed}* (tanto os documentos internos quanto os externos) são submetidos para um processo de identificação de palavras, com o objetivo de amenizar alguns problemas relacionados à interpretação textual. Durante a etapa inicial, as palavras não identificadas como relevantes (ou seja, que não são entidades nomeadas (EN) ou conceitos) podem ser removidas.

Na **Delimitação**, os documentos já preparados (tanto os documentos internos quanto os externos) são submetidos a um processo de delimitação dos escopos textuais, como parágrafos e sentenças. Os relacionamentos latentes entre os documentos podem ser transferidos para as representações considerando seus escopos textuais. Nesse caso, a separação dos documentos em sentenças é justificada pelo fato que elas caracterizam o menor escopo possível com um agregador de informação latente potencial.

⁸ Os textos utilizados no exemplo referem-se ao ICMC (Instituto de Ciências Matemáticas e de Computação) e ao LABIC (Laboratório de Inteligência Computacional) da USP e foram adaptados para demonstrar as etapas da técnica *CIET.5_{embed}*

Algoritmo 1 – Técnica de extração de contexto *CIET.5_{embed}***Requer:** Documentos D , fontes externas de documentos E e w (tamanho do contexto)**Assegure:** Conjunto de contextos R

```

1: procedimento CIET.5( $D, E$ )
2:    $D, E \leftarrow \text{PREPARA}(D, E)$ 
3:    $D, E \leftarrow \text{DELIMITA}(D, E)$ 
4:    $M \leftarrow \text{MODELA}(D, E)$ 
5:    $D, A \leftarrow \text{CONTEXTUALIZA}(M, D, w)$ 
6:    $R \leftarrow \{\}$ 
7:   para todo  $d \in D$  faça
8:      $C \leftarrow \{\}$ 
9:     para todo  $a \in A$  faça
10:      para todo  $c \in d$  faça
11:         $s \leftarrow \text{SIMILARIDADE}(a, c)$ 
12:        se  $s \geq t$  então                                      $\triangleright$  Limiar de similaridade  $t$ 
13:           $C \leftarrow C \cup \{a\}$ 
14:        fim se
15:      fim para
16:    fim para
17:     $R \leftarrow R \cup C$ 
18:  fim para
19:  retorna  $R$ 
20: fim procedimento

```

Na **Modelagem**, um modelo textual baseado em *word embeddings* e treinado anteriormente com os documentos das fontes externas é retreinado com os documentos internos. Esta etapa tem como objetivo obter a generalização do conhecimento de mundo e a especificação dos documentos analisados. Treinar um modelo com documentos externos pode ampliar o vocabulário e intensificar as relações entre as palavras, possivelmente favorecendo a etapa de extração de padrões focada em extrair contextos dos documentos.

Na **Contextualização**, os contextos dos documentos internos são identificados. As palavras de cada sentença são processadas no modelo textual para encontrar as palavras mais relacionadas a elas. Utilizando, por exemplo, a métrica cosseno, é calculada a similaridade entre os vetores das palavras das sentenças e os vetores do modelo textual retreinado. Neste momento é feita pergunta: “*Quais são w as palavras mais relacionadas à sentença S_x ?*”, sendo w um número natural referente ao tamanho dos contextos e que pode ser definido para a execução da técnica. S_x representa cada sentença do total de x sentenças.

Finalmente, na **Extração**, os contextos são extraídos dos documentos utilizando um limiar de comparação, como observado no Algoritmo 1. Na técnica *CIET.5_{embed}*, as similaridades entre contextos também são consideradas, para intensificar as relações entre eles. Para um documento $D_1 = \{c_1 = \{w_1, w_2, w_3\}, c_2 = \{w_2, w_4\}\}$, em que A é o conjunto único de todos os contextos identificados a , quando o grau de similaridade $S_{1,2} = \frac{\text{length}(c_1 \cap c_2)}{\text{length}(c_2)}$ entre o contexto c_1 e

c_2 é maior ou igual que um limiar t , então o contexto c_2 é adicionado na lista de contextos do documento D_1 . Analogamente, quando o grau de similaridade $S_{2,1}$ entre o contexto c_2 e c_1 é maior que t , então o atributo c_1 é adicionado à lista de contextos do documento D_1 .

3.3.2 Técnica de Extração de Informação Contextual baseada em Regras de Associação (*RulesContext*)

A técnica de extração de contextos baseada em regras de associação *RulesContext*, proposta neste trabalho, é uma técnica que extrai regras de associação de *reviews* e as transforma em informações contextuais para serem utilizadas em sistemas de recomendação.

As regras de associação foram propostas por [Agrawal, Imieliński e Swami \(1993\)](#) e são amplamente utilizadas na literatura para encontrar correlações entre itens de uma determinada base de dados. As regras de associação são apresentadas no formato $LHS \rightarrow RHS$, em que LHS significa lado esquerdo e RHS lado direito, ambos são formados por um conjunto de itens tal como $LHS \cap RHS = \emptyset$.

As informações contextuais podem ser formadas por termos fortemente correlacionados, como por exemplo nomes de locais (São Paulo) e também informações de tempo (quinta-feira). A técnica *RulesContext* (visão geral mostrada na Figura 12) encontra correlações entre os termos por meio da extração de regras de associação e gera informações de contexto formadas pelos termos dessas regras. As etapas da técnica são descritas a seguir e exemplificadas na Figura 13⁹.

A etapa de **Separação por itens** possibilita a extração de contexto do item. Nessa etapa os textos são separados por item, isto é, subconjuntos de textos são formados. Cada subconjunto é composto por textos de *reviews* sobre um item específico.

Figura 12 – Visão geral da técnica *RulesContext*

No **Pré-processamento e Preparação**, os textos são pré-processados, isto é, as *stopwords* são removidas e os termos são radicalizados. Além disso, esses textos devem ser transformados

⁹ Os textos utilizados no exemplo referem-se ao ICMC (Instituto de Ciências Matemáticas e de Computação) e ao LABIC (Laboratório de Inteligência Computacional) da USP e foram adaptados para demonstrar as etapas da técnica *RulesContext*

Figura 13 – Exemplo de extração de contexto utilizando a técnica *RulesContext*

em um formato no qual o algoritmo de extração de regras de associação possa manipular. Portanto, cada conjunto de textos é transformado em um conjunto de transações, no qual cada texto é uma transação e cada termo do texto é um item da transação.

Na **Extração de regras de associação**, as regras de associação são extraídas das transações de cada subconjunto. Para isso, foi utilizado o algoritmo de extração de regras de associação Apriori (AGRAWAL; IMIELNISKI; SWAMI, 1993). Esse algoritmo extrai as regras em duas etapas combinando os itens de uma base de dados e calculando duas medidas: suporte e confiança.

A medida de suporte calcula a porcentagem de transações que contêm os itens que estão sendo analisados (Equação 3.1, em que $T(LHS)$ é o número de transações contendo A e $T()$ é o número total de transações). Depois disso, os itens são combinados em regras e a confiança é aplicada como limiar. A confiança mede a quantidade de transações que *RHS* ocorre dado que *LHS* ocorreu (Equação 3.2). Se a regra tem um valor de confiança maior que a confiança mínima,

então é apresentada para o usuário, caso contrário é removida.

$$Suporte(LHS) = \frac{T(LHS)}{T()} \quad (3.1)$$

$$Confianca(LHS \rightarrow RHS) = \frac{Suporte(LHS \cup RHS)}{Suporte(LHS)} \quad (3.2)$$

O primeiro passo do algoritmo apriori consiste em verificar se os itens são frequentes de acordo com um valor de suporte mínimo. Para isso, são calculados os suportes de cada item. Se esses valores forem superiores ao suporte mínimo, então os *itemsets* de tamanho 1 são considerados frequentes. Em seguida, todos os *itemsets* de tamanho 2 são verificados, combinando todos os *itemsets* frequentes de tamanho 1. Então, todos os conjuntos de 3 itens são verificados combinando todos os *itemsets* frequentes de tamanho 2. Esse processo continua até que não existam mais *itemsets* frequentes para serem extraídos.

O segundo passo do algoritmo Apriori consiste na análise dos *itemsets* frequentes de tamanho 2. Por exemplo: dado um *itemset* frequente de tamanho 2 $\{a, b\}$, o algoritmo extrai as regras $a \rightarrow b$ e verifica seu valor de confiança, se for inferior a um valor de confiança mínimo, a regra é descartada, caso contrário é armazenada. Então, o algoritmo testa a regra $b \rightarrow a$ utilizando a mesma lógica. Para *itemsets* frequentes de tamanho n , o algoritmo testa todas as possíveis combinações dos n itens, sempre conferindo o valor de confiança.

Após a extração das regras, existem várias medidas que podem avaliá-las de acordo com alguns objetivos pré-definidos.

Uma medida muito conhecida é a medida *Lift*, que calcula a força da correlação. O resultado apresenta quantas vezes *LHS* e *RHS* aparecem juntos comparando com a quantidade esperada de vezes. Os valores variam de 0 a ∞ , sendo que quando estão próximos de 1 indicam que não há correlação entre os itens, valores maiores que 1 indicam que há correlação entre os itens e valores menores que 1 indicam que os itens aparecem juntos por acaso. A medida é apresentada na Equação 3.3.

$$Lift(LHS \rightarrow RHS) = \frac{Suporte(LHS \cup RHS)}{Suporte(LHS)Suporte(RHS)} \quad (3.3)$$

A medida *mutual information* também é muito conhecida e mede o quão dependentes são as variáveis do *LHS* e *RHS*. A medida retorna 0 se as variáveis forem totalmente independentes. A medida *mutual information* é apresentada na Equação 3.4

$$MI(LHS \rightarrow RHS) = Support(LHS \cup RHS) \log(Lift(LHS \rightarrow RHS)) \quad (3.4)$$

Por fim, após extrair as regras, é feita a **Transformação de Regras em Contexto**, em que as regras extraídas são transformadas em informação contextual. Por exemplo, a regra

{Camp⇒Sao,Carlos}, após a transformação, passa a ser {Camp_Sao_Carlos}. Com isso, as informações contextuais estão estruturadas para serem utilizadas pelos sistemas de recomendação.

3.3.3 Técnica de Extração de Contexto utilizando Mineração de Opiniões (CEOM)

Como já discutido no Capítulo 2, várias são as informações que podem ser extraídas do conteúdo textual das *reviews*. Essas informações podem representar grande relevância no processo de recomendação. Por exemplo, as informações de opiniões dos usuários são muito importantes para um sistema de recomendação, já que indicam se os usuários gostaram ou não de um determinado item. Ainda mais importante que a opinião geral expressa nas *reviews*, existem as opiniões baseadas em aspectos, que expressam a satisfação ou insatisfação dos usuários sobre aspectos mais específicos do item avaliado. Essas informações podem também ser consideradas como informações contextuais, pois caracterizam situações de usuários e itens dentro de um sistema.

Dessa forma, neste trabalho foi proposta a técnica de extração de contexto que utiliza mineração de opiniões baseada em aspectos, *CEOM* (*Context Extraction technique based on Opinion Mining* - Figura 14). Essa técnica é apresentada a seguir, com uma descrição de cada etapa. Para um melhor entendimento da técnica, na Figura 15¹⁰, é apresentado um exemplo que mostra os resultados de cada etapa.

Figura 14 – Visão geral da técnica *CEOM*

A primeira etapa da técnica para extração de contexto é o **Pré-Processamento**, no qual é construída a árvore de dependência das sentenças, utilizando um parser de dependência. Além disso, no pré-processamento, também é realizada a lematização das palavras, utilizando um lematizador. Neste trabalho foram utilizados o parser de dependência e o lematizador da *Stanford*¹¹.

¹⁰ Os textos utilizados no exemplo são fictícios e criados para ilustrar a técnica *CEOM*.

¹¹ <<https://nlp.stanford.edu>>

Figura 15 – Exemplo de extração de contexto utilizando a técnica CEOM

Para a **Extração dos Aspectos**, segunda etapa, é utilizada uma abordagem baseada em relações sintáticas (PORIA *et al.*, 2014). Abordagens baseadas em relações sintáticas são métodos não supervisionados que têm como objetivo analisar a relação entre aspectos e termos opinativos. Abordagens desse tipo consistem em identificar relações sintáticas e gramaticais em uma sentença para definir os termos que representam aspectos. Dessa forma, nesta técnica (CEOM) são empregadas regras de dependência na árvore sintática para extrair aspectos. As regras utilizadas são listadas a seguir, considerando que h refere-se a um token ativo que está em uma relação objeto substantivo (PORIA *et al.*, 2014).

- Se o termo t_1 tem um adjetivo modificador, então t_1 é extraído como aspecto. No exemplo Ex1, “waiters” possui o adjetivo modificador “polite”, então “waiter” é extraído como um aspecto.
- Se a sentença não possui verbo auxiliar, por exemplo, “was”, “would”, “should”, “could”, então:
 1. Se o verbo v é modificado por um adjetivo, então h e v são extraídos como aspectos. No exemplo Ex2, “food” está em uma relação de sujeito com “smells” e “smells” é modificado pelo adjetivo modificador “great”, dessa forma ambos os aspectos “smell”

Figura 16 – Exemplo Ex1

e “*food*” são extraídos.

Figura 17 – Exemplo Ex2

- Se um termo t_1 tem alguma relação de objeto direto com um token t_2 e o POS do token é substantivo, então t_2 é extraído como aspecto. No exemplo Ex3, “*love*” está em uma relação de objeto direto com “*service*” então o aspecto “*service*” é extraído.

Figura 18 – Exemplo Ex3

- Se t_1 estiver na relação de complemento clausal aberto com um token t_2 , então o aspecto $t_1 - t_2$ é extraído. Se t_1 está conectado com um token t_3 cujo POS é substantivo, então t_3 é extraído como um aspecto. No exemplo Ex4, “*like*” e “*comment*” estão em complemento clausal e “*comment*” é conectado à “*food*” usando uma relação de preposição. O POS de “*food*” é substantivo e, portanto, o termo “*food*” é extraído como um aspecto.

Figura 19 – Exemplo Ex4

- Uma cópula é a relação entre o complemento de um verbo copulativo¹² e o verbo copulativo. Se o token t_1 está em relação cópula com um verbo copular, então t_1 é extraído como termo de aspecto. No exemplo Ex5, “*expensive*” é extraído como um aspecto.
- Se o token t_1 estiver em relação de cópula com um verbo copular e o POS de h for substantivo, então h será extraído como um aspecto. No exemplo Ex6, o termo “*atmosphere*” é extraído como um aspecto.

¹² Verbos copulativos são verbos de ligação entre o sujeito e o predicativo do sujeito. Por exemplo: ser, estar, continuar, parecer, ficar, permanecer, etc.

Figura 20 – Exemplo Ex5

Figura 21 – Exemplo Ex6

- Se o token t_1 estiver em relação de cópula com um verbo copular e o verbo copular estiver conectado a um token t_2 usando qualquer relação de dependência e t_2 for um verbo, então ambos t_1 e t_2 serão extraídos como termos de aspecto implícito. No exemplo Ex7, “strong” está em relação cópula com “is” e “strong” está ligado à palavra “eat” por relação de complemento clausal aberto. Dessa forma, “strong” e “eat” são extraídos como aspectos.

Figura 22 – Exemplo Ex7

Na **Classificação do Sentimento**, é assumido que todo adjetivo é uma palavra opinativa. Dessa forma, para definir a polaridade, a técnica seleciona o trecho (sentença) do texto em que o aspecto ocorre e classifica esse trecho utilizando um classificador de sentimento. Neste trabalho de doutorado, é utilizado *SentiWordNet* como classificador de sentimento. *SentiWordNet* é um recurso léxico criado para apoiar a classificação de sentimentos e aplicações de mineração de opinião (PANG; LEE, 2008). Esse recurso é o resultado da anotação automática de todos os *synsets*¹³ da *WordNet* de acordo com as noções de “positividade”, “negatividade” e “neutralidade”. Cada *synset* está associado a três pontuações numéricas Pos, Neg e Neu que indicam o quão positivos, negativos e objetivos (neutros) os termos contidos no *synset* são. Cada uma das três faixas varia no intervalo [0,0, 1.0], e sua soma é 1.0 para cada *synset* (BACCIANELLA; ESULI; SEBASTIANI, 2010).

Por meio da terceira etapa são obtidas informações das *reviews* no formato {aspecto, adjetivo, sentimento}. O sentimento é formado pelas pontuações numéricas Pos, Neg e Neu como mencionado anteriormente. Na quarta etapa, referente à **Extração do Contexto**, as informações que representarão o contexto são selecionadas, sendo o sentimento a polaridade com maior valor. Dessa forma, os seguintes tipos de informações podem ser extraídas como contexto:

¹³ De acordo com a *WordNet*, um *synset* ou conjunto de sinônimos é definido como um conjunto de um ou mais sinônimos que são permutáveis em algum contexto sem mudar o valor real da proposição no qual eles estão embutidos.

- aspectos
- adjetivos
- sentimento
- aspectos_adjetivos
- aspectos_sentimentos
- adjetivos_sentimentos
- aspectos_adjetivos_sentimentos

Na próxima seção é apresentada a etapa na qual as informações contextuais extraídas são utilizadas pelos sistemas de recomendação sensíveis ao contexto.

3.4 Sistemas de Recomendação Sensíveis ao Contexto

Na quinta etapa do método *CARM-TOM*, o conjunto de informações contextuais gerado na etapa de extração de contexto é inserido nos sistemas de recomendação sensíveis ao contexto, juntamente com os dados de usuários e itens selecionados no pré-processamento. A informação contextual é considerada para recomendação de acordo com o tipo de sistema de recomendação que é utilizado. Como apresentado no Capítulo 2, nos sistemas de recomendação de pré-filtragem contextual, o contexto é utilizado no início do processo para filtrar os dados de entrada no sistema. Nos sistemas de recomendação de modelagem contextual, o contexto é utilizado pelo sistema juntamente com os dados de usuários e itens. Por fim, nos sistemas de recomendação de pós-filtragem contextual, as recomendações geradas são filtradas ou reordenadas de acordo com o contexto. Essas três abordagens de recomendação sensíveis ao contexto, podem utilizar sistemas de recomendação tradicionais em sua implementação, como sistemas de filtragem colaborativa.

Sistemas de recomendação de filtragem colaborativa podem ser organizados em duas categorias, como apresentado no Capítulo 2: **métodos de vizinhança** (métodos de vizinhos) e **modelos de fatores latentes** (métodos baseados em modelo). **Métodos de vizinhança** encontram relações entre usuários e/ou itens e então usam essas relações para fazer as recomendações. Neste trabalho de doutorado foram considerados os algoritmos de recomendação sensíveis ao contexto: *cReduction* (ADOMAVICIUS *et al.*, 2005), *Weight PoF* e *Filter PoF* (PANNIELLO; GORGOGNONE, 2012), apresentados na Seção 2.1 e baseados no algoritmo de vizinhança *Item-Based Collaborative Filtering (IBCF)* (DESHPANDE; KARYPIS, 2004), que é um dos *baselines* utilizados nos experimentos. No IBCF, um modelo M de filtragem colaborativa baseada no item é uma matriz que representa as similaridades entre todos os pares de itens, de acordo com alguma medida de similaridade. Neste trabalho é considerada a medida de similaridade cosseno, mais comumente utilizada em sistemas de recomendação e definida como:

$$sim(i_1, i_2) = \cos(\vec{i}_1, \vec{i}_2) = \frac{\vec{i}_1 \cdot \vec{i}_2}{\|\vec{i}_1\| * \|\vec{i}_2\|}, \quad (3.5)$$

em que $\vec{i}_1$ e $\vec{i}_2$ são vetores de avaliações e o operador “.” denota o produto dos dois vetores. Para esse algoritmo é considerada a avaliação binária, ou seja o valor 1 significa que o usuário avaliou o item respectivo, enquanto o valor 0 é o oposto. Dado um usuário ativo u_a e seu conjunto de itens observados, as N recomendações são geradas calculando os *scores* de recomendação para os itens candidatos como:

$$score(u_a, O, r) = \frac{\sum_{i \in K_r \cap O} sim(r, i)}{\sum_{i \in K_r} sim(r, i)}, \quad (3.6)$$

em que K_r é o conjunto dos k itens mais similares ao item candidato r . Os N itens candidatos com valores mais altos de *score* são recomendados ao usuário u_a .

Por outro lado, os **modelos de fatores latentes** procuram encontrar atributos ou padrões nos dados de treinamento, também chamados fatores, que são usados para fazer as recomendações. Um dos *baselines* utilizados neste trabalho é o modelo de fatores latentes baseado em técnicas de fatoração de matrizes e apresentado por [Koren et al. \(2009\)](#) (**MF**), que combina boa acurácia e escalabilidade.

O conjunto de treinamento consiste de avaliações dadas pelos usuários a conjuntos de itens, que são organizados em uma matriz de avaliações R , de tamanho $m \times n$, considerando m usuários e n itens. A entrada r_{x_i, y_j} corresponde à avaliação feita pelo usuário x_i sobre o item y_j . O principal objetivo da fatoração de matrizes é decompor a matriz de ratings R em duas matrizes aproximadas menores, X e Y , que correspondem a k fatores latentes para os m usuários e os n itens, respectivamente (Equação 3.7).

$$\hat{R} = XY^T = \begin{pmatrix} x_{11} & x_{12} & x_{13} & \cdots & x_{1k} \\ x_{21} & x_{22} & x_{23} & \cdots & x_{2k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & x_{m3} & \cdots & x_{mk} \end{pmatrix} \times \begin{pmatrix} y_{11} & y_{12} & \cdots & y_{1n} \\ y_{21} & y_{22} & \cdots & y_{2n} \\ y_{31} & y_{32} & \cdots & y_{3n} \\ \vdots & \vdots & \ddots & \vdots \\ y_{k1} & y_{k2} & \cdots & y_{kn} \end{pmatrix} \quad (3.7)$$

Considerando que o objetivo é prever as avaliações desconhecidas da matriz R , é possível usar as matrizes inferidas X e Y para calcular uma avaliação aproximada. A avaliação prevista $\hat{r}_{x_i, y_j}$ é dada pelo produto cruzado do vetor de fatores dos usuários e o vetor de fatores dos itens, como mostrado na Equação 3.8, tal que $\vec{x}_i$ corresponde aos fatores inferidos para o usuário x_i e $\vec{y}_j$ aos fatores inferidos para o item y_j .

$$\hat{r}_{x_i, y_j} = \vec{x}_i \cdot (\vec{y}_j)^T \quad (3.8)$$

Para obter os vetores de fatores, o sistema deve minimizar a Equação 3.9, utilizando dados treinados (conjunto S) e algum algoritmo de otimização, tal como *Gradiente Descendente Estocástico* ([BOTTOU, 2012](#)) ou *Mínimos Quadrados Alternados* ([LAWSON; HANSON, 1995](#)). Com relação ao algoritmo utilizado, os parâmetros k e λ devem ser otimizados. O primeiro parâmetro (k) corresponde ao número de fatores latentes utilizados para modelar os dados de

recomendação. Ele é responsável por deixar o modelo mais simples ou mais complexo, dependendo do quanto de complexidade é necessário para capturar todas as dimensões latentes dos dados de entrada. O segundo parâmetro (λ) é utilizado para dar peso à restrição de regularização para evitar *overfitting*.

$$J = \sum_{(x_i, y_j) \in S} (r_{x_i, y_j} - \vec{x}_i \cdot (\vec{y}_j)^T)^2 + \lambda (\|\vec{x}_i\|^2 + \|\vec{y}_j\|^2) \quad (3.9)$$

As técnicas de fatoração de matrizes não são exclusivas para sistemas de recomendação tradicionais, embora várias modificações são necessárias para utilizá-los em dados multidimensionais (usuários $\times$ itens $\times$ contextos). A principal ideia é utilizar tensores para representarem todas as dimensões do problema e então executar alguma técnica de decomposição de tensores.

Existem muitas formas de fazer isso, como Decomposição Tucker (TUCKER, 1966) e Decomposição Canônica (STEGEMAN; SIDIROPOULOS, 2007). O primeiro método permite decompor um tensor de ordem N em um de menor dimensão e N matrizes. Por outro lado, Decomposição Canônica decompõe um tensor como uma soma de outros tensores, que são mais simples do que o original. Esses métodos, em suas formas originais, não são adequados para o domínio de recomendação, já que eles não apresentam bons resultados em cenários esparsos. Dessa forma, Karatzoglou *et al.* (2010) propuseram um modelo genérico que utiliza Decomposição Tucker apenas nos dados observados, levando a boa precisão, apesar da baixa escalabilidade. Acar *et al.* (2011) propuseram o algoritmo CP-WOPT que utiliza Decomposição Canônica também nas avaliações observadas. Embora Acar *et al.* (2011) demonstraram que CP-WOPT teve resultados melhores que vários outros métodos, existem outros algoritmos que, baseados em interações de pares, são mais simples e mais fáceis para implementar. Aggarwal (2016) descreve esse algoritmo, utilizado e citado neste trabalho como **CAMF**, em seu livro de sistemas de recomendação.

A ideia central dos algoritmos de interações de pares é decompor o tensor de avaliações R em n matrizes de fatores: $U_1, U_2, U_3, \dots, U_n$, tal que U_1 e U_2 representam os fatores de usuários e os fatores de itens, respectivamente, e U_a ($3 \leq a \leq n$) representam fatores contextuais da variável de contexto a . Essas novas matrizes são então utilizadas para fazer a previsão das avaliações $\hat{r}_{i_1, \dots, i_n}$, em que i_1 representa um dado usuário, i_2 um dado item, e $i_3, \dots, i_n$ são informações contextuais, como mostrado na Equação 3.10.

$$\hat{r}_{i_1, \dots, i_n} = \sum_{a < b \leq n} [U_a(U_b)^T]_{i_a i_b} \quad (3.10)$$

Cada matriz de fatores U_a é do tamanho $s_a \times k$, tal que s_a representa o número de valores únicos da variável a e k representa o número de fatores. Para obter essas matrizes, a seguinte equação deve ser minimizada (Equação 3.11) utilizando algum algoritmo de otimização. O

parâmetro λ é utilizado para regularização e o conjunto S consiste em avaliações específicas.

$$J = \sum_{(i_1, \dots, i_n) \in S} (r_{i_1, \dots, i_n} - \sum_{a < b \leq n} [U_a(U_b)^T]_{i_a i_b})^2 + \lambda \sum_{a=1}^n \|U_a\|^2 \quad (3.11)$$

Dessa forma, na etapa de recomendação podem ser utilizados diversos algoritmos de recomendação sensíveis ao contexto. Neste trabalho, são utilizados algoritmos baseados no método de vizinhança, ou seja, que utilizam o IBCF. Além disso, é utilizado um algoritmo de fatoração de matrizes sensível ao contexto (CAMF) baseado no MF.

Como mencionado anteriormente, o contexto pode estar associado ao item da recomendação, ao usuário ou à própria aplicação. Neste trabalho de doutorado foram propostas duas abordagens para considerar o contexto: 1) “*Contexto das Reviews*”; ou 2) “*Contexto dos Itens*”. Na primeira maneira, os contextos extraídos de uma *review* escrita pelo usuário U_{ex} sobre o item I_{ex} são atribuídos ao par $U_{ex}-I_{ex}$. Ou seja, o contexto extraído da *review* é diretamente relacionado ao usuário (que escreveu a *review*) e ao item (que está sendo avaliado). Na segunda abordagem, os contextos extraídos de todas as *reviews* escritas sobre o item I_{ex} são atribuídos a todos os pares $U_{I_{ex}}-I_{ex}$ em que $U_{I_{ex}}$ é o conjunto de todos os usuários que avaliaram o item I_{ex} . Ou seja, dessa forma é considerado que o contexto está relacionado com o item, não importante qual usuário está o avaliando. É possível dizer que por meio dessa abordagem o contexto utilizado na recomendação é enriquecido.

A saída do método de recomendação sensível ao contexto baseado em mineração de textos e de opiniões (*CARM-TOM*) são as recomendações geradas pelos sistemas de recomendação sensíveis ao contexto utilizando uma das três técnicas de extração de contexto propostas neste trabalho: *CIET.5_{embed}*, *RulesContext* e *CEOM*. Essas técnicas podem ser utilizadas individualmente ou em conjunto para possibilitar a combinação dos contextos extraídos. A avaliação individual dessas técnicas assim como da combinação das mesmas será apresentada no Capítulo 4.

3.5 Considerações Finais

Neste capítulo foi apresentado o método de recomendação sensível ao contexto proposto neste trabalho, o *CARM-TOM*. Esse método tem o propósito de executar desde o pré-processamento de *reviews* até os sistemas de recomendação sensíveis ao contexto, gerando recomendações utilizando informações contextuais extraídas por técnicas de extração de contexto. As técnicas de extração de contexto consideradas foram propostas também neste trabalho: 1) *CIET.5_{embed}*, que é baseada em word-embeddings; 2) *RulesContext*, baseada em regras de associação; e 3) *CEOM*, baseada em mineração de opiniões.

No próximo capítulo, será apresentada a avaliação desta proposta. Além disso, serão apresentados experimentos realizados para a construção de baselines que foram utilizados na avaliação. As técnicas de extração de contexto foram avaliadas individualmente e também

de forma combinada. Dessa forma, foi feita a análise de qual delas extrai informações mais relevantes, que podem melhorar o desempenho da recomendação, e de que maneira a combinação das mesmas melhora ou não os resultados.

AVALIAÇÃO EXPERIMENTAL

Neste capítulo é apresentada a avaliação experimental do método de recomendação proposto neste trabalho (*CARM-TOM*) e também das técnicas de extração de contexto propostas (*CIET.5_{embed}*, *RulesContext*, *CEOM*). O capítulo está organizado como:

- Na **Seção 4.1**, é apresentada a base de dados utilizada para a avaliação. Trata-se de uma base de *reviews* de usuários que passou por uma preparação e limpeza resultando em 3 diferentes bases.
- Na **Seção 4.2**, são apresentadas as ferramentas e métodos utilizados como apoio ao trabalho.
- Na **Seção 4.3**, são listadas as configurações experimentais utilizadas na avaliação assim como a medida utilizada para de avaliação.
- Na **Seção 4.4**, são discutidos os experimentos realizados para a construção de *baselines* para o domínio de *reviews*. Os resultados desses experimentos foram publicados no relatório técnico [Sundermann, Domingues e Rezende \(2018\)](#). Nesse trabalho foram utilizados os algoritmos sensíveis ao contexto baseados no algoritmo *Item-based Collaborative Filtering* (IBCF).
- Na **Seção 4.5**, a técnica de extração de contexto *CIET.5_{embed}*, proposta neste trabalho, é avaliada. Nesses experimentos foram utilizados os algoritmos de recomendação baseados no IBCF e como *baselines* os métodos avaliados na Seção 4.4, além do próprio IBCF. Os resultados foram publicados no artigo [Sundermann et al. \(2018\)](#).
- Na **Seção 4.6**, é detalhada a avaliação da técnica *RulesContext*, juntamente com a técnica *CIET.5_{embed}*, utilizando o algoritmo CAMF (algoritmo de recomendação sensível ao contexto e baseado em fatoração de matrizes). Nesse trabalho foi considerado o algoritmo MF como *baseline*. Os resultados desse trabalho foram publicados no artigo [Sundermann et al. \(2019b\)](#) o qual foi convidado para ser estendido e submetido para o journal *Expert Systems* (Online ISSN: 1468-0394).

- Na **Seção 4.7**, foi avaliada a técnica *CEOM* no domínio de restaurantes. Nessa avaliação foram utilizados tanto os algoritmos de recomendação baseados no IBCF, quanto o algoritmo CAMF. Como *baselines* foram considerados o IBCF e o MF. Os resultados desse trabalho estão sendo incorporados na extensão do artigo [Sundermann et al. \(2019b\)](#).
- Na **Seção 4.8**, as técnicas de extração de contexto propostas neste trabalho de doutorado são avaliadas no domínio de restaurantes. Além disso, as combinações entre as técnicas também são avaliadas e analisadas. Os resultados desses experimentos complementarão as análises do artigo de extensão citado no item anterior.
- Por fim, na **Seção 4.9**, são apresentadas as considerações finais do capítulo de avaliação experimental.

4.1 Base de *reviews* utilizada na avaliação experimental

Nos experimentos realizados para a avaliação do método e técnicas propostas neste trabalho, foi utilizada a base de *reviews* RecSys, que é uma base disponibilizada para o desafio de sistemas de recomendação ACM RecSysChallenge 2013 proposto para a customização de recomendações para os usuários da Yelp¹. A Yelp é uma companhia multinacional localizada em São Francisco, California (USA), que possui aplicações e um website no qual usuários podem avaliar estabelecimentos comerciais. Em cada avaliação (*review*) é possível deixar uma nota, de 1 a 5 estrelas e também escrever um texto explicando a opinião sobre o estabelecimento.

A base de dados RecSys consiste originalmente de 11537 itens (estabelecimentos comerciais), 45980 usuários e 229901 *reviews*. Entretanto, após o primeiro passo da proposta deste trabalho (pré-processamento), o conjunto de dados foi reduzido a 2510 itens, 16086 usuários e 130632 *reviews*. A coleção de textos resultante é composta por 130632 documentos (conteúdos textuais das *reviews*). Os textos também passaram pela etapa de normalização do método proposto (*CARM-TOM*). Dessa forma, foi gerado um novo conjunto de textos, *YelpNormal*, formado pelos textos normalizados. Esse conjunto é derivado da base *Yelp*.

Além da base completa, foi separada uma parte dela referente ao domínio de restaurantes. Essa seleção foi feita visando a mineração de opiniões. A partir da base de restaurantes foi feita uma filtragem excluindo usuários e itens com menos de 20 *reviews*. Dessa forma, a base ficou com 10017 *reviews*, 360 usuários e 398 itens. Esse subconjunto da base *Yelp* é referenciado neste trabalho como *YelpRest*.

4.2 Ferramentas e Métodos Utilizados

Nesta seção são apresentados os métodos e as ferramentas que foram utilizados para a avaliação experimental. A seguir são descritas as ferramentas utilizadas para a normalização dos

¹ <<https://www.yelp.com>>

textos (Etapa 2 do método *CARM-TOM*), para a extração de entidades nomeadas (construção do *baseline EntityAsContext*) e para a construção de hierarquia de tópicos (construção do *baseline TopicsAsContext*).

- **Normalização:** na condução dos experimento foi utilizada a ferramenta de normalização *TextExpansion*² (apresentada na Seção 3.2 do Capítulo 3) para normalizar os textos das *reviews*.
- **Reconhecimento de Entidades Nomeadas:** o reconhecedor de entidades nomeadas *Stanford NER*³ (FINKEL; GRENAGER; MANNING, 2005), mais conhecido como *CRF-Classifer*, foi usado para a extração de entidades nomeadas. *Stanford NER* oferece uma implementação geral da sequência de modelos *linear chain conditional random field* (CRF) (LAFFERTY; MCCALLUM; PEREIRA, 2001). Esse reconhecedor de entidades nomeadas inclui um modelo de quatro classes treinado para a conferência em aprendizado de língua natural (CoNLL) que classifica entidades nomeadas nas seguintes classes: Local, Pessoa, Organização e Misc. *Stanford NER* também inclui um modelo de sete classes, treinado para o MUC (*Message Understanding Conferences*) que reconhece as classes Tempo, Local, Organização, Pessoa, Dinheiro, Porcentagem e Data; e um modelo de três classes treinado em ambos conjuntos de dados CoNLL e MUC para a intersecção dessas classes. Para este trabalho foi utilizado o modelo de sete classes para extrair entidades nomeadas de *reviews*.
- **Construção de Hierarquia de Tópicos:** na construção de hierarquia de tópicos, foi utilizada a ferramenta LIHC⁴ para o agrupamento hierárquico dos itens, que implementa o método *LUPI-based Incremental Hierarchical Clustering* (MARCACINI; REZENDE, 2013). Essa ferramenta é parte da Torch, que é um conjunto de ferramentas de suporte para o agrupamento de textos e construção de hierarquias de tópicos.

Os sistemas de recomendação baseados no IBCF (apresentados na Seção 2.1, do Capítulo 2) e utilizados neste trabalho, são parte do *framework* de recomendação CARSLibrary⁵:

- **IBCF**, sistema de recomendação baseado em vizinhos mais próximos e que não utiliza contexto;
- **C. Reduction** (ADOMAVICIUS *et al.*, 2005) (Abordagem de pré-filtragem contextual): a informação contextual é usada como um rótulo para filtrar os dados que não correspondem a um contexto específico. Os dados restantes (dados contextualizados) são usados para gerar o modelo de recomendação.
- **Weight PoF e Filter PoF** (PANNIELLO; GORGOGNONE, 2012) (Abordagens de pós filtragem contextual): as informações contextuais são utilizadas para reordenar ou filtrar as recomendações. Primeiramente, o algoritmo tradicional é aplicado para construir o modelo de recomendação, ignorando a informação contextual. Então, a probabilidade dos usuários

² <<http://lasid.sor.ufscar.br/expansion/static/index.html>>

³ <<https://nlp.stanford.edu/software/CRF-NER.shtml>>

⁴ <http://sites.labc.icmc.usp.br/torch/doceng2013>

⁵ <<https://github.com/maddomingues/CARSLibrary>>

acessarem os itens dado o contexto é calculada e multiplicada pelos scores dos itens, para reordenar as recomendações (*Weight PoF*) ou para ser usada como limiar para filtrá-las (*Filter PoF*).

Neste trabalho, esses sistemas baseados no IBCF, consideram, assim como o próprio IBCF, valores de avaliação binários, isto é, se o item foi avaliado (um) ou não (zero).

Além dos sistemas de recomendação baseados no IBCF, também foram utilizados os sistemas de recomendação baseados em fatoração de matrizes, o CAMF (sensível ao contexto) e o MF (que não utiliza contexto), ambos também apresentados na Seção 2.1. Esses algoritmos consideram os valores reais de avaliação, isto é, as notas dadas pelos usuários sobre os itens.

Para técnica *CIET.5_{embed}* foi utilizado o tokenizador NLTK Tokenize API⁶ para identificar e dividir as sentenças dos textos. Também foram utilizados a base da Wikipedia em inglês (dump of 2017-09-26⁷) como uma fonte externa de documentos e o Word2Vec (utilizando o modelo de aprendizado CBOW (MIKOLOV; LE; SUTSKEVER, 2013)) como ferramenta de modelagem de textos⁸, com janela de 5 palavras (valor *default*) utilizando 5 épocas (valor *default*) para treino e frequências mínimas de 10 documentos externos e 1 para textos internos (para garantir o escaneamento completo das palavras dos documentos analisados).

4.3 Configuração Experimental e Medida de Avaliação

Um sistema de recomendação pode ser avaliado de forma *online*, *offline* ou por meio de estudos de usuários. Neste trabalho, foi executada uma avaliação *offline*, baseada no protocolo *All But One* (BREESE; HECKERMAN; KADIE, 1998) com validação cruzada de 10 *folds*, em que o conjunto de transações é particionado em 10 subconjuntos. Para cada *fold*, $n - 1$ desses subconjuntos são utilizados para treino e o restante para teste. O conjunto de treino T_r é usado para construir o modelo de recomendação. Para cada usuário do conjunto de teste T_e , um item é escondido como um conjunto único H , e os itens restantes representam o conjunto de itens observáveis O utilizados na recomendação.

Baseado na validação cruzada com 10 *folds*, é calculada a *Mean Average Precision* para 10 recomendações ($MAP@10$) e, para comparar dois algoritmos de recomendação, é aplicado o teste *t-student* com um nível de confiança de 95%.

Para gerar o conjunto das top 10 recomendações utilizando o algoritmo IBCF, são considerados os 4 itens mais similares. Para o algoritmo *Filter PoF* foi utilizado um valor de limiar para filtrar as recomendações igual a 0,1.

Os algoritmos MF e CAMF foram executados 20 vezes, variando os valores de k e λ .

⁶ <<http://www.nltk.org/api/nltk.tokenize.html>>

⁷ <<https://dumps.wikimedia.org/enwiki/>>

⁸ <<https://radimrehurek.com/gensim/models/word2vec.html>>

Como já explicado anteriormente, o parâmetro k refere-se aos fatores que são aprendidos a partir dos dados. Para explorar a qualidade das recomendações usando representações de diferentes dimensionalidades, foram utilizados os valores: $k = 5, 10, 50$ e 100 . Já o parâmetro λ é utilizado para evitar o *overfitting*, dessa forma os valores utilizados foram $\lambda = 1, 10, 100, 150$ e 200 , definidos de forma empírica.

4.4 Avaliação Experimental de Métodos de Extração de Contexto para a Construção de Baselines para o Domínio de Reviews

Nestes experimentos, foram avaliados dois métodos propostos na literatura que utilizam mineração de textos para extração de contexto. Esses métodos foram apresentados no Capítulo 2, na Seção 2.3. Domingues *et al.* (2014b) propuseram extrair entidades nomeadas de conteúdos textuais de páginas da Web para utilizar as entidades como informações contextuais em sistemas de recomendação sensíveis ao contexto (método *EntityAsContext*). Sundermann *et al.* (2016) propuseram construir hierarquias de tópicos de páginas da Web utilizando informações privilegiadas, para extrair tópicos dessas hierarquias e utilizar os tópicos como informações contextuais em sistemas de recomendação (método *TopicAsContext*).

No método *TopicAsContext*, duas representações de textos são obtidas, uma chamada de informação técnica e outra chamada de informação privilegiada. Ambas as representações são inseridas no método LIHC para a construção de hierarquias de tópicos. Com isso, agrupamentos das representações são gerados de forma separada, e a combinação deles é feita no agrupamento consensual, no qual um peso, chamado de fator de combinação α , é atribuído para a informação privilegiada. Após a construção das hierarquias de tópicos, os tópicos dos grupos e subgrupos são extraídos. Essa extração é feita seguindo a configuração de granularidade $\{x, y\}$, que determina que os tópicos extraídos devem ter no mínimo x documentos associados a eles e no máximo y documentos. Com essa estratégia de extração, é possível extrair tópicos mais específicos e tópicos mais gerais variando os valores de x e y .

O objetivo desta avaliação experimental foi explorar e avaliar esses métodos de extração de contexto no domínio de *reviews*. Essa exploração permitiu a construção de *baselines* para serem utilizados em trabalhos em desenvolvimento na área de sistemas de recomendação sensíveis ao contexto.

Foi utilizado para os experimentos, o método de recomendação sensível ao contexto, *CARM-TOM*, proposto neste trabalho. Dessa forma, foram seguidos os mesmos passos do método descrito no Capítulo 3, pág. 83. Os resultados desta seção foram publicados no relatório técnico Sundermann, Domingues e Rezende (2018).

4.4.1 Extração de Informações Contextuais

Os métodos *EntityAsContext* e *TopicAsContext* foram utilizados para extrair informações contextuais da base de *reviews Yelp* e de sua derivada *YelpNormal*, ambas apresentadas na Seção 4.1. Para o método *EntityAsContext* as classes de entidades nomeadas reconhecidas foram tempo, data, local e organização. Para avaliar a importância de cada classe como contexto, as seguintes combinações foram consideradas:

1. Data
2. Data e local
3. Data, local e organização
4. Data, local e tempo
5. Data, organização
6. Data, organização e tempo
7. Data e tempo
8. Local
9. Local e organização
10. Local, organização e tempo
11. Local e tempo
12. Organização
13. Organização e tempo
14. Tempo
15. Data, local, organização e tempo

Portanto, para o método *EntityAsContext*, **15 variações de experimentos** foram executadas tanto para a base de *reviews Yelp* quanto para sua derivada *YelpNormal*. Para o método *TopicAsContext*, foram construídas 3 hierarquias de tópicos variando o valor do fator de combinação $\alpha = 0$, $\alpha = 0,5$ e $\alpha = 1$ e considerando as 15 combinações de entidades nomeadas como informação privilegiada. Para a extração de tópicos, foram consideradas as seguintes configurações de granularidade $\{2, 7\}$, $\{10, 50\}$, $\{15, 20\}$ e $\{50, 100\}$. Dessa forma, **180 combinações de experimentos** foram executadas para o método *TopicAsContext*, utilizando as bases *Yelp* e *YelpNormal* (15 combinações de entidades nomeadas, 3 valores de α e 4 configurações de granularidade).

Nas Tabelas 12 e 13, são apresentados, de forma resumida, o número de cada informação contextual e o número de transações (usuário x item x contexto), para *EntityAsContext* e *TopicAsContext* respectivamente. Para o método *EntityAsContext*, cada informação contextual é referida pelas classes das entidades (*Data*, *Local*, *Org* e *Tempo*) unidas por *underline* (por exemplo, *Data_Tempo*, *Data_Org*, etc). Para o método *TopicAsContext*, as classes das entidades utilizadas como informações privilegiadas são unidas por *underline* com o fator de combinação e a configuração de granularidade. Por exemplo, *DataOrg_05_15_20* representa a informação con-

textual (tópicos) extraída da hierarquia de tópicos construída utilizando as classes de entidades nomeadas *Data* e *Organização* como informação privilegiada, o fator de combinação $\alpha = 0,5$ e a configuração de granularidade $\{15, 20\}$.

Tabela 12 – Características da informação contextual extraída pelo método *EntityAsContext*.

Contexto	Yelp		YelpNormal	
	#Contextos	#Transações	#Contextos	#Transações
Data	2630	33411	2722	41025
Data Local	12227	113872	7258	92674
Data_Local_Org	38003	188295	12024	113108
Data_Local_Tempo	13221	129443	7832	105559
Data_Org	30257	108627	8030	61739
Data_Org_Tempo	31242	124196	8604	74624
Data_Tempo	3628	48983	3296	51649
Local	9617	80431	4543	51649
Local_Org	35425	154891	9311	33603
Local_Org_Tempo	36431	170467	9893	84972
Local_Tempo	10637	96039	5125	64538
Org	27666	75219	5312	20714
Org_Tempo	28674	90794	5894	33603
Tempo	1022	15578	582	12889
Data_Local_Org_Tempo	38986	203866	12598	125993

Tabela 13 – Características da informação contextual extraída pelo método *TopicAsContext*.

Contexto	Yelp		YelpNormal	
	#Contextos	#Transações	#Contextos	#Transações
Data_0_15_20	266	5440	253	4969
DataLocal_05_15_20	383	7421	321	6247
DataLocalOrg_1_15_20	277	4967	291	5430
DataLocalTempo_0_15_20	311	6007	317	6234
DataOrg_0_15_20	321	6148	281	5452
DataOrgTempo_0_15_20	275	5358	292	5668
DataTempo_0_15_20	307	5811	270	6428
Local_1_15_20	272	4935	296	5382
LocalOrg_0_15_20	312	5768	298	5650
LocalOrgTempo_0_15_20	316	5943	267	5235
LocalTempo_0_15_20	297	5553	281	5452
Org_05_15_20	313	6090	250	4942
OrgTempo_0_15_20	298	5589	302	5833
Tempo_0_15_20	243	5055	222	4394
DataLocalOrgTempo_0_15_20	299	5623	314	6077

O *baseline* considerado nesta avaliação foi o algoritmo de recomendação *Item-Based Collaborative Filtering* (IBCF), apresentado no Capítulo 3, Seção 3.4.

4.4.2 Resultados com algoritmos baseados no IBCF

Os resultados são agrupados em dois conjuntos, “*Contexto das Reviews*” e “*Contexto dos itens*”, como explicado no Capítulo 3, Seção 3.4. Para o *baseline* IBCF, foi obtido como resultado o valor de *MAP@10* igual a 0,0215.

Os resultados são apresentados em quatro subseções, representando os dois métodos de extração de contexto e as duas formas de utilizar contexto. Dessa forma, na Subseção 4.4.2.1, são apresentados os resultados do método *EntityAsContext* considerando o “Contexto das Reviews”. Os resultados do mesmo método, porém considerando o “Contexto dos Itens”, são apresentados na Subseção 4.4.2.2. Finalmente, os resultados do método “*TopicAsContext*”, considerando o “Contexto das Reviews” e “Contexto dos Itens”, são apresentados nas Subseções 4.4.2.3 e 4.4.2.4, respectivamente.

4.4.2.1 *EntityAsContext* considerando o “Contexto das Reviews”

Na Tabela 14, são apresentados os valores de *MAP@10* para o método *EntityAsContext* considerando o “Contexto das Reviews”. Pode-se notar que para a base *Yelp*, os melhores resultados foram apresentados utilizando o contexto *Local_Org*. Ou seja, a combinação das classes de entidades nomeadas “Local” e “Organização” geraram recomendações mais precisas para os algoritmos *C. Reduction* e *Weight PoF*. Já para o algoritmo *Filter PoF*, o melhor resultado foi apresentado utilizando o contexto *Org* (classe “Organização”).

Tabela 14 – Comparando os algoritmos de recomendação sensíveis ao contexto, utilizando os contextos do método *EntityAsContext*, com o *baseline* IBCF (considerando “Contexto das Reviews”). Os valores que são estatisticamente diferentes que o *baseline* ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o *baseline* ficam em **negrito**.

Context	IBCF	Yelp			YelpNormal		
		<i>C. Reduction</i>	<i>Weight PoF</i>	<i>Filter PoF</i>	<i>C. Reduction.</i>	<i>Weight PoF</i>	<i>Filter PoF</i>
Data	0,0215	0,0041*	0,0042*	0,0013*	0,0037*	0,0037*	0,0013*
Data_Local	0,0215	0,0115*	0,0118*	0,0013*	0,0108*	0,0110*	0,0012*
Data_Local_Org	0,0215	0,0141*	0,0145*	0,0018*	0,0134*	0,0135*	0,0014*
Data_Local_Tempo	0,0215	0,0118*	0,0119*	0,0013*	0,0109*	0,0111*	0,0012*
Data_Org	0,0215	0,0115*	0,0120*	0,0036*	0,0072*	0,0075*	0,0026*
Data_Org_Tempo	0,0215	0,0112*	0,0115*	0,0033*	0,0076*	0,0078*	0,0014*
Data_Tempo	0,0215	0,0025*	0,0026*	0,0020*	0,0027*	0,0029*	0,0016*
Local	0,0215	0,0095*	0,0096*	0,0018*	0,0052*	0,0055*	0,0016*
Local_Org	0,0215	0,0143*	0,0147*	0,0023*	0,0048*	0,0051*	0,0029*
Local_Org_Tempo	0,0215	0,0135*	0,0140*	0,0021*	0,0094*	0,0095*	0,0016*
Local_Tempo	0,0215	0,0100*	0,0104*	0,0012*	0,0070*	0,0071*	0,0010*
Org	0,0215	0,0098*	0,0113*	0,0068*	0,0027*	0,0031*	0,0026*
Org_Tempo	0,0215	0,0102*	0,0111*	0,0054*	0,0048*	0,0051*	0,0029*
Tempo	0,0215	0,0032*	0,0032*	0,0026*	0,0025*	0,0029*	0,0012*
Data_Local_Org_Tempo	0,0215	0,0141*	0,0143*	0,0016*	0,0136*	0,0138*	0,0019*

Para o conjunto de dados *YelpNormal*, os algoritmos *C. Reduction* e *Weight PoF* apresentaram os melhores resultados utilizando o contexto *Data_Local_Org* (combinação das classes “Data”, “Local” e “Organização”). Enquanto que o algoritmo *Filter PoF* apresenta melhor desempenho considerando os contextos *Org* e *Org_Tempo*.

No geral, os resultados dos algoritmos sensíveis ao contexto utilizando entidades nomeadas como “Contexto das Reviews” foram inferiores aos resultados do IBCF com significância

estatística. Então, os contextos extraídos por esse método não melhoraram o desempenho da recomendação para esse conjunto de dados. Além disso, os resultados para a base *YelpNormal* foram inferiores, o que mostra que a técnica de normalização ou o normalizador utilizado não melhoraram os resultados da recomendação.

Analisando as características dos contextos extraídos, Tabela 12, nota-se que o maior número de transações ou contexto por item pode ter influenciado os melhores resultados para os algoritmos *C. Reduction* e *Weight PoF*. Para o algoritmo *Filter PoF*, não foi observada relação entre as características da Tabela 12 com os resultados do algoritmo.

4.4.2.2 EntityAsContext considerando o “Contexto dos Itens”

Para os experimentos considerando “Contexto dos Itens” foi utilizada apenas a base *Yelp*, sem a normalização, já que a base *YelpNormal* apresentou resultados inferiores nos experimentos da seção anterior. Os resultados desses experimentos são apresentados na Tabela 15. Foi analisado que considerando o contexto como “Contexto dos Itens” o desempenho da recomendação melhorou de forma significativa. Todos esses resultados foram melhores que os resultados dos experimentos anteriores, quando foi considerado o “Contexto das Reviews”.

Os algoritmos *C. Reduction* e *Weight PoF* apresentaram melhores resultados comparando com o IBCF com significância estatística. Os melhores resultados para os 3 algoritmos foram apresentados considerando o contexto *Tempo*.

Tabela 15 – Comparando os algoritmos de recomendação sensíveis ao contexto, utilizando os contextos extraídos pelo método *EntityAsContext*, com o *baseline* IBCF (considerando “Contexto dos Itens”). Para a apresentação dos resultados em tabelas foi utilizado o seguinte padrão: os valores que são estatisticamente diferentes que o *baseline* ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o *baseline* ficam em **negrito**.

Contexto	IBCF	<i>C. Reduction</i>	<i>Weight PoF</i>	<i>Filter PoF</i>
Data	0,0215	0,0386*	0,0400*	0,0047*
Data_Local	0,0215	0,0352*	0,0369*	0,0053*
Data_Local_Org	0,0215	0,0354*	0,0367*	0,0057*
Data_Local_Tempo	0,0215	0,0354*	0,0369*	0,0010*
Data_Org	0,0215	0,0348*	0,0362*	0,0052*
Data_Org_Tempo	0,0215	0,0346*	0,0362*	0,0053*
Data_Tempo	0,0215	0,0379*	0,0389*	0,0061*
Local	0,0215	0,0357*	0,0374*	0,0054*
Local_Org	0,0215	0,0353*	0,0366*	0,0059*
Local_Org_Tempo	0,0215	0,0349*	0,0363*	0,0057*
Local_Tempo	0,0215	0,0350*	0,0365*	0,0053*
Org	0,0215	0,0350*	0,0368*	0,0055*
Org_Tempo	0,0215	0,0348*	0,0363*	0,0051*
Tempo	0,0215	0,0394*	0,0409*	0,0077*
Data_Local_Org_Tempo	0,0215	0,0352*	0,0367*	0,0055*

Nas Figuras 23, 24 e 25, os resultados do método *EntityAsContext* são exibidos em três gráficos. No primeiro gráfico da primeira figura, são apresentados os resultados para o conjunto

de dados *Yelp* utilizando o “*Contexto das Reviews*”. No segundo gráfico da segunda fase são apresentados os resultados para o conjunto de dados *YelpNormal* utilizando o “*Contexto das Reviews*”. E por fim, no terceiro gráfico são apresentados os resultados para o conjunto de dados *Yelp* utilizando o “*Contexto dos Itens*”. Analisando os gráficos, foi observado o que foi discutido anteriormente: os resultados para o conjunto de dados *Yelp* foram melhores que os resultados para o conjunto de dados *YelpNormal* e os resultados utilizando o “*Contexto dos Itens*” foram melhores que o resultados considerando o “*Contexto das Reviews*”.

Figura 23 – Gráfico com os resultados do método *EntityAsContext* utilizando a base *Yelp* e considerando o “*Contexto das Reviews*”

4.4.2.3 TopicAsContext considerando “Contextos das Reviews”

Os resultados do método *TopicAsContext*, Tabela 16, foram no geral inferiores que os resultados do método *EntityAsContext* e, portanto, inferiores ao IBCF com significância estatística. A normalização dos textos melhorou os resultados em poucos casos, como observado na Tabela 17.

Em alguns casos os resultados com o conjunto de dados *YelpNormal* foram inferiores, com significância estatística. Os casos que não tiveram diferença estatística representam uma

Figura 24 – Gráfico com os resultados do método *EntityAsContext* utilizando a base *YelpNormal* e considerando o *Contexto das Reviews*

Tabela 16 – Comparando os algoritmos de recomendação sensíveis ao contexto, utilizando os contextos do método *TopicAsContext*, com o *baseline* IBCF (considerando “*Contextos das Reviews*”). Para a apresentação dos resultados em tabelas foi utilizado o seguinte padrão: os valores que são estatisticamente diferentes que o *baseline* ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o *baseline* ficam em **negrito**.

Context	IBCF	Yelp			YelpNormal		
		<i>C. Reduction</i>	<i>Weight PoF</i>	<i>Filter PoF</i>	<i>C. Reduction</i>	<i>Weight PoF</i>	<i>Filter PoF</i>
Data_0_15_20	0,0215	0,0029*	0,0029*	0,0002*	0,0070*	0,0070*	0,0046*
DataLocal_05_15_20	0,0215	0,0017*	0,0017*	0,0036*	0,0024*	0,0024*	0,0032*
DataLocalOrg_1_15_20	0,0215	0,0042*	0,0042*	0,0081*	0,0038*	0,0038*	0,0043*
DataLocalTempo_0_15_20	0,0215	0,0034*	0,0034*	0,0033*	0,0021*	0,0021*	0,0042*
DataOrg_0_15_20	0,0215	0,0041*	0,0041*	0,0043*	0,0041*	0,0051*	0,0019*
DataOrgTempo_0_15_20	0,0215	0,0024*	0,0026*	0,0051*	0,0026*	0,0026*	0,0027*
DataTempo_0_15_20	0,0215	0,0041*	0,0041*	0,0021*	0,0015*	0,0015*	0,0040*
Local_1_15_20	0,0215	0,0008*	0,0008*	0,0015*	0,0013*	0,0013*	0,0019*
LocalOrg_0_15_20	0,0215	0,0020*	0,0020*	0,0034*	0,0059*	0,0075*	0,0061*
LocalOrgTempo_0_15_20	0,0215	0,0045*	0,0056*	0,0022*	0,0017*	0,0017*	0,0014*
LocalTempo_0_15_20	0,0215	0,0019*	0,0019*	0,0037*	0,0003*	0,0003*	0,0003*
Org_05_15_20	0,0215	0,0017*	0,0017*	0,0014*	0,0048*	0,0049*	0,0016*
OrgTempo_0_15_20	0,0215	0,0047*	0,0047*	0,0039*	0,0034*	0,0034*	0,0017*
Tempo_0_15_20	0,0215	0,0045*	0,0045*	0,0003*	0,0003*	0,0003*	0,0003*
DataLocalOrgTempo_0_15_20	0,0215	0,0004*	0,0004*	0,0004*	0,0021*	0,0021*	0,0027*

Tabela 17 – Número de casos nos quais os resultados para o conjunto de dados *YelpNormal* foram piores, melhores ou equivalentes aos resultados do conjunto *Yelp*.

	<i>C. Reduction</i>	<i>Weight PoF</i>	<i>Filter PoF</i>
Piores	7 (4%)	8 (4%)	13 (7%)
Melhores	10 (6%)	8 (4%)	10 (6%)
Equivalentes	163 (90%)	164 (91%)	157 (87%)

Figura 25 – Gráfico com os resultados do método *EntityAsContext* utilizando a base *Yelp* e considerando o *Contexto dos Itens*

média de 90% dos casos. Dessa forma, pode-se concluir que a normalização dos textos não resultou em melhorias significantes para a recomendação.

Na Tabela 18, os resultados foram resumidos exibindo as melhores configurações para cada informação privilegiada. Para o conjunto de dados *Yelp*, o algoritmo *C. Reduction* apresentou os melhores resultados utilizando o contexto *DataLocal_1_15_20*. O algoritmo *Weight PoF* foi melhor utilizando o contexto *OrgTempo_05_15_20*. Por fim, o algoritmo *Filter PoF* apresentou o melhor resultado dentre todos os casos com o contexto *LocalTempo_0_2_7*.

Para o conjunto de dados *YelpNormal*, o algoritmo *C. Reduction* apresentou o melhor resultado utilizando o contexto *DataLocalOrgTempo_1_15_20*. Diferentemente, os algoritmos *Weight PoF* e *Filter PoF* tiveram o melhor desempenho utilizando os contextos *LocalOrg_0_15_20* e *DataLocalOrgTempo_1_15_20*, respectivamente.

Analisando as características da Tabela 13, não é possível concluir se há uma relação direta entre elas e os resultados, isto é, os números de contextos ou transações aparentemente não influenciaram nos valores da medida MAP.

Tabela 18 – As melhores configurações e valores de $MAP@10$ (entre parênteses) para cada informação privilegiada, considerando o método *TopicAsContext* e o “Contexto das Reviews”.

Informação Privilegiada	Yelp			YelpNormal		
	<i>C. Reduction</i>	<i>Weight PoF</i>	<i>Filter PoF</i>	<i>C. Reduction</i>	<i>Weight PoF</i>	<i>Filter PoF</i>
Data	0_15_20 (0,0029)	0_15_20 (0,0029)	0_10_50 (0,0033)	0_15_20 (0,0070)	0_15_20 (0,0070)	0_15_20 (0,0046)
DataLocal	1_15_20 (0,0086)	1_15_20 (0,0086)	05_15_20 (0,0036)	0_10_50 (0,0038)	0_10_50 (0,0037)	1_50_100 (0,0055)
DataLocal_Org	0_2_7 (0,0044)	05_15_20 (0,0058)	1_15_20 (0,0081)	05_15_20 (0,0047)	05_15_20 (0,0047)	1_2_7 (0,0056)
DataLocalTempo	0_15_20 (0,0034)	0_15_20 (0,0034)	05_2_7 (0,0044)	0_2_7 (0,0050)	0_2_7 (0,0051)	0_15_20 (0,0042)
DataOrg	0_15_20 (0,0041)	0_15_20 (0,0041)	05_15_20 (0,0055)	0_50_100 1_2_7 (0,0065)	0_50_100 1_2_7 (0,0066)	1_2_7 (0,0093)
DataOrgTempo	1_15_20 (0,0051)	1_15_20 (0,0053)	1_15_20 (0,0078)	1_50_100 (0,0044)	1_50_100 (0,0044)	1_15_20 (0,0045)
DataTempo	1_15_20 (0,0061)	1_15_20 (0,0060)	05_50_100 (0,0044)	05_15_20 (0,0070)	05_15_20 (0,0070)	05_15_20 (0,0073)
Local	0_15_20 (0,0033)	0_15_20 05_50_100 (0,0033)	1_10_50 (0,0058)	0_10_50 (0,0032)	0_10_50 (0,0032)	0_2_7 (0,0026)
LocalOrg	1_15_20 (0,0057)	1_15_20 (0,0057)	1_2_7 (0,0038)	0_15_20 (0,0059)	0_15_20 (0,0075)	0_15_20 (0,0061)
LocalOrgTempo	0_2_7 (0,0046)	0_15_20 (0,0056)	0_2_7 (0,0048)	05_15_20 (0,0058)	05_15_20 (0,0058)	1_15_20 (0,0037)
LocalTempo	0_2_7 (0,0051)	0_2_7 (0,0051)	0_2_7 (0,0096)	0_2_7 (0,0052)	0_2_7 (0,0052)	1_15_20 (0,0053)
Org	05_50_100 (0,0053)	05_50_100 (0,0057)	05_50_100 (0,0059)	05_15_20 (0,0048)	05_15_20 (0,0049)	05_2_7 1_15_20 (0,0055)
OrgTempo	05_15_20 (0,0074)	05_15_20 (0,0087)	05_15_20 (0,0080)	1_10_50 (0,0045)	1_15_20 (0,0056)	1_15_20 (0,0060)
Tempo	0_15_20 (0,0045)	0_15_20 (0,0045)	05_15_20 (0,0026)	0_50_100 (0,0038)	0_50_100 (0,0039)	05_15_20 (0,0029)
DataLocalOrgTempo	1_10_50 (0,0051)	1_10_50 (0,0051)	0_2_7 (0,0078)	1_15_20 (0,0072)	1_15_20 (0,0072)	1_15_20 (0,0095)

4.4.2.4 TopicAsContext considerando o “Contexto dos Itens”

Neste caso, o conjunto de dados *YelpNormal* não foi considerado, já que a normalização dos textos não trouxe melhoras consideráveis para os resultados. De forma similar ao método *EntityAsContext*, considerando os contextos extraídos pelo método *TopicAsContext* como “Contexto dos Itens” os resultados foram melhores, principalmente para os algoritmos *C. Reduction* e *Weight PoF* (Tabela 19).

Em todos os casos os algoritmos *C. Reduction* e *Weight PoF* foram melhores ou equivalentes ao IBCF. Com relação ao algoritmo *Filter PoF*, seus resultados foram inferiores que os resultados do IBCF, com significância estatística, em todos os casos.

Na Tabela 20, são apresentadas as melhores configurações para cada informação privilegiada. Para o algoritmo *C. Reduction*, o melhor resultado foi obtido utilizando o contexto *DataLocalOrgTempo_0_15_20*. Para o algoritmo *Weight PoF*, o contexto *Org_05_15_20* foi o

Tabela 19 – Comparando os algoritmos de recomendação, utilizando contextos do método *TopicAsContext*, com o *baseline* IBCF (considerando o “*Contexto dos Itens*”). Para a apresentação dos resultados em tabelas foi utilizado o seguinte padrão: os valores que são estatisticamente diferentes que o *baseline* ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o *baseline* ficam em **negrito**.

Contexto	IBCF	C. Reduction	Weight PoF	Filter PoF
Data_0_15_20	0,0215	0,0272*	0,0296*	0,0041*
DataLocal_05_15_20	0,0215	0,0261*	0,0279*	0,0094*
DataLocalOrg_1_15_20	0,0215	0,0284*	0,0310*	0,0087*
DataLocalTempo_0_15_20	0,0215	0,0267*	0,0290*	0,0081*
DataOrg_0_15_20	0,0215	0,0287*	0,0310*	0,0096*
DataOrgTempo_0_15_20	0,0215	0,0271*	0,0299*	0,0061*
DataTempo_0_15_20	0,0215	0,0265*	0,0287*	0,0082*
Local_1_15_20	0,0215	0,0259*	0,0280*	0,0107*
LocalOrg_0_15_20	0,0215	0,0261*	0,0289*	0,0078*
LocalOrgTempo_0_15_20	0,0215	0,0259*	0,0286*	0,0104*
LocalTempo_0_15_20	0,0215	0,0253*	0,0276*	0,0051*
Org_05_15_20	0,0215	0,0285*	0,0321*	0,0079*
OrgTempo_0_15_20	0,0215	0,0286*	0,0314*	0,0037*
Tempo_0_15_20	0,0215	0,0258*	0,0284*	0,0029*
DataLocalOrgTempo_0_15_20	0,0215	0,0301*	0,0301*	0,0020*

que gerou os melhores resultados. Para o algoritmo *Filter PoF*, o melhor resultado foi obtido utilizando o contexto *LocalOrg_0_2_7*.

Tabela 20 – As melhores configurações e valores de *MAP@10* (entre parênteses) para cada informação privilegiada, considerando o método *TopicAsContext* e o “*Contexto dos Itens*”.

Informação Privilegiada	C. Reduction	Weight PoF	Filter PoF
Data	0_15_20 (0,0272)	0_15_20 (0,0296)	1_15_20 (0,0067)
DataLocal	05_15_20 (0,0261)	05_15_20 (0,0279)	05_15_20 (0,0094)
DataLocalOrg	1_15_20 (0,0284)	1_15_20 (0,0310)	05_2_7 (0,0106)
DataLocalTempo	0_15_20 (0,0267)	0_15_20 (0,0290)	1_15_20 (0,0098)
DataOrg	0_15_20 (0,0287)	0_15_20 (0,0310)	1_2_7 (0,0113)
DataOrgTempo	0_15_20 (0,0271)	0_15_20 (0,0299)	05_2_7 (0,0099)
DataTempo	0_15_20 (0,0265)	0_15_20 (0,0287)	0_2_7 (0,0091)
Local	1_15_20 (0,0259)	1_15_20 (0,0280)	1_15_20 (0,0107)
LocalOrg	1_15_20 (0,0262)	0_15_20 (0,0289)	0_2_7 (0,0134)
LocalOrgTempo	0_2_7 (0,0259)	0_2_7 (0,0286)	0_2_7 (0,0104)
LocalTempo	0_15_20 (0,0253)	0_15_20 (0,0276)	0_2_7 (0,0089)
Org	05_15_20 (0,0285)	05_15_20 (0,0321)	1_2_7 (0,0121)
OrgTempo	0_15_20 (0,0286)	0_15_20 (0,0314)	1_2_7 (0,0109)
Tempo	0_15_20 (0,0258)	0_15_20 (0,0284)	0_2_7 (0,0072)
DataLocalOrgTempo	0_15_20 (0,0301)	0_15_20 (0,0301)	0_2_7 (0,0094)

Nas Figuras 26, 27 e 28, alguns dos melhores resultados do método *TopicAsContext*

são apresentados em três gráficos. O primeiro gráfico mostra os resultados para o conjunto de dados *Yelp* utilizando o “*Contexto das Reviews*”. O segundo gráfico mostra os resultados para o conjunto de dados *YelpNormal* utilizando o “*Contexto das Reviews*”. Por fim, no terceiro gráfico estão os resultados para o conjunto de dados *Yelp* utilizando o “*Contexto dos Itens*”. Analisando os gráficos, nota-se que os resultados para o conjunto de dados *Yelp* foram melhores que os resultados do conjunto de dados *YelpNormal* e os resultados utilizando o “*Contexto dos Itens*” foram melhores que os resultados do “*Contexto das Reviews*”.

Figura 26 – Gráfico com alguns dos melhores resultados do método *TopicAsContext* utilizando a base *Yelp* e considerando o “*Contexto das Reviews*”

4.5 Avaliação Experimental da Técnica $CIET.5_{embed}$ com algoritmos baseados no IBCF

O objetivo dos experimentos apresentados nesta seção, publicados em [Sundermann et al. \(2018\)](#), é avaliar o método de recomendação sensível ao contexto proposto (*CARM-TOM*) analisando o impacto do uso da informação contextual extraída pela técnica $CIET.5_{embed}$. Para esse objetivo, os resultados da proposta foram comparados com os resultados de três *baselines*: IBCF, *TopicAsContext* e *EntityAsContext*.

Figura 27 – Gráfico com alguns dos melhores resultados do método *TopicAsContext* utilizando a base *YelpNormal* e considerando o “Contexto das Reviews”

4.5.1 Extração de Informações Contextuais

A base de dados *Yelp* passou pela extração de contexto utilizando a técnica *CIET.5_{embed}*. Para o limiar da técnica foram utilizados os valores 0,25, 0,50 e 1.0 e para o tamanho dos contextos foram considerados os valores 1, 2, 3, 4, 5 e 10. Esses valores foram selecionados como os melhores valores a partir de experimentos preliminares.

No total, foram utilizadas **18 configurações diferentes** (3 valores de limiar e tamanhos de contexto). Cada informação contextual é referida como *Tamanho_Limiar* (por exemplo, o tipo do contexto *1_025* representa o contexto com 1 palavra que foi extraído considerando o valor de limiar igual a 0,25). Na Tabela 21, são apresentados o número de cada informação contextual e o número de transações (usuário x item x contexto).

4.5.2 Resultados

Os resultados estão agrupados em dois conjuntos, “Contexto das Reviews” e “Contexto dos Itens”. Os resultados das 18 variações dos experimentos foram comparados com os 3 *baselines*.

4.5.2.1 Contexto das Reviews

Para o *baseline* IBCF, que não utiliza contexto, o valor de *MAP@10* obtido como resultado foi igual a 0,0215. Na Seção 4.4, foi analisado que para o *baseline* “EntityAsCon-

Figura 28 – Gráfico com alguns dos melhores resultados do método *TopicAsContext* utilizando a base *Yelp* e considerando o “Contexto dos Itens”

Tabela 21 – Características da informação contextual extraída pela técnica $CIET.5_{embed}$

Contexto	#Contextos	#Transações
1_025	1097	129478
1_05	5800	533800
1_1	1086	129462
2_025	592	130030
2_05	4297	357309
2_1	3877	122446
3_025	407	130406
3_05	2377	127177
3_1	7475	109260
4_025	292	130475
4_05	1581	128782
4_1	11122	89672
5_025	1125	129215
5_05	3433	125068
10_025	981	129605
10_05	3351	123964
10_1	1785	4252

text”, os melhores resultados foram apresentados pelo contexto “*Local_Org*”, com valores de *MAP@10* iguais a 0,0143 (*C. Reduction*), 0,0147 (*Weight PoF*) e 0,0023 (*Filter PoF*). Com relação ao *baseline* “*TopicAsContext*”, os melhores valores foram apresentados pelo contexto “*DataLocal_1_15_20*”, isto é, considerando a informação privilegiada “*Data e Local*”, fator de combinação $\alpha = 1$ e configuração de granularidade $\{15, 20\}$, com valores de *MAP@10* iguais a 0,0086 (*C. Reduction*), 0,0086 (*Weight PoF*) e 0,0028 (*Filter PoF*).

Na Tabela 22, são apresentados os resultados da proposta, comparando com o IBCF, que é o *baseline* que apresentou melhores resultados. O algoritmo *Filter PoF* foi o único algoritmo que

apresentou resultados inferiores ao IBCF com diferença estatisticamente significativa em todos os casos. Os melhores resultados para os algoritmos *C. Reduction* e *Weight PoF* foram apresentados utilizando os contextos *1_05* e *3_025*. No primeiro caso, o algoritmo *Weight PoF* apresentou um resultado superior ao IBCF com significância estatística. Na Figura 29, os resultados para “*Contexto das Reviews*” estão resumidos em um gráfico com os melhores resultados de cada método.

Tabela 22 – Comparando o método *CARM-TOM*, utilizando os contextos extraídos pela técnica *CIET.5_{embed}*, considerando *MAP@10*. Os valores que são estatisticamente diferentes que o *baseline* ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o *baseline* ficam em **negrito**.

Contexto	IBCF	C. Reduction	Weight PoF	Filter PoF
1_025	0,0215	0,0209	0,0210	0,0027*
1_05	0,0215	0,0221	0,0226*	0,0029*
1_1	0,0215	0,0214	0,0215	0,0025*
2_025	0,0215	0,0208	0,0209	0,0029*
2_05	0,0215	0,0220	0,0224	0,0029*
2_1	0,0215	0,0201	0,0201	0,0036*
3_025	0,0215	0,0224	0,0226	0,0028*
3_05	0,0215	0,0204	0,0205	0,0030*
3_1	0,0215	0,0180*	0,0180*	0,0024*
4_025	0,0215	0,0221	0,0222	0,0028*
4_05	0,0215	0,0223	0,0222	0,0030*
4_1	0,0215	0,0144*	0,0144*	0,0046*
5_025	0,0215	0,0207	0,0210	0,0022
5_05	0,0215	0,0205	0,0205	0,0032*
5_1	0,0215	0,0091*	0,0093*	0,0008*
10_025	0,0215	0,0221	0,0223	0,0028*
10_05	0,0215	0,0202	0,0203	0,0032*
10_1	0,0215	0,0058*	0,0058*	0,0058*

Figura 29 – Os melhores valores de *MAP@10* para “*Contexto das Reviews*”

No geral, pode-se observar, analisando os resultados e os dados da Tabela 21, que o número de contextos (coluna “#Contextos”) não influencia nos resultados. O que pode influenciar os resultados é o número de transações (usuário x item x contexto - coluna “#Transações”).

4.5.2.2 Contexto dos Itens

Foi observado que o contexto dos itens melhorou muito o desempenho da recomendação. Todos esses resultados foram melhores que os resultados anteriores, quando foi considerado o contexto das *reviews*. Pode-se dizer que os contextos dos itens enriquece a informação contextual usada pelo sistema.

Na Seção 4.4, foi analisado que o método *EntityAsContext*, a classe “*Tempo*” apresentou os melhores resultados para todos os algoritmos, com valores de *MAP@10* iguais a 0,0394 (*C. Reduction*), 0,0409 (*Weight PoF*) e 0,0077 (*Filter PoF*). Com relação ao método *TopicAsContext*, os algoritmos sensíveis ao contexto apresentaram melhores resultados considerando o contexto “*Org_05_15_20*”, com valores de *MAP@10* iguais a 0,0285 (*C. Reduction*), 0,0321 (*Weight PoF*) e 0,0079 (*Filter PoF*).

Na Tabela 23, são apresentados os melhores resultados da proposta comparando com o *baseline* (*Entidades - Tempo*). A configuração de informação contextual *10_1* promoveu os melhores resultados da recomendação, comparando com o *baseline*. Pode-se observar que os tamanhos de contexto 4 e 10 foram os melhores tamanhos nesses experimentos. Na Figura 30, os resultados do “*Contexto dos Itens*” são resumidos, apresentando um gráfico com os melhores resultados para cada método.

Tabela 23 – Comparando a técnica CIET.5_{embed} com o *baseline* *EntityAsContext*. Os valores que são estatisticamente diferentes que o *baseline* ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o *baseline* ficam em **negrito**.

<i>EntityAsContext</i>			
Contexto	<i>C. Reduction</i>	<i>Weight PoF</i>	<i>Filter PoF</i>
Tempo	0,0394	0,0409	0,0077
CIET.5 _{embed}			
Contexto	<i>C. Reduction</i>	<i>Weight PoF</i>	<i>Filter PoF</i>
4_025	0,0359	0,0375	0,0060
4_05	0,0357	0,0368	0,0049*
4_1	0,0346*	0,0365*	0,0053*
10_05	0,0363	0,0380	0,0047*
10_1	0,0503*	0,0882*	0,1249*

Em resumo, a proposta deste doutorado apresentou um desempenho melhor comparando com os *baselines*. Analisando os resultados e Tabela 21, os melhores resultados estão relacionados ao grande número de transações (coluna “#Transações”), o que justifica a melhora nos resultados quando considerando o “*Contexto dos Itens*”. O algoritmo *Filter PoF* foi o único que não apresentou resultados satisfatórios na maioria dos casos, o que pode ser justificado pelo valor de limiar de corte do algoritmo (0,1).

Figura 30 – Os melhores valores de $MAP@10$ para o “Contexto dos Itens”

4.6 Avaliação Experimental das Técnicas $CIET.5_{embed}$ e RulesContext com o algoritmo CAMF

Nesta avaliação foram conduzidos dois experimentos diferentes. No primeiro experimento, o método *CARM-TOM* é avaliado, com as técnicas $CIET.5_{embed}$ e *RulesContext*, e comparado com o algoritmo MF. O objetivo dessa avaliação foi demonstrar o impacto do uso da informação contextual extraída pelas técnicas $CIET.5_{embed}$ e *RulesContext* no sistema de recomendação CAMF. No segundo experimento, foi utilizado o método *CARM-TOM* para comparar a técnica $CIET.5_{embed}$ com a técnica *RulesContext*, com o objetivo de identificar qual técnica de extração de contexto gera os melhores resultados para a recomendação.

4.6.1 Extração de Informações Contextuais

A base de dados passou pela extração de contexto utilizando as técnicas $CIET.5_{embed}$ e *RulesContext*. Com relação à técnica $CIET.5_{embed}$, foram selecionados os valores de limiar iguais a 0.25, 0.50 e 1.0 e tamanhos de contexto iguais a 4 e 10, devido aos bons resultados dos experimentos anteriores. No total, foram utilizadas **6 configurações diferentes** (3 valores de limiar e 2 tamanhos de contexto). Cada informação contextual é referida como explicado na seção anterior.

Com relação a técnica *RulesContext*, foi utilizado um valor de suporte igual a 10%, um valor de confiança igual a 50% e valores da medida de informação mútua (MI) de 50% e

75%. Além disso, foram selecionados conjuntos das regras com melhor classificação de acordo com essa medida. Dessa forma, foram selecionados conjuntos com as top 5, 10 e 20 regras, totalizando **6 combinações**. Cada informação contextual é referida como $MI_NroDeRegras$ (por exemplo, o tipo de contexto 50_5 representa as top 5 regras (contextos) extraídas utilizando MI igual a 50). Na Tabela 24, são apresentados o número de cada informação contextual e o número de transações (usuário $\times$ item $\times$ contexto).

Tabela 24 – Características dos contextos extraídos pela técnica $RulesContext$

Contexto	#Contextos	#Transações
50_5	10942	641850
50_10	21907	1227952
50_20	42626	2224927
50_50	47458	4366839
50_100	176110	6896866
75_5	10062	559690
75_10	18320	888111
75_20	31877	1317127
75_50	63711	2161854
75_100	102382	3102823

4.6.2 Resultados “Contexto dos Itens”

Nesta seção, primeiramente são apresentados os resultados do método proposto ($CARM-TOM$) com a técnica $CIET.5_{embed}$, e então, com a técnica $RulesContext$. Ambas são comparadas com o *baseline* MF. Por fim, são comparados os resultados das técnicas $CIET.5_{embed}$ e $RulesContext$. Nestes experimentos foram considerados os contextos dos itens, já que apresentaram melhores resultados no experimentos anteriores.

Na Tabela 25, pode-se observar que, em geral, os resultados foram muito satisfatórios comparados com os resultados do *baseline* MF. A informação contextual 10_1 apresentou os melhores resultados. Entretanto, o contexto 10_025 apresentou o melhor valor de $MAP@10$ para os parâmetros k igual a 5 e λ igual a 150. Deve ser enfatizado que essa combinação de parâmetros resultou nos melhores resultados para esses experimentos em particular. Na Figura 31, é apresentado um gráfico com os resultados da técnica $CIET.5_{embed}$.

Os resultados da proposta, com os contextos extraídos pela técnica $RulesContext$, são apresentados na Tabela 26. Novamente os resultados foram muito satisfatórios. Pode-se notar que os contextos extraídos com o corte da MI igual a 50% apresentaram os melhores resultados na maioria dos casos, com o maior valor de MAP apresentado pelo contexto 50_20 .

Foi analisado que utilizar um número maior de regras como contexto e, além disso, selecionar as melhores delas (de acordo com a medida MI), pode gerar bons resultados. Complementando, os parâmetros λ igual a 150 e K igual a 5, apresentaram os melhores resultados, como nos experimentos anteriores. Na Figure 32, é apresentado um gráfico com os resultados da técnica $RulesContext$.

Tabela 25 – Comparando os resultados de ($MAP@10$) do algoritmo de recomendação CAMF utilizando os contextos extraídos pela técnica $CIET.5_{embed}$, com os resultados do *baseline* MF. Os valores que são estatisticamente diferentes que o *baseline* ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o *baseline* ficam em **negrito**.

Parâmetros		Baseline	4_025	4_05	4_1	10_025	10_05	10_1
λ	k							
1	5	0,0015	0,0014	0,0015	0,0009	0,0015	0,0019	0,0028
	10	0,0012	0,0014	0,0016	0,0014	0,0013	0,0009	0,0036*
	50	0,0012	0,0010	0,0017	0,0008	0,0014	0,0013	0,0082*
	100	0,0012	0,0011	0,0010	0,0005*	0,0015	0,0010	0,0083*
10	5	0,0016	0,0030*	0,0040*	0,0018	0,0031*	0,0034*	0,0082*
	10	0,0016	0,0028*	0,0034*	0,0035*	0,0040*	0,0034*	0,0077*
	50	0,0015	0,0034*	0,0040*	0,0012*	0,0038*	0,0033*	0,0079*
	100	0,0014	0,0022*	0,0019*	0,0007*	0,0015	0,0014	0,0083*
100	5	0,0017	0,0040*	0,0036*	0,0019	0,0039*	0,0035*	0,0079*
	10	0,0019	0,0044*	0,0049*	0,0036*	0,0059*	0,0058*	0,0084*
	50	0,0020	0,0034*	0,0041*	0,0026*	0,0045*	0,0051*	0,0080*
	100	0,0019	0,0032*	0,0030*	0,0007*	0,0027*	0,0031*	0,0082*
150	5	0,0017	0,0068*	0,0079*	0,0020*	0,0093*	0,0087*	0,0080*
	10	0,0019	0,0046*	0,0033*	0,0036*	0,0053*	0,0053*	0,0077*
	50	0,0020	0,0058*	0,0045*	0,0015*	0,0046*	0,0038*	0,0081*
	100	0,0019	0,0028*	0,0022	0,0007*	0,0025	0,0024	0,0081*
200	5	0,0033	0,0074*	0,0062*	0,0021*	0,0080*	0,0061*	0,0082*
	10	0,0031	0,0038*	0,0034	0,0039*	0,0034	0,0042*	0,0069*
	50	0,0024	0,0035*	0,0058*	0,0029	0,0045*	0,0066*	0,0080*
	100	0,0023	0,0030*	0,0032*	0,0007*	0,0026*	0,0031*	0,0081*

Tabela 26 – Comparando os resultados ($MAP@10$) do algoritmo de recomendação sensível ao contexto CAMF utilizando os contextos extraídos pela técnica *RulesContext*, com os resultados do *baseline* MF. Os valores que são estatisticamente diferentes que o *baseline* ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o *baseline* ficam em **negrito**.

Parâmetros		Baseline	50_5	50_10	50_20	75_5	75_10	75_20
λ	k							
1	5	0,0015	0,0016	0,0024	0,0020	0,0019	0,0022	0,0019
	10	0,0012	0,0021*	0,0018*	0,0019	0,0016	0,0017	0,0021*
	50	0,0012	0,0016*	0,0021*	0,0017	0,0015*	0,0020*	0,0019*
	100	0,0012	0,0021*	0,0021*	0,0023*	0,0015	0,0015	0,0017
10	5	0,0016	0,0090*	0,0115*	0,0116*	0,0033*	0,0085*	0,0082*
	10	0,0016	0,0040*	0,0050*	0,0055*	0,0062*	0,0048*	0,0033*
	50	0,0015	0,0040*	0,0028*	0,0009*	0,0035*	0,0036*	0,0019
	100	0,0014	0,0030*	0,0015	0,0014	0,0023*	0,0015	0,0016
100	5	0,0017	0,0014	0,0009*	0,0037*	0,0026	0,0017	0,0015
	10	0,0019	0,0049*	0,0076*	0,0070*	0,0038*	0,0047*	0,0057*
	50	0,0020	0,0072*	0,0079*	0,0084*	0,0057*	0,0093*	0,0105*
	100	0,0019	0,0024*	0,0029*	0,0014*	0,0019	0,0014*	0,0015*
150	5	0,0017	0,0117*	0,0114*	0,0065*	0,0103*	0,0111*	0,0107*
	10	0,0019	0,0056*	0,0060*	0,0055*	0,0039*	0,0040*	0,0045*
	50	0,0020	0,0018	0,0026*	0,0022	0,0015*	0,0008*	0,0005*
	100	0,0019	0,0026*	0,0026*	0,0018*	0,0017*	0,0014*	0,0015
200	5	0,0033	0,0014*	0,0011*	0,0036	0,0018	0,0017*	0,0016*
	10	0,0031	0,0059*	0,0074*	0,0072*	0,0039*	0,0045*	0,0063*
	50	0,0024	0,0072*	0,0075*	0,0119*	0,0059*	0,0023	0,0110*
	100	0,0023	0,0028	0,0029*	0,0029	0,0017	0,0014*	0,0017*

Analisando os parâmetros utilizados nos experimentos, foi observado que para a técnica $CIET.5_{embed}$, os melhores resultados foram obtidos com o tamanho de contexto igual a 10 e o limiar igual a 25%. Para a técnica *RulesContext*, o corte da MI que gerou os melhores resultados foi 50%, isto é, utilizando um número maior de regras e selecionando as melhores. Com relação aos parâmetros da fatoração de matrizes, os melhores resultados foram obtidos com k igual a 5 e

Figura 31 – Valores de MAP@10 para a técnica $CIET.5_{embed}$

λ igual a 150, ou seja, um modelo com baixa complexidade e com uma valor relativamente alto do parâmetro que controla o *overfitting*.

Por fim, na Figura 33 é apresentada a comparação entre as técnicas $CIET.5_{embed}$ e $RulesContext$. São comparados os melhores valores de MAP@10 (eixo vertical) variando os valores de λ e k (eixo horizontal). Na maioria dos casos, a técnica $CIET.5_{embed}$ teve um melhor desempenho que a técnica $RulesContext$. Entretanto, nos dois casos, 10_5 e 150_5 , a técnica $RulesContext$ foi superior. Na Figura 33, também é possível observar que o método $CARM-TOM$ com as técnicas de extração de contexto apresentou melhores resultados que o *baseline* MF em todos os casos.

4.7 Avaliação Experimental da Técnica de Extração de Contextos baseada em Mineração de Opiniões no Domínio de Restaurantes

O objetivo dos experimentos apresentados nesta seção é avaliar o método de recomendação sensível ao contexto proposto analisando o impacto do uso da informação contextual extraída pela técnica $CEOM$. Para esse objetivo, os resultados da proposta foram comparados com os resultados do *baseline* IBCF e foram utilizados o “Contexto das reviews”

Figura 32 – Valores de $MAP@10$ para a técnica *RulesContext*

4.7.1 Extração de Informações Contextuais

A base de dados *YelpRest* passou pela extração de contexto utilizando a técnica *CEOM*. Dessa forma, foram extraídos os 7 tipos de contextos apresentados no Capítulo 3, Seção 3.3.3. Na Tabela 21, são apresentados o número de cada informação contextual e o número de transações (usuário x item x contexto).

Tabela 27 – Características da informação contextual extraída pela técnica *CEOM*

Contexto	#Contextos	#Transações
aspectos	11358	1445283
adjetivos	7606	1353427
sentimentos	3	30054
aspectos_adjetivos	73747	3315933
aspectos_sentimentos	14869	1727226
adjetivos_sentimentos	9780	1540518
aspectos_adjetivos_sentimentos	51405	2907271

4.7.2 Resultados com algoritmos baseados no IBCF

Na Tabela 28, são apresentados os resultados da técnica *CEOM* considerando os algoritmos baseados no IBCF e comparando com este *baseline*. Os melhores resultados foram apresentados pelo contexto *aspectos_sentimentos*. Com relação aos algoritmos, o algoritmo *Filter PoF* apresentou o melhor desempenho, seguido do algoritmo *Weight PoF*. Esses resultados são apresentados visualmente no gráfico da Figura 34.

Figura 33 – Comparando os valores de $MAP@10$ entre as técnicas $CIET.5_{embed}$, $RulesContext$ e o $baseline$ MF

Tabela 28 – Comparando os resultados de $MAP@10$ dos algoritmos de recomendação baseados no IBCF utilizando os contextos extraídos pela técnica $CEOM$, com os resultados do $baseline$ IBCF. Os valores que são estatisticamente diferentes que o $baseline$ ($p-value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o $baseline$ ficam em **negrito**

Contexto	IBCF	<i>C. Reduction</i>	<i>Weight PoF</i>	<i>Filter PoF</i>
aspectos	0,0201	0,0261	0,0414*	0,0438*
adjetivos	0,0201	0,0267	0,0402*	0,0435*
sentimentos	0,0201	0,0201	0,0254*	0,0264*
aspectos_adjetivos	0,0201	0,0205	0,0313*	0,0323*
aspectos_sentimentos	0,0201	0,0269	0,0421*	0,0436*
adjetivos_sentimentos	0,0201	0,0266*	0,0408*	0,0403*
aspectos_adjetivos_sentimentos	0,0201	0,0254	0,0428*	0,0406*

Analisando a Tabela 27, os melhores resultados não estão diretamente relacionados com os números altos de contextos ou transações. Entretanto, os valores mais baixos para o contexto “sentimento”, pode estar relacionado ao baixo número de contextos e transações, porém não é comprovado um padrão para os outros tipos de contexto.

4.7.3 Resultados com algoritmos baseados no CAMF

Na Tabela 29, são apresentados os resultados da técnica $CEOM$, considerando o algoritmo CAMF e comparando com o $baseline$ MF. Os parâmetros λ e k foram definidos considerando os melhores resultados dos experimentos anteriores. Assim como os resultados da seção anterior, nesta seção os resultados também foram muito satisfatórios com relação ao $baseline$. Os contextos aspectos_adjetivos_sentimentos e os parâmetros $\lambda = 200$ e $k = 50$ apresentaram os melhores

Figura 34 – Gráfico com os valores de $MAP@10$ da técnica *CEOM* comparando com o *baseline* IBCF

resultados.

Tabela 29 – Comparando os resultados de $MAP@10$ do algoritmo de recomendação CAMF utilizando os contextos extraídos pela técnica *CEOM*, com os resultados do *baseline* MF. Os valores que são estatisticamente diferentes que o *baseline* ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o *baseline* ficam em **negrito**

Parâmetros		CAMF	aspectos	adjetivos	sentimentos	aspectos, adjetivos	aspectos, sentimentos	adjetivos sentimentos	aspectos, adjetivos sentimentos
λ	k								
100	10	0,0084	0,0208*	0,0264*	0,0176*	0,0278*	0,0204*	0,0232*	0,0266*
	50	0,0062	0,0321*	0,0325*	0,0230*	0,0378*	0,0274*	0,0332*	0,0364*
150	10	0,0067	0,0210*	0,0211*	0,0119*	0,0302*	0,0245*	0,0233*	0,0315*
	50	0,0090	0,0053*	0,0042*	0,0061*	0,0023*	0,0028*	0,0038*	0,0039*
200	10	0,0109	0,0162*	0,0197*	0,0139	0,0184*	0,0211*	0,0177*	0,0287*
	50	0,0082	0,0295*	0,0344*	0,0202*	0,0594*	0,0288*	0,0336*	0,0613*

Observando o número de contextos e o número de transações, não foi constatada relação dessas características com os resultados, porém o contexto “sentimentos” apresentou novamente os valores mais baixos de $MAP@10$. Na Figura 35, é apresentado um gráfico com esses valores.

Na próxima seção, são apresentados os resultados das três técnicas de extração de contextos no domínio de restaurantes. Além disso, os contextos são combinados e tais combinações são avaliadas.

Figura 35 – Gráfico com os valores de $MAP@10$ da técnica *CEOM* comparando com o *baseline* MF

4.8 Avaliação experimental das técnicas de extração de contexto no domínio de restaurantes

Na Tabela 30, são apresentados os resultados dos algoritmos baseados no IBCF utilizando o contexto “Tempo” extraído pelo técnica *EntityAsContext* e o contexto *Org_15_20*, extraído pela técnica *TopicAsContext*. Esses contextos foram selecionados devido aos bons resultados apresentados nos experimentes da Seção 4.4.

Tabela 30 – Comparando os resultados de $MAP@10$ dos algoritmos de recomendação baseado no IBCF utilizando os contextos extraídos pelas técnicas *EntityAsContext* e *TopicAsContext*, com os resultados do *baseline* IBCF. Os valores que são estatisticamente diferentes que o *baseline* ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o *baseline* ficam em **negrito**

Contexto	IBCF	C. Reduction	Weight PoF	Filter PoF
Tempo	0,0201	0,0722*	0,0759*	0,0851*
Org_05_15_20	0,0201	0,0181	0,0263*	0,0364*

Os resultados da técnica *CIET.5_{embed}* no domínio de restaurantes (base *YelpRest*) são apresentados na Tabela 31. Comparando esses resultados com os resultados da Tabela 25, nota-se que considerando um domínio específico os resultados foram superiores que os resultados da base *Yelp* (domínio geral). O contexto 10_1 continuou apresentando os melhores resultados, sendo o algoritmo *Filter PoF* o que mostrou melhor desempenho.

Na Tabela 32, são exibidos os resultados da técnica *RulesContext* para o domínio de restaurantes. Os resultados foram muito satisfatórios sendo na maioria dos casos melhores que o

Tabela 31 – Comparando os resultados de $MAP@10$ dos algoritmos de recomendação baseados no IBCF utilizando os contextos extraídos pela técnica $CIET.5_{embed}$, com os resultados do *baseline* IBCF, para a base *YelpRest*. Os valores que são estatisticamente diferentes que o *baseline* ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o *baseline* ficam em **negrito**

Contexto	IBCF	<i>C. Reduction</i>	<i>Weight PoF</i>	<i>Filter PoF</i>
4_025	0,0200	0,0677*	0,0737*	0,0759*
4_05	0,0200	0,0729*	0,0750*	0,0714*
4_1	0,0200	0,0745*	0,0810*	0,0838*
10_025	0,0200	0,0778*	0,0823*	0,0716*
10_05	0,0200	0,0286	0,0298	0,0222
10_1	0,0200	0,0708*	0,1173*	0,2212*

IBCF com significância estatística. O contexto com melhores resultados foi 75_5.

Tabela 32 – Comparando os resultados de $MAP@10$ dos algoritmos de recomendação baseados no IBCF utilizando os contextos extraídos pela técnica *RulesContext*, com os resultados do *baseline* IBCF, para a base *YelpRest*. Os valores que são estatisticamente diferentes que o *baseline* ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o *baseline* ficam em **negrito**

Contexto	IBCF	<i>C. Reduction</i>	<i>Weight PoF</i>	<i>Filter PoF</i>
50_5	0,0200	0,0360*	0,0539*	0,0657*
50_10	0,0200	0,0237	0,0398*	0,0559*
50_20	0,0200	0,0154	0,0225	0,0346*
75_5	0,0200	0,0330	0,0588*	0,0729*
75_10	0,0200	0,0194	0,0194	0,0515*
75_20	0,0200	0,0215	0,0327*	0,0435*

Por fim, na Tabela 33, são apresentados os resultados das combinações dos diferentes contextos, considerando aqueles que levaram aos melhores resultados nos experimentos do domínio de restaurantes. Sendo assim, foram combinados $CIET.5_{embed}$ (10_1) com *RulesContext* (75_5), $CIET.5_{embed}$ (10_1) com *CEOM* (aspectos_adjetivos_sentimentos) e $CIET.5_{embed}$ (10_1) com *CEOM* (aspectos_adjetivos_sentimentos). De acordo com a Tabela 33, a combinação $CIET.5_{embed}$ (10_1) com *RulesContext* (75_5) trouxe melhores resultados para a recomendação de restaurantes.

Tabela 33 – Comparando os resultados de $MAP@10$ dos algoritmos de recomendação baseados no IBCF utilizando as combinações dos contextos extraídos pelas técnicas *CEOM*, $CIET.5_{embed}$ e *RulesContext*, com os resultados do *baseline* IBCF, para a base *YelpRest*. Os valores que são estatisticamente diferentes que o *baseline* ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o *baseline* ficam em **negrito**

Contexto	IBCF	<i>C. Reduction</i>	<i>Weight PoF</i>	<i>Filter PoF</i>
$CIET.5_{embed} + RulesContext$	0,0201	0,0735*	0,1391*	0,3256*
$RulesContext + CEOM$	0,0201	0,0254	0,0644*	0,0882*
$CIET.5_{embed} + CEOM$	0,0201	0,0806*	0,1315*	0,2556*

No gráfico da Figura 36, podem ser observados todos os resultados destes experimentos. A combinação das técnicas $CIET.5_{embed} + RulesContext$ foi a que apresentou os melhores resultados.

Figura 36 – Gráfico com os valores de $MAP@10$ das técnicas e combinações utilizando a base *YelpRest* e o *baseline* IBCF

Com relação ao algoritmo CAMF, baseado no MF, os resultados das técnicas *EntityAsContext* (Tempo) e *TopicAsContext* (Org_05_15_20) são apresentados na Tabela 34, sendo os resultados do contexto Tempo, os melhores.

Tabela 34 – Comparando os resultados de $MAP@10$ do algoritmo de recomendação CAMF utilizando os contextos extraídos pelas técnicas *EntityAsContext* e *TopicAsContext*, com os resultados do *baseline* MF, para a base *YelpRest*. Os valores que são estatisticamente diferentes que o *baseline* ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o *baseline* ficam em **negrito**

Parâmetros		MF	Tempo	Org 05_15_20
λ	k			
100	10	0,0084	0,0818*	0,0310*
	50	0,0062	0,1381*	0,0640*
150	10	0,0067	0,0679*	0,0235*
	50	0,0090	0,0178*	0,0099
200	10	0,0109	0,0877*	0,0185*
	50	0,0082	0,1283*	0,0591*

Na Tabela 35, são listados os resultados da técnica *CIET.5_{embed}* no domínio de restaurantes. O contexto 10_1 apresentou o maior valor de $MAP@10$ desses experimentos, para os parâmetros $\lambda = 100$ e $K=10$. Entretanto, o contexto 4_025 apresentou em média os melhores resultados.

Para a técnica *RulesContext*, os resultados com a base *YelpRest* estão apresentados na Tabela 36, na qual observa-se que o contexto 75_20 obteve os melhores resultados.

A Tabela 37 apresenta os resultados das combinações entre as técnicas de extração de

Tabela 35 – Comparando os resultados de $MAP@10$ do algoritmo de recomendação CAMF utilizando os contextos extraídos pela técnica $CIET.5_{embed}$, com os resultados do *baseline* MF, para a base *YelpRest*. Os valores que são estatisticamente diferentes que o *baseline* ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o *baseline* ficam em **negrito**

Parâmetros		MF	4_025	4_05	4_1	10_025	10_05	10_1
λ	k							
100	10	0,0084	0,0166	0,0103	0,0080	0,0113	0,0118	0,0540*
	50	0,0062	0,0202*	0,0169*	0,0082*	0,0185*	0,0170*	0,0082*
150	10	0,0067	0,0179*	0,0119*	0,0078*	0,0148*	0,0147*	0,0078*
	50	0,0090	0,0091	0,0071	0,0066	0,0071	0,0064*	0,0066
200	10	0,0109	0,0169*	0,0101	0,0078	0,0125	0,0115	0,0078
	50	0,0082	0,0197*	0,0198*	0,0118	0,0168*	0,0148*	0,0118*

Tabela 36 – Comparando os resultados de $MAP@10$ do algoritmo de recomendação CAMF utilizando os contextos extraídos pela técnica *RulesContext*, com os resultados do *baseline* MF, para a base *YelpRest*. Os valores que são estatisticamente diferentes que o *baseline* ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o *baseline* ficam em **negrito**

Parâmetros		MF	50_5	50_10	50_20	75_5	75_10	75_20
λ	k							
100	10	0,0084	0,0135*	0,0163*	0,0214*	0,0176*	0,0202*	0,0240*
	50	0,0062	0,0262*	0,0228*	0,0238*	0,0169*	0,0257*	0,0304*
150	10	0,0067	0,0140*	0,0091*	0,0122*	0,0163*	0,0165*	0,0174*
	50	0,0090	0,0058	0,0045*	0,0027*	0,0052	0,0052	0,0052*
200	10	0,0109	0,0143	0,0120	0,0158	0,0191*	0,0197*	0,0253*
	50	0,0082	0,0157*	0,0301*	0,0205*	0,0261*	0,0260*	0,0186*

contexto. Foram combinados os melhores tipos de contexto extraídos de cada técnica. As combinações foram: *RulesContext* (75_20) com $CIET.5_{embed}$ (4_025), *RulesContext* (75_20) com *CEOM* (Aspectos_Adjetivos_Sentimentos) e $CIET.5_{embed}$ (4_025) com *CEOM* (Aspectos_Adjetivos_Sentimentos). Por meio desses resultados, é possível concluir que a combinação $CIET.5_{embed}$ (4_025) com *CEOM* (Aspectos_Adjetivos_Sentimentos) gerou melhores recomendações.

Tabela 37 – Comparando os resultados de ($MAP@10$) do algoritmo de recomendação CAMF utilizando a combinação dos contextos extraídos pelas técnicas *CEOM*, *RulesContext* e $CIET.5_{embed}$, com os resultados do *baseline* MF, para a base *YelpRest*. Os valores que são estatisticamente diferentes que o *baseline* ($p - value > 0,05$) são apresentados com um asterisco (*) e os valores que são melhores que o *baseline* ficam em **negrito**

Parâmetros		MF	<i>CIET + Rules</i>	<i>CIET + CEOM</i>	<i>Rules + CEOM</i>
λ	k				
100	10	0,0084	0,0072	0,0176*	0,0164*
	50	0,0062	0,0181*	0,0153*	0,0214*
150	10	0,0067	0,0105*	0,0206*	0,0157*
	50	0,0090	0,0045*	0,0177*	0,0051*
200	10	0,0109	0,0111	0,0140	0,0189*
	50	0,0082	0,0237*	0,0144*	0,0193*

No gráfico da Figura 37, são exibidos todos os resultados desses experimentos. Nota-se que a técnica *CEOM* obteve os melhores resultados.

Figura 37 – Gráfico com os valores de $MAP@10$ das técnicas e combinações utilizando a base *YelpRest* e o *baseline MF*

4.9 Considerações finais

Neste capítulo foram apresentadas as avaliações experimentais do método *CARM-TOM* e das técnicas de extração de contextos *CIET.5_{embed}*, *RulesContext* e *CEOM*. Além disso, foi apresentada uma avaliação experimental que resultou na construção de dois *baselines*, o *TopicAsContext* e o *EntityAsContext*.

Nos experimentos foi utilizada a base de *reviews Yelp* e suas derivadas: *YelpNormal*, a qual passou pela etapa de normalização do método *CARM-TOM* e *YelpRest*, parte da base *Yelp* referente ao domínio de restaurantes.

Para a construção do *baseline TopicAsContext* foram realizados 180 experimentos. Já para o *baseline EntityAsContext* foram 15 experimentos. Os experimentos da técnica *CIET.5_{embed}* totalizaram 18, da técnica *RulesContext* totalizaram 6 e foram 7 experimentos para a técnica *CEOM*. Esses números não estão considerando as execuções para os diferentes subconjuntos da base *Yelp*, sendo assim o número de experimentos é ainda maior.

A normalização utilizada neste trabalho não apresentou melhoras no resultado final da recomendação, porém não é possível concluir que a normalização pode afetar de forma negativa a recomendação. Para se ter uma análise completa, como trabalhos futuros, pretende-se realizar experimentos utilizando outros normalizadores.

Dessa forma, na maior parte dos experimentos foi considerada a base *Yelp* e a partir da experimentação da mineração de opinião, passou a ser empregada a base *YelpRest*. Assim, foi

possível avaliar o resultado da recomendação em um domínio específico.

Os algoritmos utilizados fazem parte de dois sub-grupos: os baseados no IBCF (*C. Reduction*, *Weight PoF* e *Filter PoF*) e um algoritmo baseado no MF (CAMF). Além disso, os baselines considerados no decorrer do projeto foram: IBCF, MF, *TopicAsContext* e *EntityAsContext*.

Neste trabalho foram propostas duas formas de considerar o contexto: “*Contexto das Reviews*” e “*Contexto dos Itens*”. A segunda forma apresentou os melhores resultados e, por essa razão, foi considerada na maior parte dos experimentos. Pode-se concluir que o “*Contexto dos Itens*” enriquece a informação contextual do sistema de recomendação.

Os resultados apresentados neste capítulo comprovam que o uso das informações contextuais extraídas pelos métodos automáticos de extração de contextos propostos neste trabalho melhoraram os valores de *MAP@10* dos sistemas de recomendação em comparação com os *baselines* considerados.

CONCLUSÃO

Neste capítulo são apresentadas as conclusões desta tese de doutorado. Para tal, as questões de pesquisa definidas na introdução são retomadas e relacionadas com as contribuições científicas alcançadas durante o desenvolvimento deste trabalho. Na sequência, é apresentada uma síntese dos artigos publicados no período deste doutorado. Por fim, são apresentadas as considerações sobre as limitações ocorridas no desenvolvimento desta tese, bem como as direções para trabalhos futuros.

5.1 Contribuições Científicas

As contribuições deste trabalho estão relacionadas ao propósito geral de avançar as pesquisas da área de sistemas de recomendação sensíveis ao contexto, em especial na extração automática de informações contextuais. Embora exista, na literatura, um esforço para o desenvolvimento de métodos de extração de contexto, ainda há uma carência de métodos automáticos. Além disso, informações de opiniões, em especial baseadas em aspectos, podem agregar aos sistemas de recomendação sensíveis ao contexto informações adicionais relevantes.

As questões de pesquisa apresentadas na introdução desta tese são sintetizadas nesta seção, apresentando os resultados obtidos e as técnicas propostas e desenvolvidas.

Questão Q1: *Abordagens de mineração de textos facilitam o processo de extração de informações contextuais de reviews, assim como o uso de tais informações resulta em recomendações mais precisas?*

Com o objetivo de responder essa questão, foram propostos: (i) método de recomendação sensível ao contexto que envolve desde o pré-processamento das reviews até a geração das recomendações utilizando informações contextuais e/ou de opiniões extraídas por técnicas automáticas. Esse método é chamado de *CARM-TOM (Context-Aware Recommender Method based on Text and Opinion Mining)*; (ii) técnica automática de extração de contexto baseada em

word embeddings, a *CIET.5_{embed}*; e (iii) técnica automática de extração de contexto baseada em regras de associação, a *RulesContext*.

Foram conduzidas avaliações experimentais nas quais o uso das informações extraídas pelas técnicas baseadas em mineração de textos propostas proporcionou ganhos significativos com relação à métrica MAP e aos *baselines* considerados. As avaliações foram realizadas considerando a base *Yelp* de estabelecimentos comerciais de domínio geral, e considerando a base *YelpRest*, que é um subconjunto da *Yelp* que possui apenas estabelecimentos do domínio de restaurantes. Para ambas as bases, os resultados foram muito satisfatórios, sendo que para o domínio específico, em geral, os resultados foram superiores.

Para a técnica *CIET.5_{embed}*, os tipos de contexto que proporcionaram melhores resultados foram os formados por 10 palavras que foram extraídos utilizando limiares iguais a 0.25 (*10_025*) e 1 (*10_1*).

Para a técnica *RulesContext*, considerando a base geral *Yelp*, as regras que representaram as melhores informações contextuais foram as top 20 regras extraídas utilizando um limiar da medida MI igual a 50% (*50_20*). Já para a base *YelpRest*, as melhores regras foram as top 20 extraídas utilizando o limiar de MI igual a 75% (*75_20*).

Questão Q2: *O uso de informações de opiniões baseadas em aspectos extraídas de reviews resulta em recomendações mais precisas?*

Com o objetivo de responder essa questão, foi proposta a técnica automática baseada em mineração de opiniões *CEOM* (*Context Extraction technique based on Opinion Mining*). Essa técnica extrai, de forma automática, informações de opinião baseada em aspectos de *reviews*.

Foram conduzidas avaliações experimentais nas quais o uso das informações extraídas pela técnica baseada em mineração de opinião propostas proporcionou ganhos significativos com relação à métrica MAP e aos *baselines* considerados. A base considerada foi a *YelpRest*, do domínio de restaurantes. Apesar de ter sido considerado uma base de domínio específico para a mineração de opiniões, a técnica *CEOM* pode ser aplicada a diferentes domínios. As informações que, em geral, apresentaram melhores resultados foram *Aspectos_Adjetivos_Sentimentos* e *Aspectos_Sentimentos*.

Questão Q3: *O uso combinado de informações de contexto e de opiniões baseadas em aspectos, ambas extraídas de forma automática de reviews, resulta em recomendações mais precisas?*

Com o objetivo de responder esta questão, foram conduzidas avaliações experimentais nas quais as informações extraídas pelas técnicas propostas foram combinadas e utilizadas nos sistemas de recomendação sensíveis ao contexto. A combinação das informações também proporcionou ganhos significativos com relação à métrica MAP e aos *baselines* considerados. Entretanto, os ganhos são mais visíveis e significativos para as combinações *CIET_RulesContext* e *CIET_CEOM* considerando os algoritmos baseados no IBCF.

A principal inovação deste trabalho está na proposta e avaliação de técnicas automáticas de extração de contexto de *reviews* para sistemas de recomendação sensíveis ao contexto. As propostas *CIET_{embed}* e *RulesContext* consistem em técnicas que utilizam abordagens de mineração de textos para a extração de informações contextuais. Embora o foco deste trabalho seja as *reviews* dos usuários, a informação contextual pode ser extraída de outros tipos de conteúdo textual, como textos de *blogs* e redes sociais. Além disso, não são técnicas sensíveis ao domínio, isto é, podem ser aplicadas a diferentes domínios. O mesmo ocorre com a técnica *CEOM*, pois trata-se de uma técnica de extração de informações de opiniões baseadas em aspectos que é independente do domínio.

5.2 Publicações

Durante o desenvolvimento deste trabalho, as contribuições foram divulgadas por meio de publicação de artigos em periódicos e publicação e apresentação de artigos em conferências. Essas publicações são listadas a seguir, apresentando a relação de cada uma com este trabalho e indicando aquelas que estão diretamente relacionadas às questões de pesquisas estabelecidas.

Artigos publicados em periódicos e anais de conferências

SUNDERMANN C. V., DE PÁDUA R., TONON V. R., DOMINGUES M.A., REZENDE S.O. (2019) A Context-Aware Recommender Method Based on Text Mining. In: Moura Oliveira P., Novais P., Reis L. (eds) Progress in Artificial Intelligence. EPIA 2019. Lecture Notes in Computer Science, vol 11805. Springer, Cham.

Nesse artigo foi publicada a proposta da técnica baseada em regras de associação, a *RulesContext*. A avaliação experimental da técnica assim como os resultados foram descritos no Capítulo 4, Seção 4.6. Esse trabalho está relacionado à questão **Q2** e foi convidado para ser estendido e submetido ao periódico *Expert Systems* (Online ISSN: 1468-0394).

SUNDERMANN, C. V.; DOMINGUES, M. A.; SINOARA, R. A.; MARCACINI, R. M.; REZENDE, S. O.. Using Opinion Mining in Context-Aware Recommender Systems: A Systematic Review. *INFORMATION*, v. 10, p. 42, 2019.

Nesse artigo foi publicado o resultado da revisão sistemática da literatura desenvolvida neste trabalho e apresentado no Capítulo 2, Seção 2.5. Esse artigo está relacionado à questão **Q1**.

DOS SANTOS, F. F.; DOMINGUES, M. A.; SUNDERMANN, C. V.; DE CARVALHO, V. O.; MOURA, M. F.; REZENDE, S. O.. Latent association rule cluster based model to extract topics for classification and recommendation applications. *EXPERT SYSTEMS WITH APPLICATIONS*, v. 112, p. 34-60, 2018.

Nesse artigo é proposto um modelo de tópicos baseado em grupos de regras de associação, LARCM. Esse trabalho foi desenvolvido em parceria com outros pesquisadores. A autora desta tese contribuiu na avaliação do método LARCM, aplicando os tópicos extraídos pelo modelo como contexto em sistemas de recomendação.

SUNDERMANN, C. V.; DOMINGUES, M. A.; CONRADO, M. DA S. ; REZENDE, S. O.. Privileged contextual information for context-aware recommender systems. *Expert Systems with Applications*, v. 57, p. 139-158, 2016.

Nesse artigo são apresentados os métodos de extração de contexto *TopicAsContext* e *EntityAsContext*, assim como a avaliação experimental e os resultados desses métodos. Esse trabalho está relacionado à questão **Q2**.

MANZATO, M. G.; DOMINGUES, M. A.; FORTES, A. C.; SUNDERMANN, C. V.; D'ADDIO, R. M.; CONRADO, M. S.; REZENDE, S. O.; PIMENTEL, M. G. C.. Mining unstructured content for recommender systems: an ensemble approach. *Information Retrieval (Boston)*, v. 1, p. 1-38, 2016.

Nesse artigo é proposto um modelo genérico baseado no aprendizado de conjunto que combina métodos simples de mineração de texto em uma abordagem de pós-processamento. A autora desta tese contribuiu na avaliação experimental da proposta e na escrita do artigo.

TONON, V. R.; SUNDERMANN, C. V.; REZENDE, S. O.. Implementação e avaliação de sistemas de recomendação, tradicional e sensível ao contexto, baseados em técnicas de fatoração de matrizes. In: *XLIV Latin American Computing Conference (CLATG)*, 2018, São Paulo. *XLIV Latin American Computing Conference (CLATG)*, 2018. v. 1. p. 1-10.

Nesse artigo foram publicados os resultados do trabalho de conclusão de curso do aluno de graduação Vítor Tonon, o qual a autora desta tese trabalhou em parceria. Neste trabalho, foram implementados e avaliados os algoritmos baseados em fatoração de matrizes utilizados neste doutorado (**MF** e **CAMF**). Esse trabalho está relacionado às questões **Q2**, **Q3** e **Q4**, já que representa os algoritmos utilizados nas avaliações das propostas.

SUNDERMANN, C. V.; ANTUNES, J.; DOMINGUES, M. A.; REZENDE, S. O.. Exploration of Word Embedding Model to Improve Context-Aware Recommender Systems. In: *2018 IEEE/WIC/ACM International Conference on Web Intelligence (WI)*, 2018, Santiago. *2018 IEEE/WIC/ACM International Conference on Web Intelligence (WI)*, 2018. p. 383.

Nesse artigo foi divulgada e avaliada a técnica CIET.5_{embed}. Os experimentos e resultados referentes a esse trabalho foram apresentados no Capítulo 4, Seção 4.5. Esse trabalho está relacionado à questão Q2.

SANTANA, I. A.; SUNIGA, A.; DONINI, J.; **SUNDERMANN, C. V.**; REZENDE, S. R.; DOMINGUES, M. A.. Transforming Geo-Referenced Data in Contextual Information for Context-Aware Recommender Systems. In: 2018 IEEE/WIC/ACM International Conference on Web Intelligence (WI), 2018, Santiago. 2018 IEEE/WIC/ACM International Conference on Web Intelligence (WI), 2018. p. 528.

Nesse artigo foram divulgados os resultados de um trabalho desenvolvido em parceria com outros pesquisadores. Nesse trabalho, foi proposta a aplicação de técnicas de agrupamento para transformar dados georreferenciados (ou seja, latitude e longitude) em informações contextuais (ou seja, regiões) para alimentar os sistemas contextuais. A autora desta tese contribuiu com parte da proposta e na execução da avaliação experimental.

DOMINGUES, M. A.; **SUNDERMANN, C. V.**; BARROS, F. M. M.; MANZATO, M. G.; PIMENTEL, M. G. C.; REZENDE, S. O.; OLIVEIRA S.. Applying multi-view based metadata in personalized ranking for recommender systems. In: the 30th Annual ACM Symposium, 2015, Salamanca. Proceedings of the 30th Annual ACM Symposium on Applied Computing - SAC '15. New York: ACM Press. p. 1105.

Nesse artigo é proposta uma técnica de extração de metadados que utiliza hierarquias de tópicos extraídas automaticamente de conteúdos textuais, considerando entidades nomeadas como informação privilegiada. Esses metadados resultantes são aplicados em um conjunto de modelos de fatores latentes baseados em *feedback* implícito para melhorar a acurácia da recomendação. A autora desta tese contribuiu para esse trabalho realizando parte da avaliação experimental e da escrita.

SUNDERMANN, C. V.; DOMINGUES, M. A.; MARCACINI, RICARDO M.; REZENDE, S. O.. Combining Privileged Information to Improve Context-Aware Recommender Systems. In: XII Encontro Nacional de Inteligência Artificial e Computacional (ENIAC), 2015, Natal, RN. XII Encontro Nacional de Inteligência Artificial e Computacional (ENIAC), 2015.

Nesse artigo foi proposta uma extensão do método LIHC, no qual é possível considerar mais de um tipo de informação privilegiada na construção das hierarquias de tópicos. Dessa forma foi avaliado o uso dos tópicos extraídos dessas hierarquias como contexto nos sistemas de recomendação.

Resumos publicados

TONON, V. R.; SUNDERMANN, C. V.; REZENDE, S. O.. Estudo e implementação de sistemas de recomendação baseados em técnicas de fatoração de matrizes. In: Simpósio Internacional de Iniciação Científica e Tecnológica da USP, 2017, São Carlos. 25o Simpósio Internacional de Iniciação Científica e Tecnológica da USP, 2017.

Nesse artigo foram divulgados os resultados do trabalho de Iniciação Científica do aluno Vítor Tonon. Esse trabalho representa o início das implementações e avaliações dos algoritmos baseados em fatoração de matrizes (*MF* e *CAMF*). Esse trabalho está relacionado às questões **Q2**, **Q3** e **Q4**, já que representa os algoritmos utilizados nas avaliações das propostas.

Relatórios Técnicos publicados

SUNDERMANN, C. V.; DOMINGUES, M. A. ; REZENDE, S. O. . Exploration of contextual information extraction methods for construction of baselines in the user review domain. 2018. Relatório Técnico - nro 427 - ICMC - Universidade de São Paulo.

Nesse relatório técnico foram divulgados os resultados da avaliação experimental dos baselines *TopicAsContext* e *EntityAsContext* no domínio de reviews de usuários. Esses experimentos e resultados estão descritos no Capítulo 4, Seção 4.4. Esse trabalho está relacionado às questões **Q2**, **Q3** e **Q4**, já que representa os *baselines* utilizados nas avaliações das propostas.

Artigo em preparação

A técnica *CEOM*, os resultados da sua avaliação experimental e os resultados da combinação das técnicas de extração de contexto, serão publicados na extensão do artigo [Sundermann et al. \(2019b\)](#), convidado para ser submetido ao *journal Expert Systems (Online ISSN: 1468-0394)*. Esses experimentos e resultados foram apresentados no Capítulo 4, Seções 4.7 e 4.8. Esse artigo está relacionado às questões de pesquisa **Q3** e **Q4**.

5.3 Limitações e Trabalhos Futuros

Nessa seção são discutidas algumas características e limitações do método e técnicas propostas e das avaliações experimentais realizadas, bem como direções de trabalhos futuros.

Com relação ao método de recomendação sensível ao contexto proposto neste trabalho, *CARM-TOM*, alguns pontos devem ser discutidos. Para o pré-processamento das *reviews* foi considerada uma abordagem de filtragem utilizada em [Chen e Chen \(2014\)](#), porém não foram consideradas outras abordagens. Além disso, para a normalização do texto foi considerada apenas uma ferramenta de normalização, *TextExpansion*. Esse fato não permite a conclusão

sobre a influência positiva ou negativa da normalização dos textos das *reviews* na acurácia das recomendações.

Para a técnica CIET.5_{embed}, uma limitação considerada é o retreino do modelo de *word embeddings* considerando os textos da base de *reviews*. Esse retreino pode ser custoso tanto em termos de processamento quanto em relação a tempo. Essa técnica, dentre as propostas deste doutorado, é a que requer mais processamento dos textos, pois vai desde a separação dos textos em sentenças até o retreino e extração dos contextos considerando o modelo de *word embeddings*. Além de utilizar fontes externas de conhecimento.

A técnica *RulesContext* pode gerar uma quantidade grande de informações contextuais, dependendo do valor de corte da medida MI (*mutual information*) e do número de regras selecionadas. O alto valor de contextos representa um maior processamento dos sistemas de recomendação sensíveis ao contexto.

A técnica *CEOM* foi avaliada no domínio de restaurantes, porém é uma técnica independente de domínio. Dessa forma, é interessante que essa técnica seja avaliada em domínios diversos.

De acordo com os pontos levantados acima, surge a necessidade e/ou possibilidade da realização de alguns trabalhos futuros:

1. consideração de diferentes critérios de filtragem de *reviews* na etapa de pré-processamento;
2. utilização de diferentes abordagens / ferramentas de normalização de textos;
3. técnica CIET.5_{embed} - exploração de diferentes valores de tamanho do contexto e limiar de grau de similaridade;
4. técnica *RulesContext* - exploração de diferentes métricas para a extração das regras de associação;
5. técnica *CEOM*: avaliação dessa técnica em outras bases de reviews, considerando diferentes domínios;
6. avaliação das propostas deste trabalho de doutorado considerando outras bases de *reviews*;
7. utilização de outros algoritmos de recomendação para as avaliações experimentais assim como de outros *baselines*.

REFERÊNCIAS

- ABADI, M. J.; LUCERI, L.; HASSAN, M.; CHOU, C. T.; NICOLI, M. A collaborative approach to heading estimation for smartphone-based pdr indoor localisation. In: **IPIN '14 - Proceedings of International Conference on Indoor Positioning and Indoor Navigation**. New York, NY, USA: IEEE, 2014. p. 554–563. Citado na página [30](#).
- ABDELBAR, A. M.; ELNABARAWY, I.; SALAMA, K. M.; WUNSCH, D. C. Matrix factorization based collaborative filtering with resilient stochastic gradient descent. In: **IJCNN '18 - Proceedings of International Joint Conference on Neural Networks**. Piscataway, New Jersey, US: [s.n.], 2018. p. 1–7. Citado na página [30](#).
- ACAR, E.; DUNLAVY, D. M.; KOLDA, T. G.; MORUP, M. Scalable tensor factorizations for incomplete data. **Chemometrics and Intelligent Laboratory Systems**, Elsevier, v. 106, n. 1, p. 41–56, 2011. Citado na página [99](#).
- ACIAR, S. Mining context information from consumer's reviews. In: **CARS '10 - Proceedings of the 2nd Workshop on Context-Aware Recommender Systems**. New York, NY, USA: ACM, 2010. Citado na página [43](#).
- ACIAR, S.; ZHANG, D.; SIMOFF, S.; DEBENHAM, J. Informed recommender: Basing recommendations on consumer product reviews. **IEEE Intelligent Systems**, v. 22, n. 3, p. 39–47, 2007. Citado na página [77](#).
- ADNAN, M. N. M.; CHOWDURY, M. R.; TAZ, I.; AHMED, T.; RAHMAN, R. M. Content based news recommendation system based on fuzzy logic. In: **ICIEV '14 - Proceedings of International Conference on Informatics, Electronics Vision**. Piscataway, New Jersey, US: IEEE, 2014. p. 1–6. Citado na página [31](#).
- ADOMAVICIUS, G.; KWON, Y. New recommendation techniques for multicriteria rating systems. **IEEE Intelligent Systems**, IEEE Educational Activities Department, Piscataway, NJ, USA, v. 22, n. 3, p. 48–55, 2007. Citado na página [67](#).
- ADOMAVICIUS, G.; SANKARANARAYANAN, R.; SEN, S.; TUZHILIN, A. Incorporating contextual information in recommender systems using a multidimensional approach. **ACM Transactions on Information Systems**, ACM, v. 23, n. 1, p. 103–145, 2005. Citado nas páginas [32](#), [33](#), [34](#), [45](#), [69](#), [97](#) e [103](#).
- 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**, IEEE Educational Activities Department, Piscataway, NJ, USA, v. 17, n. 6, p. 734–749, 2005. Citado na página [29](#).
- _____. Context-aware recommender systems. In: **Recommender Systems Handbook**. Berlin, Heidelberg: Springer-Verlag, 2011. p. 217–253. Citado nas páginas [32](#), [33](#), [34](#) e [41](#).
- AGGARWAL, C. C. **Recommender Systems: The Textbook**. 1st. ed. New York City, EUA: Springer Publishing Company, Incorporated, 2016. Citado nas páginas [23](#), [29](#), [30](#), [36](#) e [99](#).

- AGRAWAL, M.; GONÇALVES, T.; QUARESMA, P. A hybrid approach for cold start recommendations. In: **SKIMA '17 - Proceedings of 11th International Conference on Software, Knowledge, Information Management and Applications**. Piscataway, New Jersey, US: IEEE, 2017. p. 1–6. Citado na página [32](#).
- AGRAWAL, R.; IMIELIŃSKI, T.; SWAMI, A. Mining association rules between sets of items in large databases. **SIGMOD Rec.**, ACM, New York, NY, USA, v. 22, n. 2, p. 207–216, 1993. Citado nas páginas [90](#) e [91](#).
- AGUILAR, J.; PORTILLA, O.; PUERTO, E. Adaptive hybrid recommender system of learning objects. In: **LA-CCI '16 - Proceedings of IEEE Latin American Conference on Computational Intelligence**. Piscataway, New Jersey, US: IEEE, 2016. p. 1–6. Citado na página [32](#).
- AHN, J.-w.; BRUSILOVSKY, P.; GRADY, J.; HE, D.; SYN, S. Y. Open user profiles for adaptive news systems: Help or harm? In: **WWW '07 - Proceedings of the 16th International Conference on World Wide Web**. New York, NY, USA: ACM, 2007. p. 11–20. Citado na página [31](#).
- AKEHURST, J.; KOPRINSKA, I.; YACEF, K.; PIZZATO, L. A. S.; KAY, J.; REJ, T. Ccr - a content-collaborative reciprocal recommender for online dating. In: **IJCAI '11 - Proceedings of the Twenty-second International Joint Conference on Artificial Intelligence**. Palo Alto, California, USA: AAAI, 2011. Citado na página [32](#).
- ALANAZI, A.; BAIN, M. A people-to-people content-based reciprocal recommender using hidden markov models. In: **RecSys '13 - Proceedings of the 7th ACM Conference on Recommender Systems**. New York, NY, USA: ACM, 2013. p. 303–306. Citado na página [31](#).
- ALBATAYNEH, N. A.; GHAUTH, K. I.; CHUA, F.-F. A semantic content-based forum recommender system architecture based on content-based filtering and latent semantic analysis. In: HERAWAN, T.; GHAZALI, R.; DERIS, M. M. (Ed.). **Recent Advances on Soft Computing and Data Mining**. Cham, Switzerland: Springer International Publishing, 2014. p. 369–378. Citado na página [31](#).
- ALMEIDA, T. A.; SILVA, T. P.; SANTOS, I.; HIDALGO, J. M. G. Text normalization and semantic indexing to enhance instant messaging and sms spam filtering. **Knowledge-Based Systems**, Elsevier Science Publishers B. V., Amsterdam, The Netherlands, The Netherlands, v. 108, n. C, p. 25–32, 2016. Citado na página [85](#).
- BACCIANELLA, S.; ESULI, A.; SEBASTIANI, F. SentiWordNet 3.0: An enhanced lexical resource for sentiment analysis and opinion mining. In: **LREC '10 - Proceedings of the Seventh conference on International Language Resources and Evaluation**. Valletta, Malta: European Languages Resources Association (ELRA), 2010. Citado na página [96](#).
- BALABANOVIC, M.; SHOHAM, Y. Fab: Content-based, collaborative recommendation. **Communications of the ACM**, ACM, New York, NY, USA, v. 40, n. 3, p. 66–72, 1997. Citado na página [32](#).
- BARAL, R.; ZHU, X.; IYENGAR, S. S.; LI, T. Reel: Review aware explanation of location recommendation. In: **UMAP '18 - Proceedings of the 26th Conference on User Modeling, Adaptation and Personalization**. New York, NY, USA: ACM, 2018. p. 23–32. Citado nas páginas [24](#), [25](#), [59](#), [60](#), [61](#), [62](#), [75](#), [76](#) e [80](#).

BARONI, M.; DINU, G.; KRUSZEWSKI, G. Don't count, predict! a systematic comparison of context-counting vs. context-predicting semantic vectors. In: **ACL '14 - Annual Meeting of the Association for Computational Linguistics**. Atlanta, Georgia: Association for Computational Linguistics, 2014. v. 1, p. 238–247. Citado na página 86.

BAUMAN, K.; TUZHILIN, A. Discovering contextual information from user reviews for recommendation purposes. In: **CBRecSys '14 - Proceedings of Workshop on New Trends in Content-based Recommender Systems**. New York, NY, USA: ACM, 2014. p. 2–9. Citado na página 44.

BELL, R.; KOREN, Y.; VOLINSKY, C. Modeling relationships at multiple scales to improve accuracy of large recommender systems. In: **KDD '07 - Proceedings of the 13th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining**. New York, NY, USA: ACM, 2007. p. 95–104. Citado na página 30.

BELLOGIN, A.; CASTELLS, P.; CANTADOR, I. Precision-oriented evaluation of recommender systems: An algorithmic comparison. In: **RecSys '11 - Proceedings of the Fifth ACM Conference on Recommender Systems**. New York, NY, USA: ACM, 2011. p. 333–336. Citado na página 74.

BERRY, M. W.; CASTELLANOS, M. (Ed.). **Survey of Text Mining: Clustering, Classification, and Retrieval**. 2nd.. ed. Berlin, Heidelberg: Springer, 2007. Citado na página 38.

BERTAGLIA, T. F. C. **Normalização textual de conteúdo gerado por usuário**. Dissertação (Mestrado) — Instituto de Ciências Matemáticas e de Computação - Universidade de São Paulo - USP, 2017. Citado na página 85.

BILLSUS, D.; PAZZANI, M. J. User modeling for adaptive news access. **User Modeling and User-Adapted Interaction**, v. 10, n. 2, p. 147–180, 2000. Citado na página 31.

BLAIR-GOLDENSOHN, S.; HANNAN, K.; MCDONALD, R.; NEYLON, T.; REIS, G. A.; REYNAR, J. Building a sentiment summarizer for local service reviews. In: **NLPix '08 - Proceedings of workshop on NLP challenges in the Information Explosion Era**. Beijing, China: Coling 2008 Organizing Committee, 2008. v. 14. Citado na página 50.

BLEI, D. M.; NG, A. Y.; JORDAN, M. I. Latent dirichlet allocation. **The Journal of Machine Learning Research**, JMLR.org, v. 3, p. 993–1022, 2003. Citado na página 50.

BOTTOU, L. Stochastic gradient descent tricks. In: _____. **Neural Networks: Tricks of the Trade: Second Edition**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 421–436. Citado na página 98.

BREESE, J. S.; HECKERMAN, D.; KADIE, C. Empirical analysis of predictive algorithms for collaborative filtering. In: **UAI '98 - Proceedings of the Fourteenth Conference on Uncertainty in Artificial Intelligence**. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1998. p. 43–52. Citado nas páginas 46 e 104.

CAMPOS, L. M. de; FERNANDEZ-LUNA, J. M.; HUETE, J. F.; RUEDA-MORALES, M. A. Combining content-based and collaborative recommendations: A hybrid approach based on bayesian networks. **International Journal of Approximate Reasoning**, v. 51, n. 7, p. 785 – 799, 2010. Citado na página 32.

CANNY, J. Collaborative filtering with privacy via factor analysis. In: **SIGIR '02 - Proceedings of the 25th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval**. New York, NY, USA: ACM, 2002. p. 238–245. Citado na página 30.

CARDOSO, N. Rembrandt - reconhecimento de entidades mencionadas baseado em relações e análise detalhada do texto. In: **Desafios na avaliação conjunta do reconhecimento de entidades mencionadas: O Segundo HAREM**. Aveiro, Portugal: Linguateca, 2008. p. 195–211. Citado na página 45.

CHEN, G.; CHEN, L. Recommendation based on contextual opinions. In: **User Modeling, Adaptation, and Personalization**. Cham, Switzerland: Springer International Publishing, 2014, (Lecture Notes in Computer Science, v. 8538). p. 61–73. Citado nas páginas 36, 59, 60, 61, 62, 63, 66, 67, 68, 69, 70, 79, 81, 84 e 138.

_____. Augmenting service recommender systems by incorporating contextual opinions from user reviews. **User Modeling and User-Adapted Interaction**, Kluwer Academic Publishers, Hingham, MA, USA, v. 25, n. 3, p. 295–329, 2015. Citado nas páginas 25, 36, 59, 60, 61, 62, 63, 68, 69, 70, 79 e 81.

CHEN, L.; CHEN, G.; WANG, F. Recommender systems based on user reviews: The state of the art. **User Modeling and User-Adapted Interaction**, Kluwer Academic Publishers, Hingham, MA, USA, v. 25, n. 2, p. 99–154, 2015. Citado nas páginas 24, 25, 53 e 56.

CHEN, L.; WANG, F. Preference-based clustering reviews for augmenting e-commerce recommendation. **Knowledge-Based Systems**, Elsevier Science Publishers B. V., Amsterdam, The Netherlands, The Netherlands, v. 50, p. 44–59, 2013. Citado na página 53.

CLAYPOOL, M.; GOKHALE, A.; MIRANDA, T.; MURNIKOV, P.; NETES, D.; SARTIN, M. Combining content-based and collaborative filters in an online newspaper. In: **ACM SIGIR '99 - Proceedings of Workshop on Recommender Systems**. New York, NY, USA: ACM, 1999. Citado na página 32.

CLAYPOOL, M.; LE, P.; WASED, M.; BROWNS, D. Implicit interest indicators. In: **IUI '01 - Proceedings of the 6th International Conference on Intelligent User Interfaces**. New York, NY, USA: ACM, 2001. p. 33–40. Citado na página 30.

CODINA, V.; RICCI, F.; CECCARONI, L. Exploiting the semantic similarity of contextual situations for pre-filtering recommendation. In: **User Modeling, Adaptation, and Personalization**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013, (Lecture Notes in Computer Science, v. 7899). p. 165–177. Citado na página 67.

COLACE, F.; SANTO, M. D.; GRECO, L. A probabilistic approach to tweets' sentiment classification. In: **ACII '13 - Proceedings of the Humaine Association Conference on Affective Computing and Intelligent Interaction**. New York, NY, USA: IEEE, 2013. p. 37–42. Citado nas páginas 61 e 69.

COLACE, F.; SANTO, M. D.; GRECO, L.; MOSCATO, V.; PICARIELLO, A. A collaborative user-centered framework for recommending items in online social networks. **Computers in Human Behavior**, v. 51, Part B, p. 694 – 704, 2015. Citado nas páginas 25, 59, 60, 61, 62, 63, 69, 79 e 81.

COLACE, F.; SANTO, M. D.; GRECO, L.; AMATO, F.; MOSCATO, V.; PERSIA, F.; PICARIELLO, A. A user-centered approach for social recommendations. In: **ACHI '15 - Proceedings of the Eighth International Conference on Advances in Computer-Human Interactions**. [S.l.: s.n.], 2015. p. 190–193. Citado nas páginas [59](#), [60](#), [61](#), [62](#), [63](#), [69](#) e [79](#).

COLLOBERT, R.; WESTON, J. A unified architecture for natural language processing: Deep neural networks with multitask learning. In: **ICML '08 - Proceedings of the 25th International Conference on Machine Learning**. New York, NY, USA: ACM, 2008. p. 160–167. Citado na página [86](#).

CONRADO, M. S. **Extração automática de termos simples baseada em aprendizado de máquina**. Tese (Doutorado) — Instituto de Ciências Matemáticas e de Computação - Universidade de São Paulo - USP, 2014. Citado na página [45](#).

CONRADO, M. S.; PARDO, T. A. S.; REZENDE, S. O. A machine learning approach to automatic term extraction using a rich feature set. In: **NAACL-HLT-SRW'13 - Proceedings of the Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies - Student Research Workshop**. Atlanta, Georgia: Association for Computational Linguistics, 2013. p. 16–23. Citado na página [45](#).

CREMONESI, P.; TURRIN, R.; AIROLDI, F. Hybrid algorithms for recommending new items. In: **HetRec '11 - Proceedings of the 2Nd International Workshop on Information Heterogeneity and Fusion in Recommender Systems**. New York, NY, USA: ACM, 2011. p. 33–40. Citado na página [32](#).

CUNNINGHAM, H.; MAYNARD, D.; BONTCHEVA, K.; TABLAN, V. Gate: an architecture for development of robust hlt applications. In: **ACL '02 - Proceedings of the 40th Annual Meeting on Association for Computational Linguistics**. Stroudsburg, PA, USA: Association for Computational Linguistics, 2002. p. 168–175. Citado na página [42](#).

DAVE, K.; LAWRENCE, S.; PENNOCK, D. M. Mining the peanut gallery: Opinion extraction and semantic classification of product reviews. In: **WWW'03 - Proceedings of the 12th International Conference on World Wide Web**. New York, NY, USA: ACM, 2003. p. 519–528. Citado na página [46](#).

DESHPANDE, M.; KARYPIS, G. Item-based top-n recommendation algorithms. **ACM Transactions on Information Systems**, ACM, New York, NY, USA, v. 22, n. 1, p. 143–177, 2004. Citado nas páginas [30](#), [46](#) e [97](#).

DEY, A. K. Understanding and using context. **Personal and Ubiquitous Computing**, Springer-Verlag, v. 5, n. 1, p. 4–7, 2001. Citado nas páginas [24](#), [32](#) e [41](#).

DING XIAOWEN, B. L.; YU, P. S. A holistic lexicon-based approach to opinion mining. In: **WSDM '08 - Proceedings of the Conference on Web Search and Web Data Mining**. New York, NY, USA: ACM, 2008. Citado na página [51](#).

DOMINGUES, M. A.; JORGE, A. M.; SOARES, C. Dimensions as virtual items: Improving the predictive ability of top-n recommender systems. **Information Processing and Management: an International Journal**, Pergamon Press, Inc., v. 49, n. 3, p. 698–720, 2013. Citado na página [35](#).

- DOMINGUES, M. A.; MANZATO, M. G.; MARCACINI, R. M.; SUNDERMANN, C. V.; REZENDE, S. O. Using contextual information from topic hierarchies to improve context-aware recommender systems. In: **ICPR '14 - Proceedings of the 22nd International Conference on Pattern Recognition**. New York, NY, USA: IEEE, 2014. p. 3606–3611. Citado nas páginas 45 e 46.
- DOMINGUES, M. A.; SUNDERMANN, C. V.; MANZATO, M. G.; MARCACINI, R. M.; REZENDE, S. O. Exploiting text mining techniques for contextual recommendations. In: **WI '14 - IEEE/WIC/ACM International Joint Conferences on Web Intelligence and Intelligent Agent Technologies**. New York, NY, USA: IEEE, 2014. v. 2, p. 210–217. Citado nas páginas 27, 45, 46 e 105.
- EKSTRAND, M. D.; RIEDL, J. T.; KONSTAN, J. A. Collaborative filtering recommender systems. **Foundations and Trends in Human-Computer Interaction**, Now Publishers Inc., Hanover, MA, USA, v. 4, n. 2, p. 81–173, 2011. Citado na página 37.
- FAYYAD, U. M.; PIATETSKY-SHAPIO, G.; SMYTH, P. From data mining to knowledge discovery: an overview. In: FAYYAD, U. M.; PIATETSKY-SHAPIO, G.; SMYTH, P.; UTHURUSAMY, R. (Ed.). **Advances in knowledge discovery and data mining**. Menlo Park, CA, USA: American Association for Artificial Intelligence, 1996. p. 1–34. Citado na página 40.
- FINKEL, J. R.; GRENAGER, T.; MANNING, C. Incorporating non-local information into information extraction systems by gibbs sampling. In: **ACL '05: Proceedings of the 43rd Annual Meeting on Association for Computational Linguistics**. Stroudsburg, PA: Association for Computational Linguistics, 2005. p. 363–370. Citado na página 103.
- GANU, G.; KAKODKAR, Y.; MARIAN, A. Improving the quality of predictions using textual information in online user reviews. **Information Systems**, Elsevier Science Ltd., Oxford, UK, UK, v. 38, n. 1, p. 1–15, 2013. Citado na página 53.
- HAMMAR, M.; KARLSSON, R.; NILSSON, B. J. Using maximum coverage to optimize recommendation systems in e-commerce. In: **RecSys '13 - Proceedings of the 7th ACM Conference on Recommender Systems**. New York, NY, USA: ACM, 2013. p. 265–272. Citado na página 30.
- HARIRI, N.; MOBASHER, B.; BURKE, R.; ZHENG, Y. Context-aware recommendation based on review mining. In: **ITWP '11: Proceedings of the 9th Workshop on Intelligent Techniques for Web Personalization and Recommender Systems**. Aachen, Alemanha: Ruzica Piskac, 2011. p. 30–36. Citado nas páginas 43 e 44.
- HAYES, C.; MASSA, P.; AVESANI, P.; CUNNINGHAM, P. An on-line evaluation framework for recommender systems. In: **AH '02 - Proceeding of the Workshop on Personalization and Recommendation in E-Commerce**. [S.l.: s.n.], 2002. Citado na página 65.
- HERLOCKER, J. L.; KONSTAN, J. A.; TERVEEN, L. G.; RIEDL, J. T. Evaluating collaborative filtering recommender systems. **ACM Transactions on Information Systems**, v. 22, p. 5–53, 2004. Citado nas páginas 36 e 37.
- HILL, W.; STEAD, L.; ROSENSTEIN, M.; FURNAS, G. Recommending and evaluating choices in a virtual community of use. In: **CHI '95 - Proceedings of the SIGCHI Conference on Human Factors in Computing Systems**. New York, NY, USA: ACM Press/Addison-Wesley Publishing Co., 1995. p. 194–201. Citado na página 30.

HO, S.-S.; LIEBERMAN, M.; WANG, P.; SAMET, H. Mining future spatiotemporal events and their sentiment from online news articles for location-aware recommendation system. In: **MobiGIS '12 - Proceedings of the First ACM SIGSPATIAL International Workshop on Mobile Geographic Information Systems**. New York, NY: ACM, 2012. p. 25–32. Citado nas páginas 59, 60, 61, 62, 64 e 78.

HOFMANN, T. Probabilistic latent semantic indexing. In: **SIGIR '99 - Proceedings of the 22nd Annual International ACM SIGIR Conference on Research and Development in Information Retrieval**. New York, NY, USA: ACM, 1999. p. 50–57. Citado na página 50.

HU, M.; LIU, B. Mining and summarizing customer reviews. In: **KDD '04 - Proceedings of the Tenth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining**. New York, NY, USA: ACM, 2004. p. 168–177. Citado nas páginas 50, 61, 65 e 77.

HUTTO, C. J.; GILBERT, E. Vader: A parsimonious rule-based model for sentiment analysis of social media text. In: **ICWSM '14 - Proceedings of International AAAI Conference on Web and Social Media**. Palo Alto, California, USA: AAAI, 2014. Citado na página 77.

ISINKAYE, F.; FOLAJIMI, Y.; OJOKOH, B. Recommendation systems: Principles, methods and evaluation. **Egyptian Informatics Journal**, v. 16, n. 3, p. 261 – 273, 2015. Citado nas páginas 30 e 31.

JALAN, K.; GAWANDE, K. Context-aware hotel recommendation system based on hybrid approach to mitigate cold-start-problem. In: **ICECDS '17 - International Conference on Energy, Communication, Data Analytics and Soft Computing**. Piscataway, New Jersey, US: IEEE, 2017. p. 2364–2370. Citado nas páginas 59, 60, 61, 62, 63, 75 e 80.

KARATZOGLOU, A.; AMATRIAIN, X.; BALTRUNAS, L.; OLIVER, N. Multiverse recommendation: n-dimensional tensor factorization for context-aware collaborative filtering. In: **RecSys '10 - Proceedings of the fourth ACM conference on Recommender systems**. New York, NY, USA: ACM, 2010. p. 79–86. Citado na página 99.

KHARRAT, F. B.; ELKHLEIFI, A.; FAIZ, R. Recommendation system based contextual analysis of facebook comment. In: **AICCSA '16 - IEEE/ACS 13th International Conference of Computer Systems and Applications**. Piscataway, New Jersey, US: IEEE, 2016. p. 1–6. Citado nas páginas 24, 59, 60, 61, 62, 63, 73, 74 e 79.

KITCHENHAM, B.; CHARTERS, S. **Guidelines for performing systematic literature reviews in software engineering**. Newcastle and Durham, UK, 2007. Citado na página 54.

KONSTAN, J. A.; MILLER, B. N.; MALTZ, D.; HERLOCKER, J. L.; GORDON, L. R.; RIEDL, J. GroupLens: Applying collaborative filtering to usenet news. **Communications of the ACM**, ACM, New York, NY, USA, v. 40, n. 3, p. 77–87, 1997. Citado na página 30.

KONSTAN, J. A.; RIEDL, J. Recommender systems: from algorithms to user experience. **User Modeling and User-Adapted Interaction**, v. 22, n. 1, p. 101–123, 2012. Citado na página 30.

KOREN, Y. Factorization meets the neighborhood: A multifaceted collaborative filtering model. In: **KDD '08 - Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining**. New York, NY, USA: ACM, 2008. p. 426–434. Citado na página 30.

- _____. Collaborative filtering with temporal dynamics. In: **KDD '09 - Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining**. New York, NY, USA: ACM, 2009. p. 447–456. Citado na página 31.
- KOREN, Y.; BELL, R.; VOLINSKY, C. *et al.* Matrix factorization techniques for recommender systems. **Computer**, IEEE, New York, NY, USA, v. 42, n. 8, p. 30–37, 2009. Citado na página 98.
- KOTHARI, A. A.; PATEL, W. D. A novel approach towards context sensitive recommendations based on machine learning methodology. In: **CSNT '15 - Fifth International Conference on Communication Systems and Network Technologies**. New York, NY, USA: IEEE, 2015. p. 1114–1118. Citado nas páginas 59, 60, 61, 62, 63, 70, 79 e 81.
- KUMAR, B.; SHARMA, N. Approaches, Issues and Challenges in Recommender Systems: A Systematic Review. **Indian Journal of Science and Technology**, v. 9, n. 47, 2016. Citado na página 54.
- LAFFERTY, J. D.; MCCALLUM, A.; PEREIRA, F. C. N. Conditional random fields: Probabilistic models for segmenting and labeling sequence data. In: **ICML '01 - Proceedings of the Eighteenth International Conference on Machine Learning**. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 2001. p. 282–289. Citado nas páginas 50 e 103.
- LAWSON, C. L.; HANSON, R. J. **Solving least squares problems**. Filadélfia, Pensilvânia, EUA: Society for Industrial and Applied Mathematics, 1995. v. 15. Citado na página 98.
- LEE, D.; PARK, S. E.; KAHNG, M.; LEE, S.; LEE, S. G. Exploiting contextual information from event logs for personalized recommendation. In: **Computer and Information Science 2010**. Yamagata, Japan: Springer Berlin Heidelberg, 2010, (Studies in Computational Intelligence, v. 317). p. 121–139. Citado na página 41.
- LEVI, A.; MOKRYN, O.; DIOT, C.; TAFT, N. Finding a needle in a haystack of reviews: Cold start context-based hotel recommender system. In: **RecSys '12 - Proceedings of the Sixth ACM Conference on Recommender Systems**. New York, NY, USA: ACM, 2012. p. 115–122. Citado nas páginas 25, 59, 60, 61, 62, 63, 65, 66, 67, 75, 78 e 81.
- LI, Y.; NIE, J.; ZHANG, Y. Contextual recommendation based on text mining. In: **COLING '10 - Proceedings of the 23rd International Conference on Computational Linguistics: Posters**. Stroudsburg, PA, USA: Association for Computational Linguistics, 2010. p. 692–700. Citado nas páginas 41, 42 e 43.
- LINDEN, G.; SMITH, B.; YORK, J. Amazon.com recommendations: Item-to-item collaborative filtering. **IEEE Internet Computing**, IEEE Educational Activities Department, Piscataway, NJ, USA, v. 7, n. 1, p. 76–80, 2003. Citado nas páginas 23 e 30.
- LIU, B. **Web Data Mining: Exploring Hyperlinks, Contents, and Usage Data (Data-Centric Systems and Applications)**. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2006. Citado na página 50.
- _____. Sentiment analysis and subjectivity. In: **Handbook of Natural Language Processing**. United Kingdom: Chapman & Hall/CRC, 2010. Citado na página 51.
- _____. Sentiment analysis and opinion mining. **Synthesis Lectures on Human Language Technologies**, Morgan & Claypool, San Rafael, California, USA, v. 5, n. 1, p. 1–167, 2012. Citado nas páginas 48 e 51.

_____. **Sentiment Analysis: Mining Opinions, Sentiments, and Emotions**. Cambridge, Reino Unido: Cambridge University Press, 2015. Citado nas páginas 46, 47, 48 e 50.

LIU, L.; MEHANDJIEV, N.; XU, D.-L. Multi-criteria service recommendation based on user criteria preferences. In: **RecSys '11 - Proceedings of the Fifth ACM Conference on Recommender Systems**. New York, NY, USA: ACM, 2011. p. 77–84. Citado na página 53.

LONG, C.; ZHANG, J.; ZHUT, X. A review selection approach for accurate feature rating estimation. In: **COLING '10 - Proceedings of the 23rd International Conference on Computational Linguistics: Posters**. Stroudsburg, PA, USA: Association for Computational Linguistics, 2010. p. 766–774. Citado na página 50.

MAKREHCHI, M.; KAMEL, M. S. Automatic extraction of domain-specific stopwords from labeled documents. In: **ECIR '08 - Proceedings of the IR Research, 30th European Conference on Advances in Information Retrieval**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. (Lecture Notes in Computer Science, v. 4956), p. 222–233. Citado na página 39.

MARCACINI, R.; REZENDE, S. O. Incremental hierarchical text clustering with privileged information. In: **DocEng'13 - Proceedings of the 2013 ACM Symposium on Document Engineering**. New York, NY, USA: ACM, 2013. p. 231–232. Citado nas páginas 45 e 103.

MARCACINI, R. M.; HRUSCHKA, E. R.; REZENDE, S. O. On the use of consensus clustering for incremental learning of topic hierarchies. In: **SBIA '12 - Advances in Artificial Intelligence - 21th Brazilian Symposium on Artificial Intelligence**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. (Lecture Notes in Computer Science), p. 112–121. Citado na página 45.

MEEHAN, K.; LUNNEY, T.; CURRAN, K.; MCCAUGHEY, A. Context-aware intelligent recommendation system for tourism. In: **PERCOM '13 - Proceedings of IEEE International Conference on Pervasive Computing and Communications (Workshops)**. Piscataway, New Jersey, US: IEEE, 2013. p. 328–331. Citado nas páginas 59, 60, 61, 62, 66 e 78.

MELVILLE, P.; MOONEY, R. J.; NAGARAJAN, R. Content-boosted collaborative filtering for improved recommendations. In: **AAAI '02 - Proceedings of Eighteenth National Conference on Artificial Intelligence**. Menlo Park, CA, USA: American Association for Artificial Intelligence, 2002. p. 187–192. Citado na página 32.

MIKOLOV, T.; LE, Q. V.; SUTSKEVER, I. Exploiting similarities among languages for machine translation. **Computing Research Repository (CoRR)**, abs/1309.4168, 2013. Citado na página 104.

MISSAOUI, S.; VIVIANI, M.; FAIZ, R.; PASI, G. A language modeling approach for the recommendation of tourism-related services. In: **SAC '17 - Proceedings of the Symposium on Applied Computing**. New York, NY, USA: ACM, 2017. p. 1697–1700. Citado nas páginas 24, 25, 59, 60, 61, 62, 63, 74 e 80.

MOONEY, R. J.; ROY, L. Content-based book recommending using learning for text categorization. In: **DL '00 - Proceedings of the Fifth ACM Conference on Digital Libraries**. New York, NY, USA: ACM, 2000. p. 195–204. Citado na página 31.

NIELSEN, F. r. A new anew: Evaluation of a word list for sentiment analysis in microblogs. **CoRR**, abs/1103.2903, 2011. Citado na página 77.

- ORELLANA-RODRIGUEZ, C.; DIAZ-AVILES, E.; NEJDL, W. Mining affective context in short films for emotion-aware recommendation. In: **HT '15 - Proceedings of the 26th ACM Conference on Hypertext and Social Media**. New York, NY, USA: ACM, 2015. p. 185–194. Citado nas páginas [36](#), [59](#), [60](#), [61](#), [62](#), [70](#), [71](#), [79](#) e [81](#).
- PANG, B.; LEE, L. Opinion mining and sentiment analysis. **Foundations and Trends in Information Retrieval**, Now Publishers Inc., Hanover, MA, USA, v. 2, n. 1-2, p. 1–135, 2008. Citado na página [96](#).
- PANG, B.; LEE, L.; VAITHYANATHAN, S. Thumbs up?: Sentiment classification using machine learning techniques. In: **EMNLP '02 - Proceedings of the ACL-02 Conference on Empirical Methods in Natural Language Processing - Volume 10**. Stroudsburg, PA, USA: Association for Computational Linguistics, 2002. p. 79–86. Citado na página [46](#).
- PANNIELLO, U.; GORGOGNONE, M. Incorporating context into recommender systems: An empirical comparison of context-based approaches. **Electronic Commerce Research**, Kluwer Academic Publishers, v. 12, n. 1, p. 1–30, 2012. Citado nas páginas [33](#), [34](#), [45](#), [97](#) e [103](#).
- PAZZANI, M.; BILLSUS, D. Learning and revising user profiles: The identification of interesting web sites. **Machine Learning**, Kluwer Academic Publishers, Hingham, MA, USA, v. 27, n. 3, p. 313–331, 1997. ISSN 0885-6125. Citado na página [31](#).
- POPESCU, A.-M.; ETZIONI, O. Extracting product features and opinions from reviews. In: **HLT '05: Proceedings of the Conference on Human Language Technology and Empirical Methods in Natural Language Processing**. Stroudsburg, PA, USA: Association for Computational Linguistics, 2005. p. 339–346. Citado na página [50](#).
- PORIA, S.; CAMBRIA, E.; KU, L.-W.; GUI, C.; GELBUKH, A. A rule-based approach to aspect extraction from product reviews. In: **Proceedings of the Second Workshop on Natural Language Processing for Social Media (SocialNLP)**. Dublin, Ireland: Association for Computational Linguistics and Dublin City University, 2014. p. 28–37. Citado nas páginas [93](#) e [94](#).
- PORIYA, A.; PATEL, N.; BHAGAT, T.; SHARMA, R. Non-personalized recommender systems and user-based collaborative recommender systems. **International Journal of Applied Information Systems (IJAIS)**, v. 6, p. 22–27, 2014. Citado na página [30](#).
- PORTUGAL, I.; ALENCAR, P. S. C.; COWAN, D. D. The use of machine learning algorithms in recommender systems: A systematic review. **CoRR**, abs/1511.05263, 2015. Citado na página [54](#).
- QIAN, X.; FENG, H.; ZHAO, G.; MEI, T. Personalized recommendation combining user interest and social circle. **IEEE Transactions on Knowledge and Data Engineering**, v. 26, n. 7, p. 1763–1777, July 2014. ISSN 1041-4347. Citado na página [77](#).
- RABINER, L. R. A tutorial on hidden markov models and selected applications in speech recognition. **Proceedings of the IEEE**, v. 77, p. 257–286, 1989. ISSN 0018-9219. Citado na página [50](#).
- RAHAYU, P.; SENSUSE, D. I.; PURWANDARI, B.; BUDI, I.; KHALID, F.; ZULKARNAIM, N. A systematic review of recommender system for e-portfolio domain. In: **Proceedings of the 5th International Conference on Information and Education Technology**. New York, NY, USA: ACM, 2017. (ICIET '17), p. 21–26. ISBN 978-1-4503-4803-4. Citado na página [54](#).

- RATNAPARKHI, A. **Maximum Entropy Models for Natural Language Ambiguity Resolution**. Tese (Doutorado) — University of Pennsylvania, Philadelphia, PA, USA, 1998. Citado na página 42.
- REICHARDT, J.; BORNHOLDT, S. Statistical mechanics of community detection. **Physical Review E**, American Physical Society, v. 74, p. 016110, 2006. Citado na página 61.
- REZENDE, S. O. (Ed.). **Sistemas Inteligentes: fundamentos e aplicações**. Barueri, Brasil: Editora Manole, 2003. Citado nas páginas 38, 39 e 40.
- RICCI, F.; ROKACH, L.; SHAPIRA, B. **Recommender Systems Handbook**. 2nd. ed. Berlin, Heidelberg: Springer-Verlag, 2015. Citado nas páginas 23, 29 e 30.
- RICCI, F.; ROKACH, L.; SHAPIRA, B.; KANTOR, P. B. **Recommender System Handbook**. Berlin, Heidelberg: Springer-Verlag, 2011. 842 p. Citado na página 38.
- SALTON, G.; MCGILL, M. J. **Introduction to Modern Information Retrieval**. New York, NY, USA: McGraw-Hill, Inc., 1983. Citado na página 40.
- SCHAFER, J. B.; FRANKOWSKI, D.; HERLOCKER, J.; SEN, S. Collaborative filtering recommender systems. In: **The Adaptive Web**. Berlin, Heidelberg: Springer-Verlag, 2007. p. 291–324. Citado na página 30.
- SEZGIN, E.; ÖZKAN, S. A systematic literature review on health recommender systems. In: **EHB '13 - E-Health and Bioengineering Conference**. Piscataway, New Jersey, US: IEEE, 2013. p. 1–4. Citado na página 54.
- SHANI, G.; GUNAWARDANA, A. Evaluating recommender systems. In: **DS '12 - Recommender Systems Handbook**. Boston, MA: Springer, 2011. p. 257–298. Citado nas páginas 36, 37 e 67.
- SINOARA, R. A.; ANTUNES, J.; REZENDE, S. O. Text Mining and Semantics: A Systematic Mapping Study. **Journal of the Brazilian Computer Society (JBCS)**, v. 23, n. 1, p. 9, 2017. Citado na página 86.
- SOHRAB, M. G.; MIWA, M.; SASAKI, Y. Centroid-means-embedding: An approach to infusing word embeddings into features for text classification. In: CAO, T.; LIM, E.-P.; ZHOU, Z.-H.; HO, T.-B.; CHEUNG, D.; MOTODA, H. (Ed.). **Advances in Knowledge Discovery and Data Mining**. Cham: Springer International Publishing, 2015. p. 289–300. Citado na página 86.
- STEGEMAN, A.; SIDIROPOULOS, N. D. On kruskal's uniqueness condition for the cande-comp/parafac decomposition. **Linear Algebra and its applications**, Elsevier, v. 420, n. 2-3, p. 540–552, 2007. Citado na página 99.
- SU, X.; KHOSHGOFTAAR, T. M. A survey of collaborative filtering techniques. **Advances in Artificial Intelligence**, Hindawi Publishing Corp., New York, NY, United States, p. 1–19, 2009. Citado na página 69.
- SULTHANA, A. R.; RAMASAMY, S. Ontology and context based recommendation system using neuro-fuzzy classification. **Computers & Electrical Engineering**, Elsevier, 2018. Citado nas páginas 25, 59, 60, 61, 62, 63, 77 e 80.

- SUNDERMANN, C.; ANTUNES, J.; DOMINGUES, M.; REZENDE, S. Exploration of word embedding model to improve context-aware recommender systems. In: **WI '18 - Proceedings of IEEE/WIC/ACM International Conference on Web Intelligence**. Piscataway, New Jersey, US: IEEE, 2018. p. 383–388. Citado nas páginas [86](#), [101](#) e [115](#).
- SUNDERMANN, C.; DOMINGUES, M.; MARCACINI, R.; REZENDE, S. Using topic hierarchies with privileged information to improve context-aware recommender systems. In: **BRACIS '14 - Proceedings of Brazilian Conference on Intelligent Systems**. Piscataway, New Jersey, US: IEEE, 2014. p. 61–66. Citado nas páginas [45](#) e [46](#).
- SUNDERMANN, C. V.; DOMINGUES, M. A.; CONRADO, M. da S.; REZENDE, S. O. Privileged contextual information for context-aware recommender systems. **Expert Systems with Applications**, v. 57, p. 139 – 158, 2016. Citado nas páginas [27](#), [45](#), [46](#) e [105](#).
- SUNDERMANN, C. V.; DOMINGUES, M. A.; MARCACINI, R. M.; REZENDE, S. O. Combining privileged information to improve context-aware recommender systems. In: **ENIAC '15 - Encontro Nacional de Inteligência Artificial e Computacional**. New York, NY, USA: ACM, 2015. Citado nas páginas [45](#) e [46](#).
- SUNDERMANN, C. V.; DOMINGUES, M. A.; REZENDE, S. O. **Exploration of contextual information extraction methods for construction of baselines in the user review domain**. [S.l.], 2018. Citado nas páginas [101](#) e [105](#).
- SUNDERMANN, C. V.; DOMINGUES, M. A.; SINOARA, R. A.; MARCACINI, R. M.; REZENDE, S. O. Using opinion mining in context-aware recommender systems: A systematic review. **Information**, v. 10, n. 2, 2019. Citado nas páginas [29](#), [54](#), [57](#), [59](#), [60](#), [61](#), [62](#) e [63](#).
- SUNDERMANN, C. V.; PÁDUA, R. de; TONON, V. R.; DOMINGUES, M. A.; REZENDE, S. O. A context-aware recommender method based on text mining. In: **EPIA '19 - Progress in Artificial Intelligence**. Cham, Suíça: Springer International Publishing, 2019. p. 385–396. Citado nas páginas [86](#), [101](#), [102](#) e [138](#).
- THELWALL, M.; BUCKLEY, K.; PALTOGLOU, G.; CAI, D.; KAPPAS, A. Sentiment strength detection in short informal text. **Journal of the American Society for Information Science and Technology**, John Wiley & Sons, Inc., New York, NY, USA, v. 61, n. 12, p. 2544–2558, 2010. Citado na página [77](#).
- TUCKER, L. R. Some mathematical notes on three-mode factor analysis. **Psychometrika**, Springer, v. 31, n. 3, p. 279–311, 1966. Citado na página [99](#).
- WANG, H.; LU, Y.; ZHAI, C. Latent aspect rating analysis on review text data: A rating regression approach. In: **KDD '10 - Proceedings of the 16th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining**. New York, NY, USA: ACM, 2010. p. 783–792. Citado nas páginas [61](#) e [67](#).
- WANG, P.; XU, B.; XU, J.; TIAN, G.; LIU, C.-L.; HAO, H. Semantic expansion using word embedding clustering and convolutional neural network for improving short text classification. **Neurocomputing**, v. 174, p. 806 – 814, 2016. ISSN 0925-2312. Citado na página [86](#).
- WANG, Y.; LIU, Y.; YU, X. Collaborative filtering with aspect-based opinion mining: A tensor factorization approach. In: **ICDM '12 - Proceedings of IEEE 12th International Conference on Data Mining**. Piscataway, New Jersey, US: IEEE, 2012. p. 1152–1157. Citado na página [53](#).

WASFI, A. M. A. Collecting user access patterns for building user profiles and collaborative filtering. In: **IUI '99 - Proceedings of the 4th International Conference on Intelligent User Interfaces**. New York, NY, USA: ACM, 1999. p. 57–64. Citado na página [32](#).

WEISS, S. M.; INDURKHYA, N.; ZHANG, T.; DAMERAU, F. J. **Text Mining: Predictive Methods for Analyzing Unstructured Information**. New York, NY, EUA: Springer, 2005. Citado na página [40](#).

WIEBE, J. Learning subjective adjectives from corpora. In: **AAAI '00 - Proceedings of the Seventeenth National Conference on Artificial Intelligence and Twelfth Conference on Innovative Applications of Artificial Intelligence**. Palo Alto, California, USA: AAAI Press, 2000. Citado na página [46](#).

WILSON, T. Recognizing contextual polarity in phrase-level sentiment analysis. In: **HLT '05 - Proceedings of the conference on Human Language Technology and Empirical Methods in Natural Language Processing**. Stroudsburg, PA, USA: Association for Computational Linguistics, 2005. p. 347–354. Citado na página [67](#).

YANG, P.; FANG, H. An exploration of ranking-based strategy for contextual suggestion. In: **TREC '12 - Proceedings of Text Retrieval Conference**. [S.l.: s.n.], 2012. Citado na página [72](#).

YANG, P.; WANG, H.; FANG, H.; CAI, D. Opinions matter: A general approach to user profile modeling for contextual suggestion. **Information Retrieval**, Kluwer Academic Publishers, Hingham, MA, USA, v. 18, n. 6, p. 586–610, 2015. Citado nas páginas [25](#), [59](#), [60](#), [61](#), [62](#), [71](#), [72](#), [74](#), [79](#) e [81](#).

YUGOSHI, I. P. M. **Mineração de opiniões baseada em aspectos para revisões de produtos e serviços**. Tese (Doutorado) — Instituto de Ciências Matemáticas e de Computação - Universidade de São Paulo - USP, 2018. Citado nas páginas [25](#) e [49](#).

ZANGERLE, E.; CHEN, C.; TSAI, M.; YANG, Y. Leveraging affective hashtags for ranking music recommendations. **IEEE Transactions on Affective Computing**, p. 1–1, 2018. Citado nas páginas [25](#), [59](#), [60](#), [61](#), [62](#), [77](#), [78](#) e [80](#).

ZHANG, W.; DING, G.; CHEN, L.; LI, C.; ZHANG, C. Generating virtual ratings from chinese reviews to augment online recommendations. **ACM Transactions on Intelligent Systems and Technology**, ACM, New York, NY, USA, v. 4, n. 1, p. 9:1–9:17, 2013. Citado nas páginas [61](#) e [72](#).

ZHAO, G.; QIAN, X.; LEI, X.; MEI, T. Service quality evaluation by exploring social users' contextual information. **IEEE Transactions on Knowledge and Data Engineering**, v. 28, n. 12, p. 3382–3394, 2016. Citado nas páginas [59](#), [60](#), [61](#), [62](#), [63](#), [72](#), [73](#) e [79](#).