



Victor Sales de Brito

Estudo comparativo de técnicas de seleção de contextos em Sistemas de Recomendação de Domínio Cruzado Sensíveis ao Contexto

Recife

2018

Victor Sales de Brito

**Estudo comparativo de técnicas de seleção de contextos
em Sistemas de Recomendação de Domínio Cruzado
Sensíveis ao Contexto**

Monografia apresentada ao Curso de Bacharelado em Ciência da Computação da Universidade Federal Rural de Pernambuco, como requisito parcial para obtenção do título de Bacharel em Ciência da Computação.

Universidade Federal Rural de Pernambuco – UFRPE

Departamento de Computação

Curso de Bacharelado em Ciência da Computação

Orientador: Prof. Dr. Douglas Vêras e Silva

Recife

2018



MINISTÉRIO DA EDUCAÇÃO E DO DESPORTO
UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO (UFRPE)
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

<http://www.bcc.ufrpe.br>

FICHA DE APROVAÇÃO DO TRABALHO DE CONCLUSÃO DE CURSO

Trabalho defendido por Victor Sales de Brito às 9 horas do dia 16 de agosto de 2018, no Auditório do CEAGRI-02 – Sala 07, como requisito para conclusão do curso de Bacharelado em Ciência da Computação da Universidade Federal Rural de Pernambuco, intitulado **Estudo comparativo de técnicas de seleção de contextos em Sistemas de Recomendação de Domínio Cruzado Sensíveis ao Contexto**, orientado por Douglas Vêras e Silva e aprovado pela seguinte banca examinadora:

Douglas Vêras e Silva
DC/UFRPE

André Câmara Alves do Nascimento
DC/UFRPE

Dedico este trabalho à minha mãe, e aos meus amigos de infância Ivo Cintra de Farias Neto e Wilton Macedo Costa Júnior (*in memoriam*).

Agradecimentos

Aos professores da Universidade Federal Rural de Pernambuco que contribuíram para minha formação acadêmica.

Ao orientador Douglas Vêras, que me ajudou e me motivou na criação deste trabalho.

À secretária Sandra Xavier, que facilitou minha jornada acadêmica desde o início.

À professora Jeane Melo, pela simpatia e amizade.

Ao meu irmão David Vieira, pela sua mentoria.

À minha companheira Roberta Gomes, pela colaboração massiva na minha graduação.

Aos amigos que adquiri na faculdade, principalmente a Francisco Lira, Leonardo Figueirôa e Rodolfo Ferreira, que auxiliaram na realização dos trabalhos da faculdade.

Aos amigos do Dota/CS, que participaram dos momentos de distração.

Aos meus colegas do TRE, que me incentivaram a finalizar o curso.

Resumo

Existem diversas abordagens para a implementação dos sistemas de recomendação, dentre elas, a abordagem de “sistemas de recomendação de domínio cruzado sensíveis ao contexto” (*Cross-Domain Context-Aware Recommender Systems* - CD-CARS), empregada neste trabalho, pois possibilita a melhoria na qualidade das recomendações usando vários domínios (ex.: livros, filmes e músicas) e considerando a aplicação de contextos (ex.: estação do ano, tempo, companhia, localização). No entanto, é necessário cautela ao utilizar contextos para realizar sugestões de itens, uma vez que os contextos podem influenciar negativamente o desempenho da recomendação quando considerados “irrelevantes”. Portanto, a seleção de contextos relevantes é um fator chave para o desenvolvimento do tipo de sistema CD-CARS e, dentro da literatura, constatou-se uma escassez de trabalhos acerca da aplicação de técnicas de seleção em conjuntos de dados com informações contextuais e de domínio cruzado. Dessa forma, este trabalho aplicou as técnicas de seleção *Information Gain* (IG), Teste qui-quadrado (χ^2), *Minimum Redundancy Maximum Relevance* (MRMR) e *Monte Carlo Feature Selection* (MCFS), em doze conjuntos de dados com três diferentes dimensões contextuais (tempo, localização e companhia) e domínios distintos (livros, televisão e músicas). Por fim, a partir dos resultados encontrados, averiguou-se que a técnica MCFS conseguiu classificar a relevância dos contextos de forma mais satisfatória.

Palavras-chave: seleção de contextos, sistemas de recomendação, classificação dos contextos.

Abstract

There are several approaches to implement a recommendation system, such as Cross-Domain Context-Aware Recommendation Systems (CD-CARS), which was used in this work because it enables quality improvement of recommendations using multiple domains (e.g. books, movies and musics), while taking into account the use of contexts (e.g. season, time, company and location). However, caution is needed in using contexts to make items suggestions, since the contexts may impair the recommendation performance when they are considered “irrelevants”. Therefore, the selection of relevant contexts is a key factor for the development of CD-CARS, and there is a lack of papers for selection techniques in datasets with contextual information and cross-domain. Thus, this work applied the Information Gain (IG), Chi-square test, Minimum Redundancy Maximum Relevance (MRMR) and Monte Carlo Feature Selection (MCFS) techniques in twelve datasets with three different contextual dimensions (time, location and company) and distinct domains (books, television and musics). Finally, from the results obtained, the MCFS technique was able to classify the relevance of the contexts in a more satisfactory way than other techniques.

Keywords: context selection, recommender systems, context classification.

Lista de ilustrações

Figura 1 – Visão geral da recomendação realizada pelo CD-CARS	18
Figura 2 – Uma característica contextual representada por dimensões, atributos e valores	28
Figura 3 – Visão geral do procedimento MCFS	33
Figura 4 – Validação cruzada <i>10-fold</i>	37
Figura 5 – Processo empregado para seleção dos contextos relevantes	45
Figura 6 – Cenários de classificação dos algoritmos	46
Figura 7 – Gráfico de dispersão do desempenho geral (Kendall) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica MAE nos conjuntos de dados com domínios livro e televisão	66
Figura 8 – Gráfico de dispersão do desempenho geral (Kendall) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica RMSE nos conjuntos de dados com domínios livro e televisão	67
Figura 9 – Gráfico de dispersão do desempenho geral dos algoritmos de seleção de contextos, aplicando o coeficiente tau de Kendall , em relação aos algoritmos de recomendação pela métrica F-Measure (com N=5) nos conjuntos de dados com domínios livro e televisão	68
Figura 10 – Gráfico de dispersão do desempenho geral (Kendall) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica MAE nos conjuntos de dados com domínios livro e música	70
Figura 11 – Gráfico de dispersão do desempenho geral (Kendall) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica RMSE nos conjuntos de dados com domínios livro e música	71
Figura 12 – Gráfico de dispersão do desempenho geral (Kendall) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica F-Measure (com N=5) nos conjuntos de dados com domínios livro e música	72

Lista de quadros

Quadro 1 – Resumo das Técnicas de Representação de Contexto	24
Quadro 2 – Valores das probabilidades condicionais	31
Quadro 3 – Desempenho geral (Kendall) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica MAE nos conjuntos de dados com domínios livro e televisão	65
Quadro 4 – Desempenho geral (Kendall) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica RMSE nos conjuntos de dados com domínios livro e televisão	66
Quadro 5 – Desempenho geral (Kendall) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica F-Measure nos conjuntos de dados com domínios livro e televisão	67
Quadro 6 – Desempenho geral (Kendall) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica MAE nos conjuntos de dados com domínios livro e música	69
Quadro 7 – Desempenho geral (Kendall) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica RMSE nos conjuntos de dados com domínios livro e música	70
Quadro 8 – Desempenho geral (Kendall) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica F-Measure nos conjuntos de dados com domínios livro e música	71

Lista de tabelas

Tabela 1 – Conjunto de treinamento	32
Tabela 2 – Tabela de contingência de 2x2.	33
Tabela 3 – Tabela de resumo dos trabalhos relacionados (parte 1)	40
Tabela 4 – Tabela de resumo dos trabalhos relacionados (parte 2)	41
Tabela 5 – Tabela de descrição das informações contextuais	42
Tabela 6 – Tabela da frequência das dimensões contextuais em relação a quantidade total de notas em cada conjunto de dados	43
Tabela 7 – Tabela da configuração dos parâmetros necessários para execução do algoritmo <i>Information Gain</i>	43
Tabela 8 – Tabela da configuração dos parâmetros necessários para execução do algoritmo Teste qui-quadrado	44
Tabela 9 – Classificação segundo algoritmos de recomendação no conjunto de dados <i>book-tv-10overlap-target-book</i>	47
Tabela 10 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados <i>book-tv-10overlap-target-book</i>	48
Tabela 11 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados <i>book-tv-10overlap-target-book</i>	48
Tabela 12 – Classificação segundo algoritmos de recomendação no conjunto de dados <i>book-tv-10overlap-target-tv</i>	49
Tabela 13 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados <i>book-tv-10overlap-target-tv</i>	49
Tabela 14 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados <i>book-tv-10overlap-target-tv</i>	50
Tabela 15 – Classificação segundo algoritmos de recomendação no conjunto de dados <i>book-tv-50overlap-target-book</i>	50
Tabela 16 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados <i>book-tv-50overlap-target-book</i>	51
Tabela 17 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados <i>book-tv-50overlap-target-book</i>	51
Tabela 18 – Classificação segundo algoritmos de recomendação no conjunto de dados <i>book-tv-50overlap-target-tv</i>	52
Tabela 19 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados <i>book-tv-50overlap-target-tv</i>	52
Tabela 20 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados <i>book-tv-50overlap-target-tv</i>	53

Tabela 21 – Classificação segundo algoritmos de recomendação no conjunto de dados <i>book-tv-100overlap-target-book</i>	53
Tabela 22 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados <i>book-tv-100overlap-target-book</i>	54
Tabela 23 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados <i>book-tv-100overlap-target-book</i>	54
Tabela 24 – Classificação do desempenho dos contextos segundo algoritmos de recomendação no conjunto de dados <i>book-tv-100overlap-target-tv</i>	55
Tabela 25 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados <i>book-tv-100overlap-target-tv</i>	55
Tabela 26 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados <i>book-tv-100overlap-target-tv</i>	56
Tabela 27 – Classificação segundo algoritmos de recomendação no conjunto de dados <i>book-music-10overlap-target-book</i>	56
Tabela 28 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados <i>book-music-10overlap-target-book</i>	57
Tabela 29 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados <i>book-music-10overlap-target-book</i>	57
Tabela 30 – Classificação segundo algoritmos de recomendação no conjunto de dados <i>book-music-10overlap-target-music</i>	58
Tabela 31 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados <i>book-music-10overlap-target-music</i>	58
Tabela 32 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados <i>book-music-10overlap-target-music</i>	58
Tabela 33 – Classificação segundo algoritmos de recomendação no conjunto de dados <i>book-music-50overlap-target-book</i>	59
Tabela 34 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados <i>book-music-50overlap-target-book</i>	59
Tabela 35 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados <i>book-music-50overlap-target-book</i>	60
Tabela 36 – Classificação segundo algoritmos de recomendação no conjunto de dados <i>book-music-50overlap-target-music</i>	60
Tabela 37 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados <i>book-music-50overlap-target-music</i>	61
Tabela 38 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados <i>book-music-50overlap-target-music</i>	61
Tabela 39 – Classificação segundo algoritmos de recomendação no conjunto de dados <i>book-music-100overlap-target-book</i>	62

Tabela 40 – Classificação segundo algoritmos de seleção no conjunto de dados <i>book-music-100overlap-target-book</i>	62
Tabela 41 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados <i>book-music-100overlap-target-book</i>	63
Tabela 42 – Classificação segundo algoritmos de recomendação no conjunto de dados <i>book-music-100overlap-target-music</i>	63
Tabela 43 – Classificação segundo algoritmos de seleção no conjunto de dados <i>book-music-100overlap-target-music</i>	64
Tabela 44 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados <i>book-music-100overlap-target-music</i>	64
Tabela 45 – Distribuição das frequências absoluta e relativa da correlação tau de Kendall (τ) nos conjuntos de dados com domínios <i>Livro</i> e <i>Televisão</i>	68
Tabela 46 – Distribuição das frequências absoluta e relativa da correlação tau de Kendall (τ) nos conjuntos de dados com domínios <i>Livro</i> e <i>Música</i>	72

Lista de abreviaturas e siglas

CARS	<i>Context-aware recommender systems</i>
CD-CARS	<i>Cross-domain context-aware recommender systems</i>
CDRS	<i>Cross-domain recommender systems</i>
IG	<i>Information Gain</i>
LVF	<i>Las vegas filter</i>
MAE	<i>Mean average error</i>
RMSE	<i>Root mean squared error</i>
MRMR	<i>Minimum redundancy maximum relevance</i>
MCFS	<i>Monte Carlo Feature Selection</i>
PreF	<i>Pre-filtering</i>
PostF	<i>Post-filtering</i>
RSs	<i>Recommender systems</i>
SDRS	<i>Single-domain recommender systems</i>

Sumário

1	INTRODUÇÃO	16
1.1	Problema	19
1.2	Objetivos	19
1.2.1	Objetivo geral	19
1.2.2	Objetivos específicos	19
1.3	Organização do trabalho	20
2	FUNDAMENTAÇÃO TEÓRICA	21
2.1	O que é Contexto?	21
2.2	Como obter a informação contextual?	21
2.3	Qual a relevância do contexto?	22
2.4	Como representar o contexto?	24
2.5	Sistemas de Recomendação	24
2.5.1	Técnicas de recomendação	25
2.5.2	Cross-domain recommender systems (CDRS)	26
2.5.3	Context-aware recommender systems (CARS)	27
2.5.4	CD-CARS, uma nova abordagem de RS	28
2.5.4.1	Algoritmos de Recomendação	29
2.6	Seleção de Características	29
2.6.1	Métodos <i>Wrapper</i>	30
2.6.2	Métodos <i>Filter</i>	30
2.6.2.1	<i>Minimum Redundancy Maximum Relevance (MRMR)</i>	30
2.6.2.2	<i>Information Gain (IG)</i>	32
2.6.2.3	Teste qui-quadrado (χ^2) de Pearson	32
2.6.2.4	<i>Monte Carlo Feature Selection (MCFS)</i>	33
2.6.3	Métodos <i>Embedded</i>	34
2.7	Avaliação de Desempenho	34
2.7.1	Avaliação dos algoritmos de recomendação	35
2.7.2	Avaliação dos algoritmos de seleção	36
2.7.3	Validação cruzada	37
3	TRABALHOS RELACIONADOS	38
4	METODOLOGIA	42
4.1	Configuração experimental	42
4.1.1	Conjuntos de dados	42

4.1.2	Algoritmos de seleção de contexto	43
4.2	Avaliação de Desempenho	45
5	RESULTADOS E DISCUSSÃO	47
5.1	Conjuntos de dados com domínios <i>Livro e Televisão</i>	47
5.1.1	10% de sobreposição e livro como domínio alvo	47
5.1.2	10% de sobreposição e televisão como domínio alvo	48
5.1.3	50% de sobreposição e livro como domínio alvo	50
5.1.4	50% de sobreposição e televisão como domínio alvo	51
5.1.5	100% de sobreposição e livro como domínio alvo	53
5.1.6	100% de sobreposição e televisão como domínio alvo	54
5.2	Conjuntos de dados com domínios <i>Livro e Música</i>	56
5.2.1	10% de sobreposição e livro como domínio alvo	56
5.2.2	10% de sobreposição e música como domínio alvo	57
5.2.3	50% de sobreposição e livro como domínio alvo	59
5.2.4	50% de sobreposição e música como domínio alvo	60
5.2.5	100% de sobreposição e livro como domínio alvo	61
5.2.6	100% de sobreposição e música como domínio alvo	63
5.3	Sumário	64
5.4	Discussão	73
5.5	Considerações Finais	74
6	CONCLUSÃO	75
6.1	Limitações	75
6.2	Trabalhos futuros	75
	REFERÊNCIAS	77
	APÊNDICES	83
	APÊNDICE A – EXEMPLO DE ARQUIVO .ARFF UTILIZADO PELO WEKA	84
	APÊNDICE B – EXEMPLO DE ARQUIVO .CSV SEM CABEÇALHO	85
	APÊNDICE C – CÓDIGO GERADO PARA EXECUTAR O ALGORITMO <i>MINIMUM REDUNDANCY MAXIMUM RELEVANCE</i> (MRMR) NA LINGUAGEM DE PROGRAMAÇÃO PYTHON.	86

APÊNDICE D – EXEMPLO DE ARQUIVO .CSV COM CABEÇALHO	88
APÊNDICE E – CÓDIGO GERADO PARA EXECUTAR O ALGORITMO <i>MONTE CARLO FEATURE SELECTION</i> (MCFS) NA LINGUAGEM DE PROGRAMAÇÃO R.	89

1 Introdução

No dia-a-dia, enfrentamos regularmente problemas de escolha, como o restaurante para jantar, onde passar as férias ou em que hotel se hospedar (BRAUNHOFER; RICCI, 2017). Essas decisões nem sempre são fáceis, pois, as vezes, existe um excesso de opções e informações que acabam dificultando a tomada de decisão. O problema de encontrar informações relevantes para o usuário, dentre uma vasta quantidade de opções, é tradicionalmente conhecido como “o problema da sobrecarga de informação” (ADOMAVICIUS; TUZHILIN, 2005; RICCI; ROKACH; SHAPIRA, 2015).

Os sistemas de recomendação (RSs) têm sido desenvolvidos a fim de resolver problemas como o supracitado (ADOMAVICIUS; TUZHILIN, 2005; RICCI; ROKACH; SHAPIRA, 2015), por serem ferramentas e técnicas de software que procuram fornecer sugestões para itens que possuem maior probabilidade de gerar interesse em um determinado usuário (RICCI; ROKACH; SHAPIRA, 2015). Sugerir aos consumidores itens de seus interesses, dentre eles, filmes, livros e músicas caracterizam um bom exemplo.

De acordo com Fernández-Tobías et al. (2012), os RSs são utilizados por diversos *websites* e aplicações de grande escala como Netflix¹, Youtube², Last.fm³, Amazon⁴, Spotify⁵, iTunes⁶, entre outros. Na maioria dos casos, esses sistemas são elaborados para recomendar itens sobre um único domínio, intitulados assim de “sistemas de recomendação domínio único” (*Single-Domain Recommender Systems* - SDRS) (ex.: o Netflix sugere filmes e seriados de TV e Last.fm faz recomendações personalizadas de artistas e músicas). No entanto, em sites de comércio eletrônico como a Amazon, por exemplo, é útil explorar as avaliações do usuário sobre diversos tipos de itens, a fim de gerar um modelo mais geral das preferências do usuário.

De fato, pode haver dependências e correlações entre preferências em diferentes domínios e, ao invés de tratar cada tipo de item (ex.: filmes, livros e músicas) de forma independente, o conhecimento adquirido em diversos domínios “fonte” (ex.: livros) podem ser utilizados para melhorar a recomendação em um outro domínio “alvo” (ex.: filmes) (FERNÁNDEZ-TOBÍAS et al., 2012). Os sistemas que utilizam essa abordagem são denominados de “sistemas de recomendação de domínio cruzado” (*Cross-Domain Recommender Systems* - CDRS), que também possui como motivação resolver alguns problemas que podem ocorrer nos SDRS, como o de *cold-start*, que é quando os usuários

¹ <https://www.netflix.com>

² <https://www.youtube.com>

³ <https://www.last.fm>

⁴ <https://www.amazon.com>

⁵ <https://www.spotify.com>

⁶ <https://www.apple.com/br/itunes>

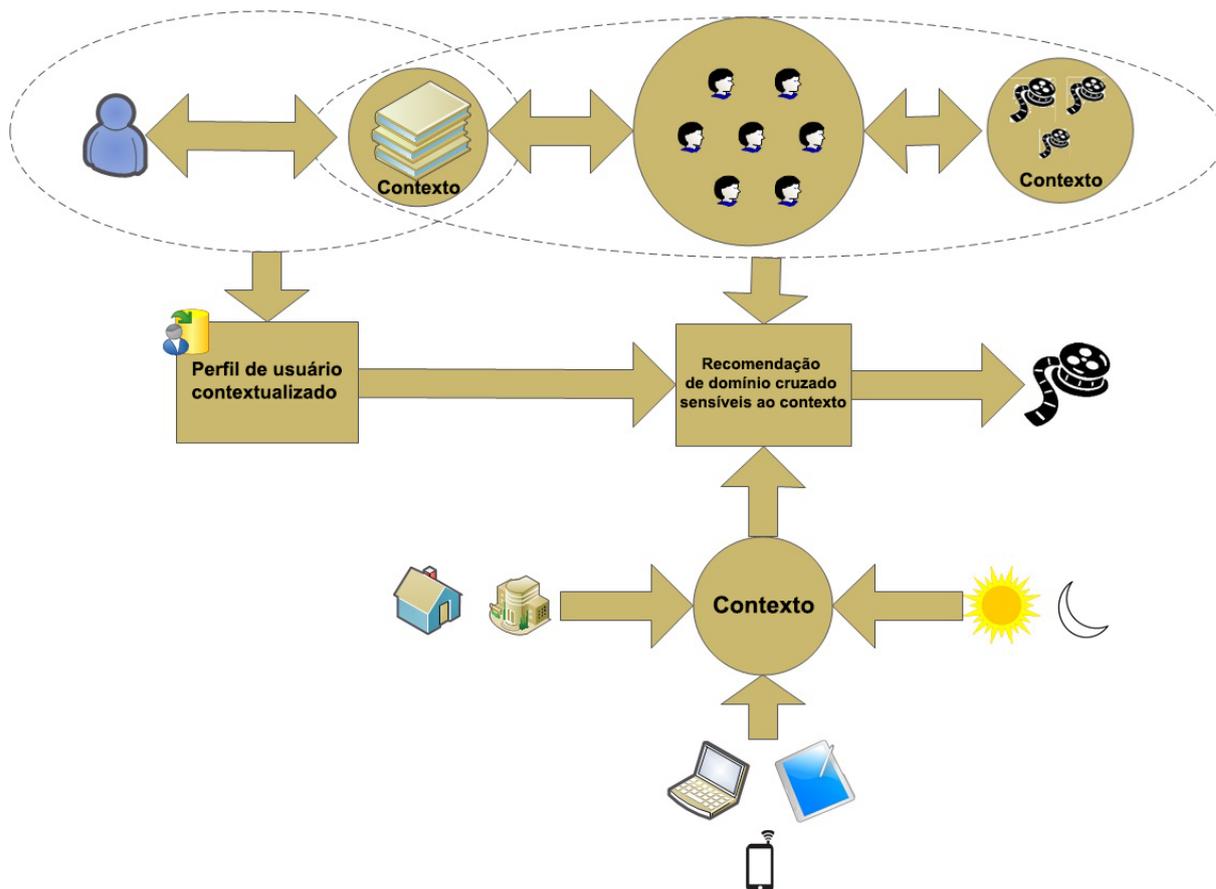
ou itens são recentemente adicionados no sistemas para os quais não existem classificações (CANTADOR et al., 2015).

Ademais, existem muitas abordagens que se concentram em apenas recomendar os itens mais relevantes para os usuários e, desta forma, não levam em consideração nenhuma informação contextual, como o tempo, o lugar e a companhia de outras pessoas (ADOMAVICIUS; TUZHILIN, 2015). Para resolver o problema citado foram criados os “sistemas de recomendação sensíveis ao contexto” (Context-Aware Recommender Systems - CARS), que visam melhorar a qualidade das recomendações utilizando diferentes informações contextuais e, assim, provendo sugestões mais adequadas e precisas para um determinado usuário dependendo de qual contexto ele esteja inserido (ADOMAVICIUS; TUZHILIN, 2015) (ex.: usando o contexto “estações do ano”, um CARS de pontos turísticos possivelmente fornecerá sugestões no verão bem diferentes do que no inverno).

Entretanto, a escolha de informações contextuais não é uma tarefa fácil, para alguns sistemas o clima pode ser importante (ex.: recomendando um destino turístico), enquanto que para outros pode ser considerado irrelevante (DEY, 2001; ODIĆ et al., 2013). É importante ignorar informações contextuais irrelevantes (BRAUNHOFER; RICCI, 2017), que não influenciam nas atribuições de notas fornecidas pelos usuários, uma vez que podem degradar a acurácia da previsão dessas notas (BALTRUNAS; LUDWIG; RICCI, 2011; ODIĆ et al., 2013). Encontrar a informação mais útil para a construção de um modelo de previsão foi amplamente estudado na aprendizagem em máquina e é conhecido como seleção de características (BRAUNHOFER; RICCI, 2017). A seleção de características, por sua vez, visa melhorar o desempenho dos algoritmos de aprendizagem e obter informações sobre o processo generativo desconhecido dos dados (GUYON; ELISSEEFF, 2003; BRAUNHOFER; FERNÁNDEZ-TOBIÁS; RICCI, 2015).

Na área de pesquisa de RSs, surgiu uma recente abordagem denominada “sistemas de recomendação de domínio cruzado sensíveis ao contexto” (Cross-Domain Context-Aware Recommender Systems - CD-CARS) (VÉRAS, 2016) demonstrado na Figura 1, que realiza a integração das técnicas de “domínio cruzado” e de “sensíveis ao contexto”, normalmente desenvolvidas separadamente. Essa integração pode ser útil em numerosas situações, nas quais as sugestões podem ser melhoradas a partir de informações obtidas em diferentes fontes, além de, também, refinadas, considerando informações contextuais específicas (JI; SHEN, 2015; TEKIN; SCHAAR, 2015). Acredita-se que a aplicação dessa abordagem possibilite obter uma sugestão significativamente melhor e mais adequada, portanto, este será o sistema de recomendação empregado durante a discussão do presente trabalho.

Figura 1 – Visão geral da recomendação realizada pelo CD-CARS



Fonte: Adaptado de [Véras \(2016, p. 29\)](#)

Para ilustrar o CD-CARS, suponha que um usuário X, que gosta de ler livros de fantasia (ex.: Harry Potter e Game of Thrones) durante os fins de semana, mas não possui nenhuma preferência sobre filmes. Por outro lado, existe um outro usuário Y, que também gosta de ler livros de fantasia durante os fins de semana, adora assistir filmes de comédia em dias úteis e filmes de ação nos fins de semana, sendo assim, o CD-CARS poderia priorizar os filmes que são de interesses do usuário Y na lista de itens recomendados para o usuário X nesses contextos em particular (filmes de comédia em dias úteis e filmes de ação nos fins de semana), posto que existe o conhecimento da similaridade entre esses usuários através das suas preferências de livro ([VÉRAS, 2016](#)).

A abordagem CD-CARS proposta em [Véras \(2016\)](#) não tinha como foco a seleção dos atributos contextuais mais relevantes, tendo utilizado um simples método para esse propósito: o *InfoGainAttributeEval* do Weka⁷. Foi possível observar que esse método não apresentou total êxito na seleção, visto que, uma dimensão contextual selecionada influenciou negativamente no desempenho do sistema. Nesse sentido, o presente projeto se propõe a utilizar diversas técnicas de seleção de contextos, a fim de obter melhores

⁷ Weka é uma coleção de algoritmos de aprendizagem de máquina para tarefas de mineração de dados. ([HALL et al., 2009](#))

resultados e realizar um estudo comparativo entre as técnicas aplicadas.

1.1 Problema

A seleção de contextos é um fator chave para o desenvolvimento do CD-CARS, uma vez que, aplicar todas as combinações as informações contextuais possíveis torna o processo demorado (VÉRAS, 2016). Além disso, utilizar contextos “irrelevantes” influencia negativamente no desempenho da recomendação (BRAUNHOFER; RICCI, 2017; ODIĆ et al., 2013).

Para selecionar os contextos, frequentemente são utilizados os métodos de filtragem, que empregam características estatísticas dos dados de treinamento para selecionar as características independentemente de qualquer modelo de predição. São exemplos de métodos de filtragem: o teste qui-quadrado de Pearson, o teste Freeman-Halton, o *minimum redundancy maximum relevance* (MRMR) e o *mutual information*. (BRAUNHOFER; RICCI, 2017)

No entanto, os diversos trabalhos que abordam o tema “seleção de contextos” não aplicam a seleção no tipo de conjunto de dados (contendo diversos domínios com informações contextuais) utilizado pelo CD-CARS. Desse modo, realizou-se um estudo comparativo de técnicas de seleção, ao aplicá-las no tipo de conjunto de dados do CD-CARS, observando a existência de alguma limitação que poderá impedir sua aplicação. Portanto, esse projeto analisou as técnicas de seleção a fim de selecionar as dimensões contextuais mais relevantes para o tipo de sistema CD-CARS.

1.2 Objetivos

Nesta seção estão expostos os objetivos almejados com a realização deste trabalho.

1.2.1 Objetivo geral

Investigar e aplicar diversas técnicas de seleção de características com o propósito de selecionar as dimensões contextuais mais relevantes para o CD-CARS.

1.2.2 Objetivos específicos

1. Comparar as técnicas de seleção ao desempenho do CD-CARS através do uso da métrica coeficiente de correlação tau de Kendall (τ).
2. Propor uma metodologia para a aplicação/avaliação da seleção, a partir das dimensões contextuais escolhidas pelas técnicas de seleção.

1.3 Organização do trabalho

O restante do trabalho está disposto da seguinte forma: o [Capítulo 2](#) apresenta os aspectos teóricos sobre as informações contextuais e os sistemas de recomendação; o [Capítulo 3](#) aborda trabalhos relacionados que têm como finalidade a seleção de contextos relevantes; o [Capítulo 4](#) detalha a metodologia aplicada para comparar os algoritmos de seleção e como analisar os resultados alcançados; o [Capítulo 5](#) apresenta os experimentos realizados pelos algoritmos de seleção, discutindo e comparando os resultados; por último, o [Capítulo 6](#) apresenta as considerações finais e possíveis trabalhos futuros.

2 Fundamentação teórica

No presente capítulo, para a devida fundamentação desta pesquisa, são expostas noções e princípios do tema em questão.

2.1 O que é Contexto?

Segundo [Dey \(2001, p. 3, tradução nossa\)](#)

Contexto é qualquer informação que pode ser usada para caracterizar a situação de uma entidade e que uma entidade é uma pessoa, lugar ou objeto que é considerado relevante para a interação entre um usuário e uma aplicação, incluindo os próprios usuários e as aplicações.

A definição supracitada não atende às expectativas da pesquisa, uma vez que existem diferentes definições de contexto dependendo do campo estudado, desta maneira, a definição escolhida será a que é usualmente utilizada dentro da área de sistemas de recomendação, onde o contexto é definido como um conjunto predefinido de atributos observáveis, cuja sua estrutura não muda significativamente ao longo do tempo ([ADOMAVICIUS; TUZHILIN, 2015](#)).

Para facilitar o entendimento, pode-se utilizar a abordagem contida nos trabalhos de [Palmisano, Tuzhilin e Gorgoglione \(2008\)](#) e [Adomavicius et al. \(2005\)](#), em que a informação contextual pode ser definida como um conjunto de N dimensões contextuais (ex.: estação, tempo, companhia, localização) e cada dimensão contextual D contém um conjunto de atributos (ex.: verão, outono, data, dia da semana, sozinho, com os filhos, cidade, ano).

2.2 Como obter a informação contextual?

De acordo com [Adomavicius e Tuzhilin \(2015\)](#) é possível obter a informação contextual através das seguintes formas:

- Explicitamente: É feita de uma forma direta, isto é, pode-se fazer perguntas diretamente aos usuários ([BALTRUNAS et al., 2012](#); [ODIC et al., 2012](#)) (ex.: ao acessar um serviço de *streaming* de músicas, poderia ser realizado um questionamento específico para o cliente, antes da obtenção de acesso as músicas) ou induzir essas informações por outros meios (ex.: é possível conseguir a localização através de um aplicativo no *smartphone*, pois, ao acessá-lo, é solicitado a permissão para obter a localização do usuário).

- **Implicitamente:** A partir dos dados ou do ambiente, é possível obter a informação contextual implicitamente (BRAUNHOFER; RICCI, 2017; BRAUNHOFER; RICCI, 2016). Isto é, a fonte dessa informação é acessada diretamente e os dados são extraídos dela, não sendo realizado nenhum tipo de interação com o usuário. (ex.: adquirir informações sobre o tempo através da hora ou data que certo evento ocorre, como no momento que o usuário avalia um filme que acabou de assistir).
- **Inferindo:** o contexto é identificado através do uso de técnicas provenientes dos métodos estatísticos ou de mineração de dados (VARGAS-GOVEA; GONZÁLEZ-SERNA; PONCE-MEDELLIN, 2011; VÉRAS, 2016). Isto é, a informação contextual não é conhecida, mas pode estar subentendida nos dados. Por exemplo, as companhias de TV a cabo querem detectar a fase da vida (infância, adolescência, adulto, velhice) daquele usuário que está assistindo TV num período de tempo, isto poderia ser feito utilizando-se dessas técnicas sobre algumas informações obtidas, como os programas de TV assistidos e os canais visitados.

2.3 Qual a relevância do contexto?

Estimar a relevância do contexto é a primeira dificuldade encontrada na construção de RSs que utilizam o contexto para as recomendações (BALTRUNAS et al., 2012).

A relevância pode ser identificada manualmente (ex.: a partir da experiência de um especialista) ou automaticamente (ex.: usando algumas abordagens computacionais, como procedimentos de seleção de características da aprendizagem de máquinas, mineração de dados e estatísticas) (ADOMAVICIUS; TUZHILIN, 2015).

O processo para definir a relevância da informação contextual pode ser definida em três tipos de abordagens (BRAUNHOFER; RICCI, 2017):

- Identificar as informações contextuais relevantes que devem ser usados pelo sistema antes de realizar as recomendações (BALTRUNAS et al., 2012; ODIC et al., 2012). Por exemplo, utilizar um questionário, e perguntar ao usuário se um certo contexto tem uma influência positiva, negativa ou neutra para a atribuição da nota de um item específico.
- Selecionar, após a aquisição dos dados sobre as notas e os contextos, aquelas informações contextuais que demonstraram ser mais úteis para calcular corretamente as recomendações (ODIC et al., 2013; VARGAS-GOVEA; GONZÁLEZ-SERNA; PONCE-MEDELLIN, 2011).

- Selecionar as informações contextuais relevantes dos usuários no momento em que eles inserem uma nota para um item. Por exemplo, estimar o impacto de cada contexto na previsão da nota e assim identificar as informações contextuais importantes a serem adquiridas, no momento da atribuição de nota, para cada usuário (BRAUNHOFER; FERNÁNDEZ-TOBIÁS; RICCI, 2015; BRAUNHOFER; RICCI, 2016; BRAUNHOFER; RICCI, 2017).

Além disso, algumas partes da informação contextual podem não ser conhecidas ou estar disponíveis. Sendo assim, de acordo com a relevância de sua aquisição e seleção, a fonte da informação contextual é classificada (VÉRAS, 2016). Essa classificação pode ser estabelecida em três categorias (ADOMAVICIUS et al., 2011):

- Totalmente observável: É conhecida explicitamente a informação contextual relevante para a aplicação assim como sua estrutura e seus valores no momento em que as recomendações são feitas. Por exemplo, no caso de recomendar a compra de um determinado produto, como um jogo eletrônico, os RSs podem considerar que apenas as dimensões contextuais: *Companhia* e *Objetivo da compra* são importantes neste aplicativo. Ademais, os RSs conhecem toda sua estrutura (atributos e valores), isto é, para a dimensão *Companhia* é conhecido o atributo “tipo de companhia”, que pode apresentar os seguintes valores: “sozinho”, “com amigos” e “família”.
- Parcialmente observável: Apenas alguma parte das informações sobre a dimensão contextual é conhecida explicitamente. Por exemplo, sabe-se que as dimensões contextuais: *Companhia* e *Objetivo da Compra* são importantes, mas não conhecidas as suas estruturas como um todo (ex.: para alguns usuários é possível obter apenas os atributos e valores da dimensão *Companhia*, enquanto que, para outros é possível obter apenas da dimensão *Objetivo da Compra*).
- Inobservável: Nenhuma informação sobre a dimensão contextual está explicitamente disponível para o sistema, então a recomendação é feita utilizando o contexto inferido.

Outro aspecto importante a ser ratificado é que a estrutura da informação contextual bem como a sua importância mudam ao longo do tempo. Essa classificação pode ser definida em duas categorias (ADOMAVICIUS et al., 2011):

- Estática: A importância da informação contextual e sua estrutura permanecem os mesmos, isto é, estável, ao longo do tempo.
- Dinâmica: É quando a estrutura ou importância da informação contextual muda de alguma maneira no decorrer do tempo. Por exemplo, em certo momento, os RSs

podem perceber que a dimensão *Companhia* não é mais relevante para a compra de produto eletrônicos, e assim, desconsiderá-lo para futuras recomendações. Além disso, a estrutura de alguma dimensão contextual pode sofrer mudança (ex.: novos atributos podem ser adicionados para a dimensão *Companhia*).

2.4 Como representar o contexto?

Segundo [Vieira, Tedesco e Salgado \(2009\)](#), o contexto pode ser representado principalmente pelas seguintes técnicas ([Quadro 2](#)): par chave-valor, linguagens de marcação (ex.: XML), mapas de tópicos (ex.: XTM), ontologias e modelos gráficos (ex.: UML).

Quadro 1 – Resumo das Técnicas de Representação de Contexto

Técnica	Vantagens	Desvantagens	Processamento e Recuperação
Par Chave-Valor	Estrutura simples, de fácil implementação e uso	Não considera hierarquia. Inadequado para aplicações com estruturas complexas	Busca linear com casamento exato de nomes
Linguagem de Marcação	Prevê hierarquia. Esquema de marcação implementa o próprio modelo.	Modelo não resolve incompletude e ambigüidade Inadequado para representar estruturas complexas	Linguagem de consulta baseada em marcação
Mapas de Tópicos	Facilita a navegação entre os elementos contextuais e a leitura por humanos.	Técnica imatura com baixo suporte de ferramentas.	Navegação por redes semânticas
Ontologias	Agrega regras, conceitos e fatos em um só modelo. Padrões facilitam reuso e compartilhamento. Viabiliza compreensão semântica entre humanos e máquinas.	Não permite modelar o comportamento dos sistemas sensíveis ao contexto. Tecnologia ainda imatura e com poucas ferramentas. Impacto no desempenho.	Motor de Inferência, Linguagens de consulta baseadas em OWL ou frames.
Modelos Gráficos	Facilita a especificação dos conceitos e definição do comportamento dos sistemas sensíveis ao contexto	Não permite processar os conceitos: mapeamento para estruturas de dados	Pode ser traduzido para XML e usa de processamento em XML

Fonte: [Vieira, Tedesco e Salgado \(2009\)](#)

2.5 Sistemas de Recomendação

Os sistemas de recomendação (RSs) surgiram a partir da necessidade de tomar decisões através das recomendações fornecidas por outros indivíduos ([ADOMAVICIUS et al., 2011](#); [RESNICK](#); [VARIAN, 1997](#)) e têm sido construídos para tentar suprir o “problema da sobrecarga de informação”, que é encontrar informações relevantes para

o usuário, dentre uma vasta quantidade de opções (ADOMAVICIUS; TUZHILIN, 2005; RICCI; ROKACH; SHAPIRA, 2015).

O primeiro sistema de recomendação desenvolvido que se tem conhecimento é o Tapestry (GOLDBERG et al., 1992), onde os autores estipularam a técnica “filtragem colaborativa”, que é recomendar um certo produto/serviço (item) através da análise dos relacionamentos entre usuários, a fim de verificar se existe indivíduos com interesses similares, e assim determinar novas associações de itens aos usuários (RICCI; ROKACH; SHAPIRA, 2015; KOREN; BELL; VOLINSKY, 2009).

Os RSs que foram desenvolvidos, ao longo do tempo, demonstraram serem úteis para lidar com o “problema da sobrecarga de informação” (RICCI; ROKACH; SHAPIRA, 2015) e se tornaram cruciais para o aumento da satisfação/fidelidade do usuário e para aqueles RSs com propósito comercial, representou um aumento substancial de vendas (ALDRICH, 2011; RICCI; ROKACH; SHAPIRA, 2015). Enquanto isso, na literatura, diversas técnicas de recomendação foram criadas, na qual variam principalmente a respeito do algoritmo de recomendação (VÉRAS, 2016; RICCI; ROKACH; SHAPIRA, 2015).

2.5.1 Técnicas de recomendação

As técnicas de recomendação podem ser classificadas pelas abordagens descritas nos trabalhos de Burke (2007), Ricci, Rokach e Shapira (2015).

- Filtragem Colaborativa: Os sistemas localizam usuários com um histórico de notas atribuídos aos itens semelhante ao do usuário ativo e, desta forma, geram recomendações de novos itens usando esta vizinhança como referência (BURKE, 2007; RICCI; ROKACH; SHAPIRA, 2015). A filtragem colaborativa é considerada a técnica mais popular e amplamente implementada em RSs (RICCI; ROKACH; SHAPIRA, 2015).
- Baseado em Conteúdo: O sistema gera recomendações com base nas características dos itens e nas notas que foram atribuídas a eles. Por exemplo, se um usuário classificar positivamente alguns filmes do gênero romance, logo, o sistema poderá recomendar outros filmes deste mesmo gênero para o indivíduo em questão (BURKE, 2007; RICCI; ROKACH; SHAPIRA, 2015).
- Baseado em Conhecimento: Este tipo de sistema recomenda através dos conhecimentos obtidos sobre os usuários e itens e como certas características dos itens irão atender as necessidades e preferências dos usuários. Por exemplo, um usuário deseja visitar um restaurante em Recife que serve comidas da culinária chinesa e/ou japonesa, além de pretender gastar pouco. O resultado foi o restaurante *China 48*, que atende perfeitamente a faixa de preço desejada, entretanto, serve apenas comida chinesa (BURKE, 2007; RICCI; ROKACH; SHAPIRA, 2015).

- Baseado em Comunidade: Este tipo sistema é considerada uma mistura das abordagens filtragem colaborativa e baseado em conteúdo (KAMAHARA et al., 2005). Ele adquire informações sobre as relações sociais dos usuários e suas preferências para a construção de comunidades (grupo de usuários que possui gostos semelhantes). A recomendação é baseado nas notas dos itens que foram fornecidas pelas comunidades ao qual o indivíduo pertence (KAMAHARA et al., 2005; RICCI; ROKACH; SHAPIRA, 2015).
- Demográfico: Este tipo de sistema recomenda itens com base no perfil demográfico do usuário e tem como pressuposto que os indivíduos com certos atributos pessoais comuns (idioma, idade, país, etc.) também terão interesses em comum (BOBADILLA et al., 2013; RICCI; ROKACH; SHAPIRA, 2015).
- Sensíveis ao Contexto: É o tipo de sistema que incorpora informações contextuais (ex.: tempo, humor, localização, clima e companhia) no processo de recomendação para sugerir itens aos usuários em determinadas circunstâncias (ADOMAVICIUS; TUZHILIN, 2015). Por exemplo, um CARS de pontos turísticos, que ao utilizar o contexto “estações do ano” (primavera, verão, outono e inverno) provavelmente fornecerá sugestões de pontos turísticos distintos, dependendo do valor desse contexto. (BALTRUNAS et al., 2012)
- Sistema de Recomendações Híbridos: São os RSs que são baseados na combinação das técnicas de recomendação, esse tipo de sistema pretende aproveitar as vantagens e suprir algumas desvantagens das técnicas combinadas. (RICCI; ROKACH; SHAPIRA, 2015; BURKE, 2007).

2.5.2 Cross-domain recommender systems (CDRS)

Os CDRS surgiram a partir de diversas motivações, geralmente devido aos usuários não terem um interesse único e suas necessidades se estenderem em diferentes áreas. (CREMONESI; TRIPODI; TURRIN, 2011) (ex.: um usuário X que tem interesse em diversos domínios, como filmes, livros, jogos, músicas, etc). Ou, para resolver alguns problemas, como o *cold-start*, que é a dificuldade em gerar recomendações devido à falta de informações suficientes sobre as preferências dos usuários ou pelas notas atribuídas aos itens (CANTADOR et al., 2015; SCHEIN et al., 2002).

Esses sistemas são capazes de recomendar itens no domínio A para usuários que atribuíram notas aos itens apenas no domínio F . O domínio F é denominado como o domínio “fonte” e o domínio A é denominado como o domínio “alvo”. Desse modo, esses sistemas estão atraindo bastante atenção, porque eles são capazes de sugerir itens que não

são necessariamente parte do mesmo domínio em que o usuário atribuiu notas aos itens (CREMONESI; TRIPODI; TURRIN, 2011).

Além disso, segundo Cremonesi, Tripodi e Turrin (2011) podem existir *overlap* (sobreposição) dos dados dos usuários ou itens entre os domínios, designando-se de quatro formas distintas:

- Sem sobreposição: como o próprio nome diz, é quando não existe nenhuma sobreposição entre os domínios.
- Sobreposição de usuário: é quando existem alguns usuários comuns que possuem preferências em ambos os domínios. Por exemplo, quando um mesmo usuário atribui notas aos itens em dois domínios distintos (jogos e filmes).
- Sobreposição de itens: é quando existem alguns itens comuns que foram avaliados pelos usuários em ambos os domínios. Por exemplo, quando há um inventário de itens em comum entre os domínios.
- Sobreposição total: entre os domínios existem tanto a sobreposição de itens quanto de usuários.

2.5.3 Context-aware recommender systems (CARS)

Os RSs tradicionais tendem a recomendar os itens mais relevantes para os usuários, sem levar em consideração nenhuma informação contextual (ex.: tempo, lugar e companhia) (ADOMAVICIUS; TUZHILIN, 2015; ADOMAVICIUS et al., 2011), o que pode acarretar em sugestões menos adequadas, pois essa informação contextual pode conter dados potencialmente úteis. Por exemplo, um usuário que deseja comprar um livro e possui como contexto “livros para meus filhos” provavelmente receberá recomendações distintas ao possuir um contexto diferente, como “livros relacionados ao trabalho” (ADOMAVICIUS et al., 2011).

Em contraste, os CARS dependem da informação contextual para realizar o processo da recomendação. Sendo possível incorporá-la nos sistemas de três maneiras (ADOMAVICIUS; TUZHILIN, 2015):

- Pré-filtragem contextual: A informação contextual é utilizada para selecionar os dados importantes para cada contexto específico. Em seguida, é obtido um conjunto relevante de dados, isto é, o conjunto de notas, onde as notas são colocadas em uma matriz de usuários×itens.

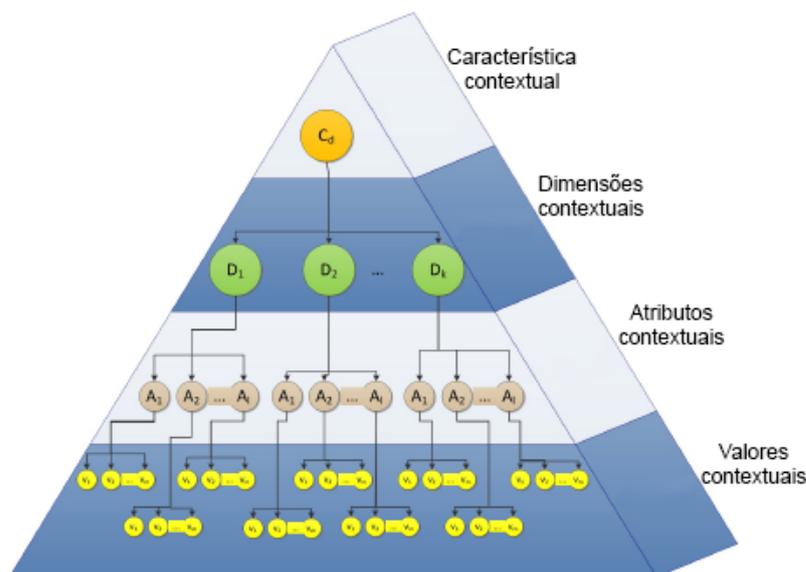
- Pós-filtragem contextual: A informação contextual inicialmente é ignorada, sendo a recomendação feita da forma tradicional (utilizando apenas os dados dos usuários e itens) e em seguida, o resultado das recomendações é ajustado para cada usuário utilizando o contexto.
- Modelagem contextual: A informação contextual é integrada diretamente na fase da recomendação, sendo parte da estimativa de previsão das notas.

2.5.4 CD-CARS, uma nova abordagem de RS

O CD-CARS tem como princípio melhorar a qualidade das recomendações de filtragem colaborativa de vários domínios, adicionando técnicas sensíveis ao contexto (VÉRAS, 2016). Para atingir esse propósito, o CD-CARS recomenda itens do domínio alvo explorando as semelhanças entre usuários considerando as notas atribuídas aos itens e seus contextos, pertencentes aos domínios de origem e destino (VÉRAS, 2016).

Baseado na definição de informação contextual estabelecida na seção 2.1, o CD-CARS modela o contexto através da abordagem utilizada no trabalho de Adomavicius e Tuzhilin (2015), onde a modelagem e previsão das preferências dos usuários incorporam as informações contextuais no processo de recomendação. Sendo assim, é possível capturar o contexto através do momento em que o usuário atribui uma nota ao item e essas informações contextuais podem ser modeladas em diferentes tipos, cada tipo definindo um determinado aspecto (ex.: tempo, local, companhia) (VÉRAS, 2016; ADOMAVICIUS; TUZHILIN, 2015). A modelagem da informação contextual foi realizada, de fato, através da criação de um conjunto de características contextuais (Figura 2).

Figura 2 – Uma característica contextual representada por dimensões, atributos e valores



Fonte: Adaptado de Vêras (2016, p. 70)

Onde cada característica ($CS_1, CS_2, \dots, CS_3, CT$), pertencente aos domínios fontes (S_1, S_2, \dots, S_n) ou domínio alvo (T), é um produto cartesiano de k dimensões contextuais (ex.: $Cd = D_1 \times D_2 \times \dots \times D_k$). Qualquer dimensão contextual pode ser descrita através de l atributos contextuais (A_1, A_2, \dots, A_l) e por fim, cada atributo possui um conjunto de valores $m(v_1, v_2, \dots, v_m)$ que representa parte da informação contextual, quando essa parte é “desconhecida”, isto é, uma parte ausente (ou não observável) da informação contextual, define-se um valor padrão: v_0 (VÉRAS, 2016).

2.5.4.1 Algoritmos de Recomendação

No CD-CARS foi proposto alguns algoritmos de recomendação, dentre eles: o *Pre-Filtering* (PreF) e *Post-Filtering* (PostF).

O algoritmo PreF usa inicialmente as informações contextuais para filtrar o tensor (também denominado de “matrizes multidimensionais” ou “cubo”) de usuário-nota-contexto do domínio alvo para obter uma matriz de duas dimensões de usuário-nota para cada contexto. Em seguida, um algoritmo base de domínio-cruzado (ex.: NNUserNgrbr-transClosure) é aplicado nessas matrizes para prever as notas dos usuários (VÉRAS, 2016).

Enquanto, o algoritmo PostF produz uma única matriz unificada de usuário-nota a partir da agregação das notas para o mesmo par de usuário-item em diferentes contextos. Logo após, um algoritmo base de domínio-cruzado (ex.: NNUserNgrbr-transClosure) é aplicado usando como entrada as matrizes unificadas. Por fim, as informações contextuais são utilizadas para filtrar as notas produzidas pelo algoritmo base de domínio-cruzado. A filtragem é realizada considerando os itens contidos no conjunto de categorias dos itens prediletos (ex.: comédia, ação, suspense, etc.) pelo usuário em determinado contexto, por exemplo, filmes de suspense durante a semana (VÉRAS, 2016).

2.6 Seleção de Características

A seleção de características é definida como o processo de selecionar um subconjunto de características relevantes para a construção de um modelo de previsão (DARABI; TEIMOURPOUR, 2017). As técnicas utilizadas para essa seleção apresentam alguns benefícios, como: facilitar a visualização e entendimento dos dados; reduzir os requisitos de armazenamento, tempo de treinamento e utilização; e melhoria no desempenho da previsão (DARABI; TEIMOURPOUR, 2017; GUYON; ELISSEEFF, 2003).

Os métodos de seleção de característica são divididos em categorias, como: *wrapper*, *filter* e *embedded*.

2.6.1 Métodos *Wrapper*

Os métodos *Wrapper* dependem do desempenho preditivo de algum algoritmo de aprendizagem para avaliar a qualidade das características selecionadas. Sendo assim, a partir da escolha desse algoritmo, o método é executado através do seguinte processo: procurar um subconjunto de características e avaliar a qualidade dessas características através do algoritmo de aprendizagem. Esse processo se repete até que alguns critérios de parada sejam satisfeitos ou o desempenho desejado do algoritmo seja obtido (LI et al., 2017; JOVIĆ; BRKIĆ; BOGUNOVIĆ, 2015).

Esses métodos não são recomendados quando o número de características é muito grande, pois o espaço de busca para n características é de 2^n , o que torna a busca exaustiva impraticável (LI et al., 2017), mas dentro da literatura, eles são definidos como viáveis ao usar estratégias de busca gulosa e algoritmos de modelagem rápida, como *naïve bayes* (CORTIZO; GIRALDEZ, 2006) e máquinas de vetores de suporte (LIU; JIANG; YANG, 2014) (*Support Vector Machines - SVM*) (PATEL, 2016; JOVIĆ; BRKIĆ; BOGUNOVIĆ, 2015).

2.6.2 Métodos *Filter*

Os métodos *Filter* são independentes de qualquer algoritmo de aprendizagem e dependem de certas particularidades dos dados para avaliar a importância dessas características, essa avaliação pode ser feita individualmente ou de várias características simultaneamente. Geralmente esses métodos são mais rápidos e escaláveis, no entanto, devido à falta de um algoritmo de aprendizagem para a seleção de características, pode ocorrer que as características selecionadas não sejam adequadas para a melhoria de desempenho no algoritmo desejado (LI et al., 2017; SAEYS; INZA; LARRAÑAGA, 2007). Para realizar esse processo de filtragem, algumas medidas foram desenvolvidas e são definidas como: informação, distância, consistência, semelhança e medidas estatísticas (JOVIĆ; BRKIĆ; BOGUNOVIĆ, 2015). Por exemplo, o *mutual information* (PENG; LONG; DING, 2005; YU; LIU, 2003) e *correlation feature selection* (CFS) (GUYON; ELISSEEFF, 2003; HALL, 2000).

Há diversos algoritmos de seleção de características que são utilizados na literatura, dentre eles, alguns são aplicados neste trabalho: *Minimum Redundancy Maximum Relevance* (MRMR), *Information Gain* (IG), Teste qui-quadrado (χ^2) e *Monte Carlo Feature Selection* (MCFS).

2.6.2.1 *Minimum Redundancy Maximum Relevance* (MRMR)

O algoritmo MRMR utiliza a informação mútua (Equação 2.3) de uma característica e uma classe, bem como a informação mútua das características entre si para inferir a

relevância e redundância dessas características, respectivamente (BRAUNHOFER; RICCI, 2017). Logo, as características que maximizam a relevância e minimizam a redundância são selecionadas no conjunto de dados utilizado (PENG; LONG; DING, 2005).

A priori, a informação mútua pode ser definida em função dos conceitos de entropia e entropia condicional (COVER; THOMAS, 1991):

- A entropia $H(X)$ é a medida da incerteza de uma variável aleatória X e pode ser descrita como:

$$H(X) = - \sum_{x \in X} p(X) \log_2 p(X) \quad (2.1)$$

onde $p(X)$ é a função de massa da probabilidade.

Por exemplo, $X = \{a \text{ com probabilidade } 1/4, b \text{ com probabilidade } 2/4 \text{ e } c \text{ com probabilidade } 1/4\}$, sendo $H(X) = -(\frac{1}{4}) \times \log_2(\frac{1}{4}) - (\frac{2}{4}) \times \log_2(\frac{2}{4}) - (\frac{1}{4}) \times \log_2(\frac{1}{4}) = \frac{3}{2}$ bits.

- Por sua vez, a entropia condicional $H(X | Y)$ de duas variáveis aleatórias (X e Y) é a incerteza média sobre a variável aleatória X após Y ser observado, representada como:

$$H(X | Y) = - \sum_{x \in X} \sum_{y \in Y} p(x, y) \log_2 [p(x | y)] = -E \log_2 p(X | Y) \quad (2.2)$$

Por exemplo, $Y = \{A \text{ com probabilidade } 3/10 \text{ e } B \text{ com probabilidade } 7/10\}$.

Quadro 2 – Valores das probabilidades condicionais

$P(x_i y_j)$	X=A	X=B
Y=A	3/5	2/5
Y=B	1/2	1/2

Fonte: O próprio autor

Onde, a entropia condicional $H(X | Y)$ será:

$$H(X | Y = A) = H(3/5, 2/5) = -3/5 * \log_2(3/5) - 2/5 * \log_2(2/5) = 0,97$$

$$H(X | Y = B) = H(1/2, 1/2) = -1/2 * \log_2(1/2) - 1/2 * \log_2(1/2) = 1$$

$$H(X | Y) = 3/10 * 0,97 + 7/10 * 1 = 0,991 \text{ bits}$$

- Portanto, a informação mútua é a medida da dependência entre duas variáveis aleatórias (X e Y), tendo valor sempre não negativo e é definida da seguinte forma:

$$I(X; Y) = H(X) - H(X | Y) \quad (2.3)$$

onde $I(X; Y)$ é a redução de incerteza sobre uma variável aleatória X depois da variável Y ser observada e $I(X; Y)$ é igual a 0 quando as variáveis forem estaticamente independentes entre si.

2.6.2.2 Information Gain (IG)

O algoritmo *Information Gain*⁸ mede o quanto aquela característica reduz a entropia para a classe desejada (SHARMA; DEY, 2012), contendo valores maior ou igual a 0, sendo assim, quanto maior o ganho de informação, mais relevante seria essa característica para o conjunto de dados selecionado.

Por exemplo, a característica *Tempo* possui vários atributos (chuvoso, nublado e ensolarado) e está contido no seguinte conjunto de treinamento:

Tabela 1 – Conjunto de treinamento

Tempo (Característica)	Jogar Futebol (Classe)
Chuvoso	Não
Chuvoso	Não
Chuvoso	Sim
Nublado	Sim
Nublado	Sim
Nublado	Não
Ensolarado	Sim
Ensolarado	Sim
Ensolarado	Sim

Fonte: O próprio autor

Para descobrir o ganho de informação dessa característica é necessário realizar o cálculo de entropia da classe e de cada atributo:

$$H(\text{Classe}) = -\left(\frac{6}{9}\right) \times \log_2\left(\frac{6}{9}\right) - \left(\frac{3}{9}\right) \times \log_2\left(\frac{3}{9}\right) = 0.918;$$

$$H(\text{Chuvoso}) = -\left(\frac{1}{3}\right) \times \log_2\left(\frac{1}{3}\right) - \left(\frac{2}{3}\right) \times \log_2\left(\frac{2}{3}\right) = 0.918;$$

$$H(\text{Nublado}) = -\left(\frac{2}{3}\right) \times \log_2\left(\frac{2}{3}\right) - \left(\frac{1}{3}\right) \times \log_2\left(\frac{1}{3}\right) = 0.918;$$

$$H(\text{Ensolarado}) = -\left(\frac{3}{3}\right) \times \log_2\left(\frac{3}{3}\right) = 0.$$

Para obter o ganho da informação é necessário calcular a entropia média destes atributos, levando em consideração a frequência relativa de cada atributo.

$$\text{InfoGain}(\text{Classe}, \text{Tempo}) = H(\text{Classe}) - H(\text{Classe} \mid \text{Chuvoso}, \text{Nublado}, \text{Ensolarado})$$

$$\text{InfoGain}(\text{Classe}, \text{Tempo}) = 0.918 - \left(\frac{3}{9}\right) \times 0.918 - \left(\frac{3}{9}\right) \times 0.918 - \left(\frac{3}{9}\right) \times 0$$

$$\text{InfoGain}(\text{Classe}, \text{Tempo}) = 0.306$$

2.6.2.3 Teste qui-quadrado (χ^2) de Pearson

O algoritmo de Teste qui-quadrado de Pearson utiliza o teste de independência para verificar o quanto duas variáveis são independentes entre si (MCHUGH, 2013), neste

⁸ $\text{InfoGain}(\text{Classe}, \text{Atributo}) = H(\text{Classe}) - H(\text{Classe} \mid \text{Atributo})$, onde H significa “entropia” definida em Teoria da informação. (HALL et al., 2009)

caso as variáveis seriam: a característica selecionada individualmente e a classe rotulada. Normalmente, quanto maior a pontuação do qui-quadrado, maior é a dependência entre as variáveis, dessa forma, considera-se a característica relativamente mais importante (LI et al., 2017).

Para verificar a dependência das variáveis é utilizada uma tabela de contingência, como apresentada na Tabela 2.

Tabela 2 – Tabela de contingência de 2x2.

	classe	\overline{classe}
$\overline{característica1}$	a	b
$característica1$	c	d

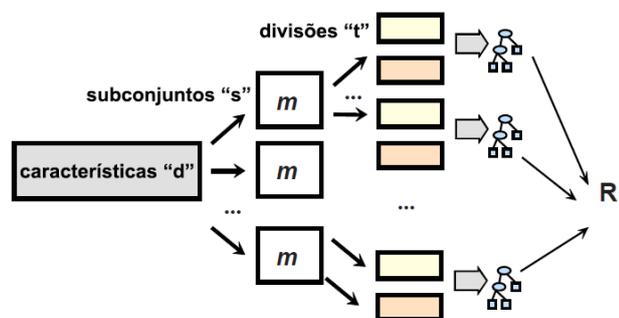
Fonte: Adaptado de Bovo (2011, p. 58)

A célula a indica o número de vezes que a $característica1$ e a $classe$ ocorrem conjuntamente, b indica o número de vezes que a $característica1$ ocorre sem a presença da $classe$, c é o número de vezes que a $classe$ ocorre sem a presença da $característica1$, e, por fim, d é número de vezes que nem a $característica1$ e nem a $classe$ ocorrem (BOVO, 2011).

2.6.2.4 Monte Carlo Feature Selection (MCFS)

O algoritmo MCFS funciona como demonstrado na Figura 3: seleciona subconjuntos s das características originais d , onde cada subconjunto contém uma seleção aleatória de características m . Cada um desses subconjuntos é dividido em conjunto de treinamento e de teste contendo o tamanho de $2/3$ e $1/3$, respectivamente. Essa divisão é repetida t vezes e um classificador de árvore de decisão é treinado em cada conjunto de treinamento. Por fim, as árvores de decisão são treinadas e avaliadas em seu respectivo conjunto de testes.

Figura 3 – Visão geral do procedimento MCFS



Fonte: Adaptado de Dрамиński et al. (2010, p. 4)

Para realizar a seleção de características, cada característica g é ranqueada de acordo com o seu desempenho nos classificadores por uma pontuação denominada *relative importance* (RI), onde quanto maior a pontuação, maior é a sua importância (BORNELÖV; KOMOROWSKI, 2016; DRAMIŃSKI et al., 2010):

$$RI_g = \frac{1}{M_g} \sum_{\tau=1}^{st} (wAcc_{\tau})^u \sum_{n_g(\tau)} IG(n_g(\tau)) \left(\frac{\text{no.in } n_g(\tau)}{\text{no.in } \tau} \right)^v \quad (2.4)$$

onde s é o número de subconjuntos, t é o número de divisões para cada subconjunto e M_g é o número de vezes que a característica g estava presente no conjunto de treinamento usado para construir a árvore de decisão. O $wAcc$ (Equação 2.5) é a precisão ponderada, que tem como finalidade avaliar a capacidade de classificação da árvore em um conjunto de testes, sendo calculada para cada árvore τ .

$$wAcc = \frac{1}{c} \sum_{i=1}^c \left(\frac{n_{ii}}{n_{i1} + n_{i2} + \dots + n_{ic}} \right) \quad (2.5)$$

onde c é o número de classes de decisão e n_{ij} é o número de amostras da classe i que foram classificados para a classe j .

Ademais, para cada $n_g(\tau)$ (um nó na árvore de decisão τ que usa a característica g) é calculado o *information gain* (IG), enquanto o $\text{no.in } n_g(\tau)$ representa o número de amostras do nó $n_g(\tau)$ contidos no conjunto de treinamento e o $\text{no.in } \tau$ é o número de amostras contidos na raiz da árvore. Por fim, existem dois fatores de ponderação (u e v) que determinam a importância, respectivamente, do $wAcc$ e do número de amostras no nó.

2.6.3 Métodos *Embedded*

Os métodos *Embedded* fornecem uma solução intermediária entre os métodos *filter* e *wrapper*, pois integra a seleção de características durante a execução do algoritmo de aprendizagem, sendo incorporados como uma funcionalidade normal ou estendida, e possuem menor complexidade computacional do que os métodos *wrapper*, uma vez que não precisam avaliar os conjuntos de características iterativamente (LI et al., 2017; JOVIĆ; BRKIĆ; BOGUNOVIĆ, 2015; SAEYS; INZA; LARRAÑAGA, 2007). Alguns métodos *embedded*: *lasso regularization* com diferentes variações (TIBSHIRANI, 1996; ZOU, 2006) e *random forests* (GENUER; POGGI; TULEAU-MALOT, 2010).

2.7 Avaliação de Desempenho

A avaliação dos algoritmos de recomendação foi realizada a partir do desempenho obtido no processo de recomendação de itens, utilizando os contextos considerados relevantes, através da aplicação de métricas populares, como a *Mean Average Error* (MAE) e a *Root Mean Squared Error* (RMSE), que têm como objetivo verificar a acurácia da

previsão das notas dos itens, e a $F\text{-measure}(N)$, utilizada para averiguar o quanto dos itens recomendados estão de acordo com os interesses dos usuários (GUNAWARDANA; SHANI, 2015).

Ademais, há outras métricas que são aplicadas para avaliar os algoritmos de recomendação, tais como: *Receiver Operating Characteristic* (ROC) (GOGA et al., 2013), *Normalized Discounted Cumulative Gain* (NDCG) (ZHANG et al., 2013), *Area Under Curve* (AUC) (FERNÁNDEZ-TOBIÁS; CANTADOR; PLAZA, 2013) e *Mean Average Precision* (MAP) (FERNÁNDEZ-TOBIÁS; CANTADOR; PLAZA, 2013).

Para avaliação dos algoritmos de seleção, foi feita uma análise de correlação entre a classificação dos contextos que apresentarem os melhores resultados na recomendação e os que foram selecionados e ordenados pelos algoritmos de seleção através do coeficiente de correlação tau de Kendall (τ). Também existem outras métricas que servem para medir o grau de correlação, sendo eles: o coeficiente de correlação de Pearson (r) (FIELLER; HARTLEY; PEARSON, 1957) e o coeficiente de correlação de Spearman (ρ) (SPEARMAN, 1904).

2.7.1 Avaliação dos algoritmos de recomendação

O MAE é calculado a partir do somatório do módulo da diferença entre as notas previstas (n_p) pelo sistema de recomendação, no conjunto de testes, e as notas reais (n_r) conhecidas pelo sistema para cada par de usuário-item sobre o número total (N_t) de pares de previsões das notas (n_p, n_r) (GUNAWARDANA; SHANI, 2015):

$$MAE = \frac{\sum_{i=1}^N |n_p - n_r|}{N_t} \quad (2.6)$$

Similarmente, o *Root Mean Squared Error* (RMSE) calcula a raiz quadrada do quadrado de todo o erro ($n_p - n_r$), com o propósito de punir grandes erros, por meio da seguinte fórmula (GUNAWARDANA; SHANI, 2015):

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (n_p - n_r)^2}{N_t}} \quad (2.7)$$

Por outro lado, as métricas apresentadas a seguir tem como finalidade calcular quanto o RS prevê corretamente os itens que serão interessantes para os usuários (GUNAWARDANA; SHANI, 2015). Diante disso, foi criado um conjunto de testes (C_t) contendo apenas os itens com nota 5 estrelas, que é o valor máximo da nota para esse conjunto de dados e o restante sendo o conjunto de treinamento (C_{tre}). Então, para cada item i com nota 5 estrelas atribuída pelo usuário u no C_t , foram realizados os seguintes passos (VÉRAS, 2016):

- As notas foram previstas para o item i e outros 100 itens escolhidos aleatoriamente no C_{tre} que não tiveram notas atribuídas pelo usuário u .
- Em ordem decrescente, foi criada uma lista de 101 itens (L_{101}) de acordo com as notas previstas e uma lista de recomendações $top-N$, que possui o número selecionado (N) de itens mais bem ranqueados da L_{101} . Se o item i aparecer na lista $top-N$, obtêm-se um *acerto*.

Sendo assim, as métricas *Recall*, *Precision* e *F-measure* podem ser definidas da seguinte maneira (CREMONESI; KOREN; TURRIN, 2010; CREMONESI; TRIPODI; TURRIN, 2011):

$$Recall(N) = \frac{\#acertos}{|Ct|} \quad (2.8)$$

$$Precision(N) = \frac{\#acertos}{N \times |Ct|} \quad (2.9)$$

$$F-measure(N) = \frac{2 \times Recall(N) \times Precision(N)}{Recall(N) + Precision(N)} \quad (2.10)$$

2.7.2 Avaliação dos algoritmos de seleção

O coeficiente de correlação tau de Kendall (τ) é uma métrica usada para avaliar o grau de similaridade entre a classificação de dois conjuntos com o mesmo número de elementos, contendo valores entre -1 e +1, sendo -1 quando a ordem dos elementos de um conjunto é exatamente o inverso do outro e +1 quando ambas as ordens dos conjuntos são idênticas (ABDI, 2007). Segundo Abdi (2007), o τ é calculado da seguinte forma:

- Seja X um conjunto de N elementos, onde $X = \{a, b, \dots, x, y, z\}$.
- Quando a ordem dos elementos do conjunto é relevante, obtemos um conjunto ordenado que pode ser representado pela ordem de classificação dos elementos. Por exemplo, um conjunto de 4 elementos: $X = \{a, b, c, d\}$, onde existe um conjunto ordenado $Y = [a, d, b, c]$, que apresenta a seguinte ordem de classificação dos elementos = [1,3,4,2].
- O conjunto ordenado Y pode ser decomposto em pares ordenados, contendo o seguinte número de pares: $N(N - 1)/2$. Nesse caso, o conjunto Y pode ser decomposto em 6 pares ordenados: $\{[a, d], [a, b], [a, c], [d, b], [d, c], [b, c]\}$.

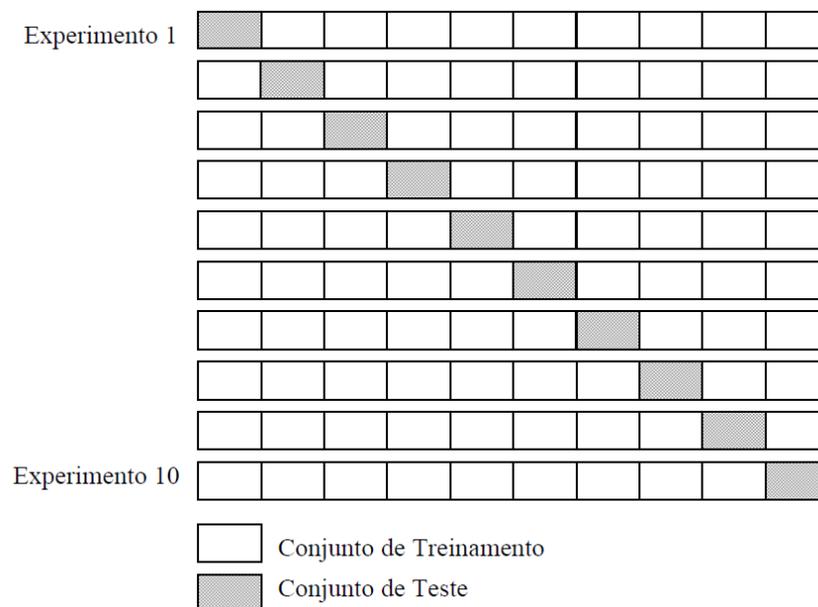
- Para comparar dois conjuntos ordenados que possuem os mesmos elementos, a abordagem de Kendall realiza a contagem do número de pares diferentes (n_{pd}) entre os conjuntos. Deste modo, o coeficiente de correlação tau de Kendall apresenta a seguinte fórmula:

$$\tau = 1 - \frac{2 \times n_{pd}}{N(N - 1)} \quad (2.11)$$

2.7.3 Validação cruzada

A validação cruzada é um método estatístico que tem como estratégia particionar o conjunto de dados disponíveis, uma ou várias vezes, em dois segmentos (um será utilizado como conjunto de treinamento e o outro para validação do modelo) (ARLOT; CELISSE, 2010; REFAEILZADEH; TANG; LIU, 2009). Uma das formas existentes de validação cruzada é o método *k-fold*, onde o conjunto de dados é dividido aleatoriamente em k subconjuntos, mutuamente excludentes, contendo tamanhos aproximadamente iguais (KOHAVI, 1995). Além disso, o treinamento e o teste são realizados k vezes e para cada iteração o treinamento é aplicado a $k-1$ subconjuntos e o teste ao subconjunto restante (Figura 4) (DELEN; WALKER; KADAM, 2005).

Figura 4 – Validação cruzada 10-fold



Fonte: Florencio Filho (2009)

3 Trabalhos relacionados

Neste capítulo serão apresentados trabalhos relacionados à seleção de contextos relevantes que exploraram três tipos de abordagens (BRAUNHOFER; RICCI, 2017): (1) identificar os fatores contextuais que devem ser usados pelo sistema antes de realizar as recomendações, (2) selecionar após a aquisição das preferências e dados contextuais aqueles fatores que demonstraram ser mais úteis para calcular corretamente as recomendações e (3) selecionar os fatores contextuais dos usuários no momento em que eles inserem uma nota para um item.

Vargas-Govea, González-Serna e Ponce-Medellin (2011) identificaram contextos relevantes através de seleção de características utilizando o algoritmo Las Vegas Filter (LVF). O LVF gera repetidamente subconjuntos aleatórios de fatores contextuais, calcula sua medida de avaliação com base em um critério de inconsistência, que testa os subconjuntos gerados para a previsão da nota, e, finalmente, retorna o subconjunto de contextos que apresentou o melhor resultado. Uma vez que os contextos relevantes são encontrados, eles são avaliados para descobrir a possibilidade da obtenção de um melhor desempenho do RS. Nesse artigo, a avaliação foi realizada em cima de três abordagens de recomendações: (1) sem características contextuais (ou seja, sem contexto); (2) a partir da fusão de aspectos sociais (através do uso de tags, ex.: delicioso, horrível, barulhento) e contextuais; (3) empregar apenas o conjunto de regras semânticas usado como contexto. Todavia, foi perceptível que a abordagem 3 não apresentou um resultado adequado, pois foi visualizado, na maioria dos casos, um desempenho significativamente pior ou, no melhor cenário, ligeiramente melhor à abordagem de “sem características contextuais”. Os autores informam que é necessário uma análise profunda do conjunto de regras utilizado para determinar o motivo desse baixo desempenho.

Baltrunas et al. (2012), Baltrunas, Ludwig e Ricci (2011), Baltrunas et al. (2011) aplicaram um *web survey* (“pesquisa na web”) para definir quais contextos são relevantes, esse *survey* é feito inicialmente requisitando aos usuários avaliar se as condições contextuais selecionadas aleatoriamente afetam positivamente, negativamente ou “não influencia” em suas decisões para visitar certo ponto turístico. Após essa etapa, são realizados cálculos estatísticos para descobrir o quanto cada fator contextual influencia na tomada de decisão do usuário. Uma limitação dessa abordagem é a restrição do conjunto de dados que pode ser utilizado, pois o cálculo da relevância do contexto só é possível se houver a quantificação de cada condição contextual através do questionário proposto.

Odic et al. (2012) identificaram duas abordagens para determinar a relevância do contexto: a primeira é definida como avaliação (*assessment*) e baseia-se em um questionário

com 12 perguntas, uma para cada informação contextual no banco de dados LDOS-CoMoDa, enquanto a segunda é denotada como detecção (*detection*) que é a realizado a partir da mineração dos dados de classificação. Para determinar qual dessas duas abordagens é melhor, eles usaram dados reais de classificação de filmes e dados de pesquisa em que os usuários foram convidados a avaliar a influência de cada condição contextual em seu comportamento de classificação. Com base nos resultados obtidos, eles concluíram que o método “*detection*” é melhor do que “*assessment*” para identificar os fatores contextuais a serem utilizados no modelo de previsão da nota, contudo, é possível aprimorar o método “*detection*” aplicado através da identificação de contextos relevantes para cada usuário separadamente, ao invés de modo generalizado (para toda população de usuários e itens).

Odić et al. (2013) propõem utilizar medidas estatísticas com “análise de poder” para definir quais contextos são relevantes, i.e., teste qui-quadrado de Pearson e teste Freeman-Halton. Dentre essas medidas, os autores consideraram o teste Freeman-Halton como o mais apto para ser aplicado no banco de dados LDOS-CoMoDa, pois a partir dos resultados obtidos, essa medida demonstrou-se ser mais útil e flexível para identificar os fatores contextuais relevantes e irrelevantes, além de obter um melhor desempenho na recomendação. Entretanto, essas medidas foram aplicadas em um conjunto de dados baseado em um único domínio e possui um tamanho reduzido, o que dificulta a obtenção de resultados satisfatórios na pesquisa, devido à alta esparsidade, ainda que os autores tenham informado que o aumento de dados não afetará “drasticamente” o seu resultado.

Braunhofer e Ricci (2017), Braunhofer e Ricci (2016), Braunhofer, Fernández-Tobías e Ricci (2015) utilizaram a estratégia denominada *Largest Deviation*, que estima o impacto de cada condição contextual na previsão da nota e, assim, tem o objetivo de identificar quais são os fatores contextuais úteis para serem extraídos do usuário no momento em que ele estiver classificando um item. Essa estratégia foi utilizada e comparada com outras identificadas no estado-da-arte, um exemplo é o Teste Freeman-Halton. Nos experimentos realizados, para cada par de itens de usuário (u, i) no conjunto de candidatos, os N fatores contextuais mais úteis são computados. Quando N vai de um até três fatores contextuais, foi demonstrado um melhor desempenho do *Largest Deviation* nas seguintes métricas: U-MAE, Precision@10 and Recall@10. Porém, ao utilizar N igual a quatro ou mais fatores, a diferença de desempenho se tornou estatisticamente insignificante. O comportamento referido já era esperado pelos autores, pois o trabalho afirma que minimizar e poupar fatores contextuais para serem utilizados na recomendação é fundamental para ganhos significativos de desempenho.

Véras (2016) aplicou a utilização de um método denominado *InfoGainAttributeEval*, fornecido pela ferramenta WEKA (HALL et al., 2009), para a seleção de contextos relevantes, que avalia o valor de um atributo contextual medindo o ganho de informação para uma “classe”, nesse caso foi utilizado como classe, o valor de avaliação do usuário atribuído

ao item, podendo variar de 1 a 5. Um fato interessante é que, diferentemente de outros trabalhos do estado-da-arte, o método foi aplicado em conjuntos de dados de “domínio cruzado”. No entanto, a partir dos resultados obtidos, foi selecionado uma dimensão contextual que influenciou negativamente no desempenho do sistema, principalmente no algoritmo de pré-filtragem.

Existem diversas abordagens para a seleção de contextos, diferentes bases de dados utilizadas (Tabela 3) e distintas formas de como representar, obter e avaliar os contextos (Tabela 4) nos trabalhos relacionados. Contudo, de acordo com nosso conhecimento, foi encontrado apenas um trabalho relevante que aplicou essa seleção sobre conjuntos de dados que contenham informações contextuais e de domínio cruzado. Portanto, a análise dos métodos existentes no estado-da-arte se faz necessária para a realização de um estudo comparativo, que, diferentemente dos trabalhos propostos, tem o propósito de identificar a melhor forma de selecionar as dimensões contextuais mais relevantes para o tipo de sistema CD-CARS.

Tabela 3 – Tabela de resumo dos trabalhos relacionados (parte 1)

Trabalho(s)	Método(s) de seleção	Abordagens de seleção	Tipo de dados
Vargas-Govea, González-Serna e Ponce-Medellm (2011)	Las Vegas Filter	(2)	CARS
Baltrunas et al. (2012), Baltrunas, Ludwig e Ricci (2011), Baltrunas et al. (2011)	Survey	(1)	CARS
Odic et al. (2012)	Survey, Teste Freeman-Halton	(1) e (2)	CARS
Odić et al. (2013)	Teste qui-quadrado, Teste Freeman-Halton	(2)	CARS
Braunhofer e Ricci (2017), Braunhofer e Ricci (2016), Braunhofer, Fernández-Tobías e Ricci (2015)	Largest Deviation, Mutual Information, Teste Freeman-Halton, mRMR	(2) e (3)	CARS
Véras (2016)	Information Gain	(2)	CD-CARS
Trabalho proposto	Information Gain, Teste qui-quadrado, mRMR, MCFS	(2)	CD-CARS

Fonte – O próprio autor

Tabela 4 – Tabela de resumo dos trabalhos relacionados (parte 2)

Trabalho(s)	Representação do contexto	Obtenção do contexto	Métricas de avaliação	Abordagens de avaliação
Vargas-Govea, González-Serna e Ponce-Medellm (2011)	Ontologia	Inferindo	Precision, Recall, NDCG	Métricas probabilística e de classificação
Baltrunas et al. (2012), Baltrunas, Ludwig e Ricci (2011), Baltrunas et al. (2011)	Chave-Valor	Explicitamente	Precision, Recall, MAE	Métricas probabilística e de classificação
Odic et al. (2012)	Chave-Valor	Explicitamente	RMSE	Métrica probabilística
Odić et al. (2013)	Chave-Valor	Explicitamente	RMSE	Métrica probabilística
Braunhofer e Ricci (2017), Braunhofer e Ricci (2016), Braunhofer, Fernández-Tobías e Ricci (2015)	Chave-Valor	Explicitamente, Implicitamente e Inferindo	MAE, Precision, Recall	Métricas probabilística e de classificação
Véras (2016)	Chave-Valor	Implicitamente e Inferindo	MAE, RMSE, F-measure	Métricas probabilística e de classificação
Trabalho proposto	Chave-Valor	Implicitamente e Inferindo	MAE, RMSE, F-measure, Correlação tau de Kendall	Métricas probabilística e de classificação

Fonte – O próprio autor

4 Metodologia

A seguir são apresentados os recursos necessários para a configuração dos experimentos, os métodos de avaliação aplicados e como os experimentos de fato foram realizados.

4.1 Configuração experimental

As próximas subseções descrevem os conjuntos de dados e os algoritmos utilizados para a seleção dos contextos.

4.1.1 Conjuntos de dados

Os conjuntos de dados usados neste trabalho foram providos por [Veras et al. \(2015\)](#), que consistem em conjuntos contendo dois domínios mais relacionados⁹ (livro e televisão) e outros considerando dois domínios menos relacionados (livro e música), ambos com diferentes níveis de sobreposição (10%, 50% e 100%). Esses conjuntos foram adaptados para utilizar somente os dados que interessam o trabalho em questão, tais como: as notas atribuídas aos itens (entre 1 e 5 estrelas) e informações sobre três dimensões contextuais (*Tempo*, *Local* e *Companhia*) que podem ser resumidas nas tabelas 5, 6 e estão disponibilizados no github¹⁰. Para as dimensões *Tempo* e *Local*, as informações contextuais foram obtidas implicitamente através dos dados sobre as datas das notas e os endereços dos usuários, respectivamente, enquanto para a dimensão *Companhia*, as informações contextuais foram inferidas a partir das opiniões fornecidas pelos usuários ([VERAS et al., 2015](#)).

Tabela 5 – Tabela de descrição das informações contextuais

Dimensão Contextual	Atributo Contextual	Valores possíveis (numericamente)
Tempo	Dia	domingo a sábado (1 a 7)
Local	Cidade	2838 (0 a 2837)
Companhia	Tipo de Companhia	sozinho, acompanhado, família, amigos, cônjuge e colegas (0 a 5)

Fonte – O próprio autor

⁹ A relação entre domínios distintos é realizada de acordo com os gêneros dos itens, quanto mais gêneros de itens em comum dentre os domínios, maior a intensidade dessa relação (ex.: livro e televisão possuem vários gêneros em comum como: “educação”, “ficção científica”, “romance”, etc.) ([VÉRAS, 2016](#))

¹⁰ <https://github.com/VictorSales/cdcars-select-contexts>

Tabela 6 – Tabela da frequência das dimensões contextuais em relação a quantidade total de notas em cada conjunto de dados

Conjunto de Dados	Tempo	Local	Companhia
<i>book-tv-10overlap-target-book</i>	514965 (100%)	244913 (48%)	104353 (20%)
<i>book-tv-10overlap-target-tv</i>	851680 (100%)	369663 (43%)	172627 (20%)
<i>book-tv-50overlap-target-book</i>	819335 (100%)	389625 (48%)	169961 (21%)
<i>book-tv-50overlap-target-tv</i>	1011324 (100%)	446297 (44%)	206512 (20%)
<i>book-tv-100overlap</i>	1249949 (100%)	557018 (45%)	251707 (20%)
<i>book-music-10overlap-target-book</i>	347805 (100%)	172780 (50%)	35785 (10%)
<i>book-music-10overlap-target-music</i>	770030 (100%)	350664 (46%)	190478 (25%)
<i>book-music-50overlap-target-book</i>	635947 (100%)	317421 (50%)	116360 (18%)
<i>book-music-50overlap-target-music</i>	897227 (100%)	407003 (45%)	197571 (22%)
<i>book-music-100overlap</i>	1031386 (100%)	478510 (46%)	207010 (20%)

Fonte – O próprio autor

4.1.2 Algoritmos de seleção de contexto

Os algoritmos de seleção de contextos explicitados na [subseção 2.6.2](#) e as ferramentas utilizadas para efetuar os métodos de seleção de contextos foram os seguintes:

- *Information Gain*: Esse algoritmo foi executado utilizando a ferramenta WEKA 3.8 (HALL et al., 2009) com a configuração apresentada na [Tabela 7](#) e o formato de arquivo *.arff* exemplificado no [Apêndice A](#).

Tabela 7 – Tabela da configuração dos parâmetros necessários para execução do algoritmo *Information Gain*

Avaliador de atributos	Método de pesquisa	Modo de seleção de atributos	Classe
<i>InfoGainAttributeEval</i>	<i>Ranker</i>	Validação Cruzada 10-fold	<i>Rating</i> (Nota do item)

Fonte – O próprio autor

- Teste qui-quadrado: Esse algoritmo foi executado utilizando a ferramenta WEKA 3.8 (HALL et al., 2009) com a configuração apresentada na [Tabela 8](#) e o formato de arquivo *.arff* exemplificado no [Apêndice A](#).

Tabela 8 – Tabela da configuração dos parâmetros necessários para execução do algoritmo Teste qui-quadrado

Avaliador de atributos	Método de pesquisa	Modo de seleção de atributos	Classe
<i>ChiSquaredAttributeEval</i>	<i>Ranker</i>	Validação Cruzada 10-fold	<i>Rating</i> (Nota do item)

Fonte – O próprio autor

- *Minimum Redundancy Maximum Relevance* (MRMR): Foi executado utilizando os dados de entrada em formato *.csv* sem cabeçalho (Apêndice B) e a implementação distribuída (aplicando os valores padrão nos parâmetros da função) por um repositório de seleção de características em Python denominado *scikit-feature* (LI et al., 2017), que é construído sobre uma biblioteca de aprendizagem de máquina *scikit-learn*¹¹ como pode ser visto no Apêndice C.
- *Monte Carlo Feature Selection* (MCFS): Foi executado utilizando os dados de entrada em formato *.csv* com cabeçalho (Apêndice D) e a implementação fornecida (aplicando os valores padrão nos parâmetros da função) pelo pacote *rmcfs*¹² da linguagem de programação R (IHAKA; GENTLEMAN, 1996) (linguagem para análise de dados e construção de gráficos) como pode ser visto no Apêndice E.

Esses algoritmos foram utilizados por serem comumente aplicados em trabalhos com propósito de seleção de características (LI et al., 2017) e nos trabalhos relacionados (ODIC et al., 2012; ODIC et al., 2013; VÉRAS, 2016; BRAUNHOFER; RICCI, 2017), ademais, demandam menos tempo de processamento e são mais rápidos por serem técnicas pertencentes aos métodos de filtragem (SAEYS; INZA; LARRAÑAGA, 2007).

No entanto, alguns algoritmos não foram aplicados neste trabalho, sendo eles: o teste *Freeman-Halton*, que apresentou dificuldade de execução em tempo hábil e que possui a recomendação de não ser aplicado em conjuntos de dados com um tamanho de amostras considerável (ex.: *cd-cars-datasets*) (KIM, 2017; ODIC et al., 2013), e o Las Vegas Filter (LVF), que não foi executado nos experimentos, pois obteve resultados inesperados em Vargas-Govea, González-Serna e Ponce-Medellin (2011), onde a abordagem de não utilizar contextos obteve melhor desempenho em comparação com utilizar os contextos relevantes no processo de recomendação, os autores informaram a necessidade de uma análise profunda para verificar a razão desse baixo desempenho (VARGAS-GOVEA; GONZÁLEZ-SERNA; PONCE-MEDELLIN, 2011), dessa forma, desencorajou o uso desse algoritmo no presente trabalho.

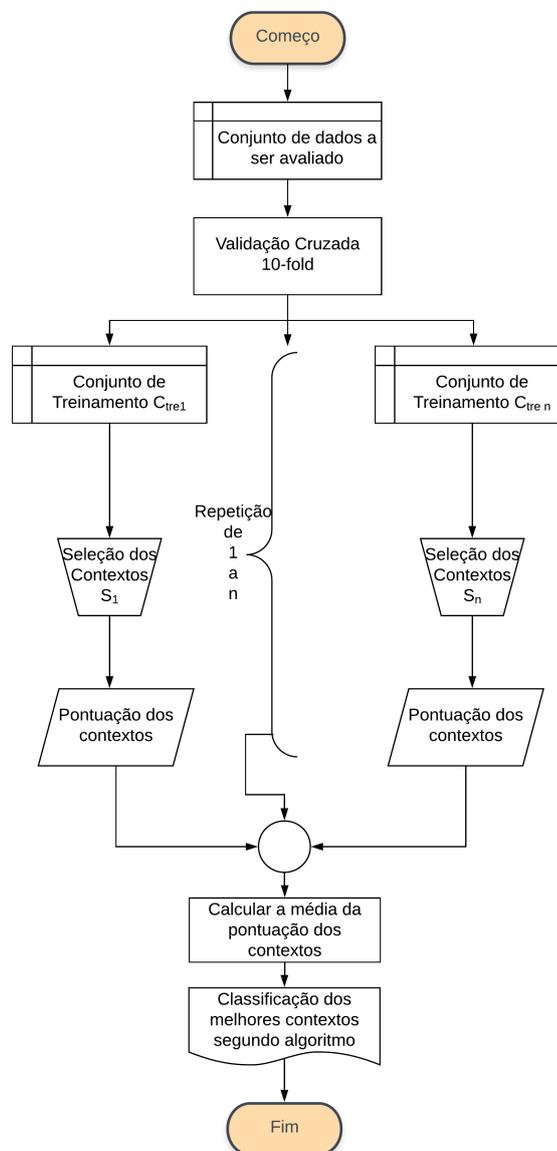
¹¹ <http://scikit-learn.org/>

¹² <https://cran.r-project.org/web/packages/rmcfs/>

4.2 Avaliação de Desempenho

A priori, para cada algoritmo de seleção de contextos, foi utilizado o método de validação cruzada n -fold (com $n=10$ e uso de sementes aleatórias em prol de gerar amostras distintas) no conjunto de dados a ser avaliado, a fim de evitar o problema da seleção tendenciosa (AMBROISE; MCLACHLAN, 2002; KRAWCZUK; LUKASZUK, 2016), e, por conseguinte, o algoritmo em questão foi executado em cada conjunto de treinamento (C_{tre}) repetidamente, como ilustrado na Figura 5. Posteriormente os contextos foram ordenados pela pontuação média obtida no processo de seleção a fim de estabelecer o *ranking* daqueles considerados relevantes.

Figura 5 – Processo empregado para seleção dos contextos relevantes



Fonte: O próprio autor

Dessa forma, para cada algoritmo de seleção de contextos e conjunto de dados, foram aferidos os resultados dos experimentos realizados em Vêras (2016) pelos algoritmos de recomendação: *Pre-Filtering* (PreF) e *Post-Filtering* (PostF) utilizando as diversas dimensões contextuais: *Tempo*, *Local* e *Companhia*, possuindo respectivamente os atributos contextuais: dia, cidade e companhia. Esses resultados foram compilados em várias listas ordenadas de acordo com o desempenho obtido pelos contextos nos algoritmos de recomendação ao utilizar as métricas: *Mean Average Error* (MAE), *Root Mean Squared Error* (RMSE) e *F-measure*, diante disso, não foi necessário executar os algoritmos de recomendação neste trabalho.

Por fim, foi calculado o grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) entre a classificação dos atributos contextuais (dia, cidade e companhia) que apresentaram os melhores índices de acordo com as métricas adotadas sobre a classificação resultante desses atributos na seleção de contextos relevantes. Por exemplo, aplicando a Métrica MAE, a classificação dos contextos que obtiveram o melhor desempenho na recomendação, em ambos algoritmos de recomendação (PreF e PostF), foi o seguinte: 1º - dia, 2º - cidade, 3º - companhia. Mas, para o algoritmo de seleção de contextos, a classificação foi: 1º - cidade, 2º - dia, 3º - companhia. Sendo assim, é possível calcular o quanto a classificação do algoritmo de seleção é similar em relação aos algoritmos de recomendação (Figura 6).

Figura 6 – Cenários de classificação dos algoritmos

	PreF	PostF	Alg. Sel.
1º	dia	dia	cidade
2º	cidade	cidade	dia
3º	companhia	companhia	companhia

Fonte: O próprio autor

5 Resultados e discussão

Neste capítulo serão expostos os experimentos realizados através do processo proposto na [seção 4.2](#) e apresentado um estudo comparativo entre os algoritmos de seleção: *Information Gain* (IG), Teste qui-quadrado (χ^2), *Minimum Redundancy Maximum Relevance* (MRMR) e *Monte Carlo Feature Selection* (MCFS), que foram descritos na [subseção 2.6.2](#). Em suma, a [seção 5.1](#) detalha os resultados obtidos pelos algoritmos de seleção em conjuntos de dados que contém os domínios *Livro* e *Televisão*; a [seção 5.2](#) detalha os resultado obtidos pelos algoritmos de seleção em conjuntos de dados que contém os domínios *Livro* e *Música*; a [seção 5.3](#) exhibe resumos dos resultados dos experimentos; na [seção 5.4](#) discute-se os resultados aferidos. Por fim, a [seção 5.5](#) apresenta as considerações finais deste capítulo.

5.1 Conjuntos de dados com domínios *Livro* e *Televisão*

As subseções a seguir apresentam os resultados dos conjuntos de dados variando o nível de sobreposição e o domínio alvo daqueles que possuem os domínios *Livro* e *Televisão*.

5.1.1 10% de sobreposição e livro como domínio alvo

A [Tabela 9](#) relata a classificação dos contextos (dia, cidade e companhia) que obtiveram o melhor desempenho pelos algoritmos de recomendação (PreF, PostF), ao utilizar as métricas MAE, RMSE e *F-Measure* (com $N=5$), sendo possível observar que o contexto *dia* atingiu o maior desempenho, em relação aos outros contextos, em todas as métricas aplicadas. Enquanto, o contexto *companhia*, geralmente obteve o pior desempenho, exceto na métrica *F-Measure* ($N=5$) com o algoritmo de recomendação PreF.

Tabela 9 – Classificação segundo algoritmos de recomendação no conjunto de dados *book-tv-10overlap-target-book*

MAE		RMSE		<i>F-measure</i> ($N=5$)	
PreF	PostF	PreF	PostF	PreF	PostF
1º - dia	1º - dia				
2º - cidade	2º - cidade	2º - cidade	2º - cidade	2º - compa- nhia	2º - cidade
3º - compa- nhia	3º - compa- nhia	3º - compa- nhia	3º - compa- nhia	3º - cidade	3º - compa- nhia

Fonte – O próprio autor

Na [Tabela 10](#) é descrita como os algoritmos de seleção de contextos estabeleceram a classificação daqueles contextos considerados relevantes. Onde nota-se que apenas o MRMR apresentou um resultado distinto na ordem de importância.

Tabela 10 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados *book-tv-10overlap-target-book*

IG	χ^2	MRMR	MCFS
1º - cidade	1º - cidade	1º - cidade	1º - cidade
2º - dia	2º - dia	2º - companhia	2º - dia
3º - companhia	3º - companhia	3º - dia	3º - companhia

Fonte – O próprio autor

A [Tabela 11](#) demonstra a partir do Kendall, o quanto a classificação dos contextos nos algoritmos de seleção é similar à classificação nos algoritmos de recomendação pelas métricas MAE, RMSE e *F-measure* (com N=5). Com o auxílio da tabela em questão, torna-se perceptível que o MRMR obteve o pior resultado dentre as técnicas nesse conjunto de dados, pois possuiu o menor coeficiente em todos os cenários, enquanto as outras técnicas apresentaram o mesmo coeficiente para cada cenário e nenhuma concordância perfeita foi obtida.

Tabela 11 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados *book-tv-10overlap-target-book*

Algoritmos de seleção	Kendall (MAE)		Kendall (RMSE)		Kendall (F-measure)	
	PreF	PostF	PreF	PostF	PreF	PostF
IG	+0,33	+0,33	+0,33	+0,33	-0,33	+0,33
χ^2	+0,33	+0,33	+0,33	+0,33	-0,33	+0,33
MRMR	-0,33	-0,33	-0,33	-0,33	-1	-0,33
MCFS	+0,33	+0,33	+0,33	+0,33	-0,33	+0,33

Fonte – O próprio autor

5.1.2 10% de sobreposição e televisão como domínio alvo

A [Tabela 12](#) relata a classificação dos contextos (dia, cidade e companhia) que obtiveram o melhor desempenho pelos algoritmos de recomendação (PreF, PostF), ao utilizar as métricas MAE, RMSE e *F-Measure* (com N=5), sendo possível observar que o contexto *dia* atingiu o maior desempenho, em relação aos outros contextos, na métrica *F-Measure* (N=5) de ambos algoritmos e nas métricas MAE e RMSE do algoritmo PreF. Enquanto, o contexto *cidade* obteve o maior desempenho nas métricas MAE e RMSE do algoritmo PostF.

Tabela 12 – Classificação segundo algoritmos de recomendação no conjunto de dados *book-tv-10overlap-target-tv*

MAE		RMSE		<i>F-measure</i> ($N=5$)	
PreF	PostF	PreF	PostF	PreF	PostF
1º - dia	1º - cidade	1º - dia	1º - cidade	1º - dia	1º - dia
2º - cidade	2º - dia	2º - cidade	2º - dia	2º - compa- nhia	2º - cidade
3º - compa- nhia	3º - compa- nhia	3º - compa- nhia	3º - compa- nhia	3º - cidade	3º - compa- nhia

Fonte – O próprio autor

Na [Tabela 13](#) é descrita como os algoritmos de seleção de contextos estabeleceram a classificação daqueles contextos considerados relevantes. O IG e o χ^2 apresentaram a mesma classificação, enquanto o MRMR apresentou a classificação inversa do MCFS.

Tabela 13 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados *book-tv-10overlap-target-tv*

IG	χ^2	MRMR	MCFS
1º - cidade	1º - cidade	1º - cidade	1º - dia
2º - dia	2º - dia	2º - companhia	2º - cidade
3º - companhia	3º - companhia	3º - dia	3º - companhia

Fonte – O próprio autor

A [Tabela 14](#) demonstra a partir do Kendall, o quanto a classificação dos contextos nos algoritmos de seleção é similar à classificação nos algoritmos de recomendação pelas métricas MAE, RMSE e *F-measure* (com $N=5$). Com o auxílio da tabela em questão, torna-se perceptível que o MRMR obteve o pior resultado dentre as técnicas nesse conjunto de dados, pois possuiu o menor coeficiente em todos os cenários, enquanto o MCFS apresentou melhor resultado nos cenários com o algoritmo PreF e com o algoritmo PostF no *F-measure* ($N=5$), por outro lado o IG e χ^2 apresentaram melhor resultado com o algoritmo PostF no MAE e RMSE.

Tabela 14 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados *book-tv-10overlap-target-tv*

Algoritmos de seleção	Kendall (MAE)		Kendall (RMSE)		Kendall (F-measure)	
	PreF	PostF	PreF	PostF	PreF	PostF
IG	+0,33	+1	+0,33	+1	-0,33	+0,33
χ^2	+0,33	+1	+0,33	+1	-0,33	+0,33
MRMR	-0,33	+0,33	-0,33	+0,33	-1	-0,33
MCFS	+1	+0,33	+1	+0,33	+0,33	+1

Fonte – O próprio autor

5.1.3 50% de sobreposição e livro como domínio alvo

A [Tabela 15](#) relata a classificação dos contextos (dia, cidade e companhia) que obtiveram o melhor desempenho pelos algoritmos de recomendação (PreF, PostF), ao utilizar as métricas MAE, RMSE e *F-Measure* (com $N=5$), sendo possível observar que o contexto *dia* atingiu o maior desempenho, em relação aos outros contextos, nas métricas MAE, F-measure e RMSE do algoritmo PostF. Enquanto, o contexto *companhia*, geralmente obteve o pior desempenho, exceto na métrica F-Measure ($N=5$) com o algoritmo de recomendação PreF.

Tabela 15 – Classificação segundo algoritmos de recomendação no conjunto de dados *book-tv-50overlap-target-book*

MAE		RMSE		<i>F-measure (N=5)</i>	
PreF	PostF	PreF	PostF	PreF	PostF
1º - dia	1º - dia	1º - cidade	1º - dia	1º - dia	1º - dia
2º - cidade	2º - cidade	2º - dia	2º - cidade	2º - companhia	2º - cidade
3º - companhia	3º - companhia	3º - companhia	3º - companhia	3º - cidade	3º - companhia

Fonte – O próprio autor

Na [Tabela 16](#) é descrita como os algoritmos de seleção de contextos estabeleceram a classificação daqueles contextos considerados relevantes. Onde nota-se que todos os algoritmos apresentaram a mesma classificação.

Tabela 16 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados *book-tv-50overlap-target-book*

IG	χ^2	MRMR	MCFS
1º - cidade	1º - cidade	1º - cidade	1º - cidade
2º - dia	2º - dia	2º - dia	2º - dia
3º - companhia	3º - companhia	3º - companhia	3º - companhia

Fonte – O próprio autor

A [Tabela 17](#) demonstra a partir do Kendall, o quanto a classificação dos contextos nos algoritmos de seleção é similar à classificação nos algoritmos de recomendação pelas métricas MAE, RMSE e *F-measure* (com N=5). Todos os algoritmos de seleção de contextos possuíram a mesma ordem de relevância dos contextos ([Tabela 16](#)), diante disso, o resultado é o mesmo em todos os cenários e apresentaram apenas uma concordância perfeita com o algoritmo de recomendação PreF na métrica RMSE.

Tabela 17 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados *book-tv-50overlap-target-book*

Algoritmos de seleção	Kendall (MAE)		Kendall (RMSE)		Kendall (F-measure)	
	PreF	PostF	PreF	PostF	PreF	PostF
IG	+0,33	+0,33	+1	+0,33	-0,33	+0,33
χ^2	+0,33	+0,33	+1	+0,33	-0,33	+0,33
MRMR	+0,33	+0,33	+1	+0,33	-0,33	+0,33
MCFS	+0,33	+0,33	+1	+0,33	-0,33	+0,33

Fonte – O próprio autor

5.1.4 50% de sobreposição e televisão como domínio alvo

A [Tabela 18](#) relata a classificação dos contextos (dia, cidade e companhia) que obtiveram o melhor desempenho pelos algoritmos de recomendação (PreF, PostF), ao utilizar as métricas MAE, RMSE e *F-Measure* (com N=5), sendo possível observar que o contexto *dia* atingiu o maior desempenho, em relação aos outros contextos, em todas as métricas aplicadas. Enquanto, o contexto *companhia*, geralmente obteve o pior desempenho, exceto na métrica *F-Measure* (N=5) com o algoritmo de recomendação PreF.

Tabela 18 – Classificação segundo algoritmos de recomendação no conjunto de dados *book-tv-50overlap-target-tv*

MAE		RMSE		<i>F-measure</i> ($N=5$)	
PreF	PostF	PreF	PostF	PreF	PostF
1º - dia	1º - dia				
2º - cidade	2º - cidade	2º - cidade	2º - cidade	2º - companhia	2º - cidade
3º - companhia	3º - companhia	3º - companhia	3º - companhia	3º - cidade	3º - companhia

Fonte – O próprio autor

Na [Tabela 19](#) é descrita como os algoritmos de seleção de contextos estabeleceram a classificação daqueles contextos considerados relevantes. Onde nota-se que apenas o MCFS apresentou um resultado distinto na ordem de importância.

Tabela 19 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados *book-tv-50overlap-target-tv*

IG	χ^2	MRMR	MCFS
1º - cidade	1º - cidade	1º - cidade	1º - dia
2º - dia	2º - dia	2º - dia	2º - cidade
3º - companhia	3º - companhia	3º - companhia	3º - companhia

Fonte – O próprio autor

A [Tabela 20](#) demonstra a partir do Kendall, o quanto a classificação dos contextos nos algoritmos de seleção é similar à classificação nos algoritmos de recomendação pelas métricas MAE, RMSE e *F-measure* (com $N=5$). Com o auxílio da tabela em questão, torna-se perceptível que o MCFS possuiu o melhor resultado dentre as técnicas nesse conjunto de dados, pois obteve concordância perfeita entre as classificações de 5 dos 6 cenários, ratificando a classificação apresentada pela técnica e refletindo a intensidade da relevância desses contextos no processo de recomendação.

Tabela 20 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados *book-tv-50overlap-target-tv*

Algoritmos de seleção	Kendall (MAE)		Kendall (RMSE)		Kendall (F-measure)	
	PreF	PostF	PreF	PostF	PreF	PostF
IG	+0,33	+0,33	+0,33	+0,33	-0,33	+0,33
χ^2	+0,33	+0,33	+0,33	+0,33	-0,33	+0,33
MRMR	+0,33	+0,33	+0,33	+0,33	-0,33	+0,33
MCFS	+1	+1	+1	+1	+0,33	+1

Fonte – O próprio autor

5.1.5 100% de sobreposição e livro como domínio alvo

A [Tabela 21](#) relata a classificação dos contextos (dia, cidade e companhia) que obtiveram o melhor desempenho pelos algoritmos de recomendação (PreF, PostF), ao utilizar as métricas MAE, RMSE e *F-Measure* (com $N=5$), sendo possível observar que o contexto *dia* atingiu o maior desempenho, em relação aos outros contextos, em todas as métricas aplicadas. Enquanto, o contexto *companhia*, geralmente obteve o pior desempenho, exceto na métrica *F-Measure* ($N=5$) com o algoritmo de recomendação PreF.

Tabela 21 – Classificação segundo algoritmos de recomendação no conjunto de dados *book-tv-100overlap-target-book*

MAE		RMSE		<i>F-measure</i> ($N=5$)	
PreF	PostF	PreF	PostF	PreF	PostF
1º - dia	1º - dia				
2º - cidade	2º - cidade	2º - cidade	2º - cidade	2º - companhia	2º - cidade
3º - companhia	3º - companhia	3º - companhia	3º - companhia	3º - cidade	3º - companhia

Fonte – O próprio autor

Na [Tabela 22](#) é descrita como os algoritmos de seleção de contextos estabeleceram a classificação daqueles contextos considerados relevantes. Onde nota-se que apenas o MCFS apresentou um resultado distinto na ordem de importância.

Tabela 22 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados *book-tv-100overlap-target-book*

IG	χ^2	MRMR	MCFS
1º - cidade	1º - cidade	1º - cidade	1º - dia
2º - dia	2º - dia	2º - dia	2º - cidade
3º - companhia	3º - companhia	3º - companhia	3º - companhia

Fonte – O próprio autor

A [Tabela 23](#) demonstra a partir do Kendall, o quanto a classificação dos contextos nos algoritmos de seleção é similar à classificação nos algoritmos de recomendação pelas métricas MAE, RMSE e *F-measure* (com N=5). Com o auxílio da tabela em questão, torna-se perceptível que o MCFS possuiu o melhor resultado dentre as técnicas nesse conjunto de dados, pois obteve concordância perfeita entre as classificações de 5 dos 6 cenários, ratificando a classificação apresentada pela técnica e refletindo a intensidade da relevância desses contextos no processo de recomendação.

Tabela 23 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados *book-tv-100overlap-target-book*

Algoritmos de seleção	Kendall (MAE)		Kendall (RMSE)		Kendall (F-measure)	
	PreF	PostF	PreF	PostF	PreF	PostF
IG	+0,33	+0,33	+0,33	+0,33	-0,33	+0,33
χ^2	+0,33	+0,33	+0,33	+0,33	-0,33	+0,33
MRMR	+0,33	+0,33	+0,33	+0,33	-0,33	+0,33
MCFS	+1	+1	+1	+1	+0,33	+1

Fonte – O próprio autor

5.1.6 100% de sobreposição e televisão como domínio alvo

A [Tabela 24](#) relata a classificação dos contextos (dia, cidade e companhia) que obtiveram o melhor desempenho pelos algoritmos de recomendação (PreF, PostF), ao utilizar as métricas MAE, RMSE e *F-Measure* (com N=5), sendo possível observar que o contexto *dia* atingiu o maior desempenho, em relação aos outros contextos, em todas as métricas aplicadas. Enquanto, o contexto *companhia*, geralmente obteve o pior desempenho, exceto na métrica *F-Measure* (N=5) com o algoritmo de recomendação PreF.

Tabela 24 – Classificação do desempenho dos contextos segundo algoritmos de recomendação no conjunto de dados *book-tv-100overlap-target-tv*

MAE		RMSE		<i>F-measure</i> ($N=5$)	
PreF	PostF	PreF	PostF	PreF	PostF
1º - dia	1º - dia				
2º - cidade	2º - cidade	2º - cidade	2º - cidade	2º - companhia	2º - cidade
3º - companhia	3º - companhia	3º - companhia	3º - companhia	3º - cidade	3º - companhia

Fonte – O próprio autor

Na [Tabela 25](#) é descrita como os algoritmos de seleção de contextos estabeleceram a classificação daqueles contextos considerados relevantes. Onde nota-se que apenas o MCFS apresentou um resultado distinto na ordem de importância.

Tabela 25 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados *book-tv-100overlap-target-tv*

IG	χ^2	MRMR	MCFS
1º - cidade	1º - cidade	1º - cidade	1º - dia
2º - dia	2º - dia	2º - dia	2º - cidade
3º - companhia	3º - companhia	3º - companhia	3º - companhia

Fonte – O próprio autor

A [Tabela 26](#) demonstra a partir do Kendall, o quanto a classificação dos contextos nos algoritmos de seleção é similar à classificação nos algoritmos de recomendação pelas métricas MAE, RMSE e *F-measure* (com $N=5$) (com $N=5$). Com o auxílio da tabela em questão, torna-se perceptível que o MCFS possuiu o melhor resultado dentre as técnicas nesse conjunto de dados, pois obteve concordância perfeita entre as classificações de 5 dos 6 cenários, ratificando a classificação apresentada pela técnica e refletindo a intensidade da relevância desses contextos no processo de recomendação.

Tabela 26 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados *book-tv-100overlap-target-tv*

Algoritmos de seleção	Kendall (MAE)		Kendall (RMSE)		Kendall (F-measure)	
	PreF	PostF	PreF	PostF	PreF	PostF
IG	+0,33	+0,33	+0,33	+0,33	-0,33	+0,33
χ^2	+0,33	+0,33	+0,33	+0,33	-0,33	+0,33
MRMR	+0,33	+0,33	+0,33	+0,33	-0,33	+0,33
MCFS	+1	+1	+1	+1	+0,33	+1

Fonte – O próprio autor

5.2 Conjuntos de dados com domínios *Livro* e *Música*

As subseções a seguir apresentam os resultados dos conjuntos de dados variando o nível de sobreposição e o domínio alvo daqueles que possuem os domínios *Livro* e *Música*.

5.2.1 10% de sobreposição e livro como domínio alvo

A Tabela 27 relata a classificação dos contextos (dia, cidade e companhia) que obtiveram o melhor desempenho pelos algoritmos de recomendação (PreF, PostF), ao utilizar as métricas MAE, RMSE e *F-Measure* (com $N=5$), sendo possível observar que o contexto *dia* atingiu o maior desempenho, em relação aos outros contextos, na métrica *F-Measure* de ambos algoritmos e nas métricas MAE e RMSE do algoritmo PreF. Enquanto, o contexto *cidade* obteve o maior desempenho nas métricas MAE e RMSE do algoritmo PostF.

Tabela 27 – Classificação segundo algoritmos de recomendação no conjunto de dados *book-music-10overlap-target-book*

MAE		RMSE		<i>F-measure</i> ($N=5$)	
PreF	PostF	PreF	PostF	PreF	PostF
1º - dia	1º - cidade	1º - dia	1º - cidade	1º - dia	1º - dia
2º - cidade	2º - dia	2º - cidade	2º - dia	2º - cidade	2º - cidade
3º - companhia	3º - companhia				

Fonte – O próprio autor

Na Tabela 28 é descrita como os algoritmos de seleção de contextos estabeleceram a classificação daqueles contextos considerados relevantes. Onde nota-se que apenas o MRMR apresentou um resultado distinto na ordem de importância.

Tabela 28 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados *book-music-10overlap-target-book*

IG	χ^2	MRMR	MCFS
1º - cidade	1º - cidade	1º - cidade	1º - cidade
2º - dia	2º - dia	2º - companhia	2º - dia
3º - companhia	3º - companhia	3º - dia	3º - companhia

Fonte – O próprio autor

A [Tabela 29](#) demonstra a partir do Kendall, o quanto a classificação dos contextos nos algoritmos de seleção é similar à classificação nos algoritmos de recomendação pelas métricas MAE, RMSE e *F-measure* (com N=5). Com o auxílio da tabela em questão, torna-se perceptível que o MRMR possuiu o pior resultado dentre as técnicas nesse conjunto de dados, pois obteve o menor coeficiente em todos os cenários, enquanto as outras técnicas apresentaram o mesmo coeficiente para cada cenário e constatou a concordância perfeita com o algoritmo de recomendação PostF nas métricas MAE e RMSE.

Tabela 29 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados *book-music-10overlap-target-book*

Algoritmos de seleção	Kendall (MAE)		Kendall (RMSE)		Kendall (F-measure)	
	PreF	PostF	PreF	PostF	PreF	PostF
IG	+0,33	+1	+0,33	+1	+0,33	+0,33
χ^2	+0,33	+1	+0,33	+1	+0,33	+0,33
MRMR	-0,33	+0,33	-0,33	+0,33	-0,33	-0,33
MCFS	+0,33	+1	+0,33	+1	+0,33	+0,33

Fonte – O próprio autor

5.2.2 10% de sobreposição e música como domínio alvo

A [Tabela 30](#) relata a classificação dos contextos (dia, cidade e companhia) que obtiveram o melhor desempenho pelos algoritmos de recomendação (PreF, PostF), ao utilizar as métricas MAE, RMSE e *F-Measure* (com N=5), sendo possível observar que o contexto *dia* atingiu o maior desempenho, em relação aos outros contextos, nas métricas MAE, F-measure e RMSE do algoritmo PostF. Enquanto, o contexto *companhia*, geralmente obteve o pior desempenho, exceto na métrica *F-Measure* (N=5) com o algoritmo de recomendação PreF.

Tabela 30 – Classificação segundo algoritmos de recomendação no conjunto de dados *book-music-10overlap-target-music*

MAE		RMSE		<i>F-measure</i> ($N=5$)	
PreF	PostF	PreF	PostF	PreF	PostF
1º - dia	1º - dia	1º - cidade	1º - dia	1º - dia	1º - dia
2º - cidade	2º - cidade	2º - compa- nhia	2º - cidade	2º - compa- nhia	2º - cidade
3º - compa- nhia	3º - compa- nhia	3º - dia	3º - compa- nhia	3º - cidade	3º - compa- nhia

Fonte – O próprio autor

Na [Tabela 31](#) é descrita como os algoritmos de seleção de contextos estabeleceram a classificação daqueles contextos considerados relevantes. Onde nota-se que todos os algoritmos apresentaram a mesma classificação.

Tabela 31 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados *book-music-10overlap-target-music*

IG	χ^2	MRMR	MCFS
1º - cidade	1º - cidade	1º - cidade	1º - cidade
2º - dia	2º - dia	2º - dia	2º - dia
3º - companhia	3º - companhia	3º - companhia	3º - companhia

Fonte – O próprio autor

A [Tabela 32](#) demonstra a partir do Kendall, o quanto a classificação dos contextos nos algoritmos de seleção é similar à classificação nos algoritmos de recomendação pelas métricas MAE, RMSE e *F-measure* (com $N=5$). Todos os algoritmos de seleção de contextos possuíram a mesma ordem de relevância dos contextos ([Tabela 31](#)), diante disso, o resultado é o mesmo em todos os cenários e não apresentaram nenhuma concordância perfeita.

Tabela 32 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados *book-music-10overlap-target-music*

Algoritmos de seleção	Kendall (MAE)		Kendall (RMSE)		Kendall (F-measure)	
	PreF	PostF	PreF	PostF	PreF	PostF
IG	+0,33	+0,33	+0,33	+0,33	-0,33	+0,33
χ^2	+0,33	+0,33	+0,33	+0,33	-0,33	+0,33
MRMR	+0,33	+0,33	+0,33	+0,33	-0,33	+0,33
MCFS	+0,33	+0,33	+0,33	+0,33	-0,33	+0,33

Fonte – O próprio autor

5.2.3 50% de sobreposição e livro como domínio alvo

A [Tabela 33](#) relata a classificação dos contextos (dia, cidade e companhia) que obtiveram o melhor desempenho pelos algoritmos de recomendação (PreF, PostF), ao utilizar as métricas MAE, RMSE e *F-Measure* (com $N=5$), sendo possível observar que o contexto *dia* atingiu o maior desempenho, em relação aos outros contextos, em todas as métricas aplicadas. Enquanto, o contexto *companhia* obteve o pior desempenho.

Tabela 33 – Classificação segundo algoritmos de recomendação no conjunto de dados *book-music-50overlap-target-book*

MAE		RMSE		<i>F-measure</i> ($N=5$)	
PreF	PostF	PreF	PostF	PreF	PostF
1º - dia	1º - dia				
2º - cidade	2º - cidade				
3º - companhia	3º - companhia				

Fonte – O próprio autor

Na [Tabela 34](#) é descrita como os algoritmos de seleção de contextos estabeleceram a classificação daqueles contextos considerados relevantes. Onde nota-se que todos os algoritmos apresentaram a mesma classificação.

Tabela 34 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados *book-music-50overlap-target-book*

IG	χ^2	MRMR	MCFS
1º - cidade	1º - cidade	1º - cidade	1º - cidade
2º - dia	2º - dia	2º - dia	2º - dia
3º - companhia	3º - companhia	3º - companhia	3º - companhia

Fonte – O próprio autor

A [Tabela 35](#) demonstra a partir do Kendall, o quanto a classificação dos contextos nos algoritmos de seleção é similar à classificação nos algoritmos de recomendação pelas métricas MAE, RMSE e *F-measure* (com $N=5$). Todos os algoritmos de seleção de contextos possuíram a mesma ordem de relevância dos contextos ([Tabela 34](#)), diante disso, o resultado é o mesmo em todos os cenários e não apresentaram nenhuma concordância perfeita.

Tabela 35 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados *book-music-50overlap-target-book*

Algoritmos de seleção	Kendall (MAE)		Kendall (RMSE)		Kendall (F-measure)	
	PreF	PostF	PreF	PostF	PreF	PostF
IG	+0,33	+0,33	+0,33	+0,33	+0,33	+0,33
χ^2	+0,33	+0,33	+0,33	+0,33	+0,33	+0,33
MRMR	+0,33	+0,33	+0,33	+0,33	+0,33	+0,33
MCFS	+0,33	+0,33	+0,33	+0,33	+0,33	+0,33

Fonte – O próprio autor

5.2.4 50% de sobreposição e música como domínio alvo

A [Tabela 36](#) relata a classificação dos contextos (dia, cidade e companhia) que obtiveram o melhor desempenho pelos algoritmos de recomendação (PreF, PostF), ao utilizar as métricas MAE, RMSE e *F-Measure* (com $N=5$), sendo possível observar que o contexto *dia* atingiu o maior desempenho, em relação aos outros contextos, em todas as métricas aplicadas. Enquanto, o contexto *companhia*, geralmente obteve o pior desempenho, exceto na métrica *F-Measure* ($N=5$) com o algoritmo de recomendação PreF e na métrica RMSE com o algoritmo de recomendação PostF.

Tabela 36 – Classificação segundo algoritmos de recomendação no conjunto de dados *book-music-50overlap-target-music*

MAE		RMSE		<i>F-measure</i> ($N=5$)	
PreF	PostF	PreF	PostF	PreF	PostF
1º - dia	1º - dia				
2º - cidade	2º - cidade	2º - cidade	2º - companhia	2º - companhia	2º - cidade
3º - companhia	3º - companhia	3º - companhia	3º - cidade	3º - cidade	3º - companhia

Fonte – O próprio autor

Na [Tabela 37](#) é descrita como os algoritmos de seleção de contextos estabeleceram a classificação daqueles contextos considerados relevantes. Onde nota-se que todos os algoritmos apresentaram a mesma classificação.

Tabela 37 – Classificação segundo algoritmos de seleção de contextos no conjunto de dados *book-music-50overlap-target-music*

IG	χ^2	MRMR	MCFS
1º - cidade	1º - cidade	1º - cidade	1º - cidade
2º - dia	2º - dia	2º - dia	2º - dia
3º - companhia	3º - companhia	3º - companhia	3º - companhia

Fonte – O próprio autor

A [Tabela 38](#) demonstra a partir do Kendall, o quanto a classificação dos contextos nos algoritmos de seleção é similar à classificação nos algoritmos de recomendação pelas métricas MAE, RMSE e *F-measure* (com N=5). Todos os algoritmos de seleção de contextos possuíram a mesma ordem de relevância dos contextos ([Tabela 37](#)), diante disso, o resultado é o mesmo em todos os cenários e não apresentam nenhuma concordância perfeita.

Tabela 38 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados *book-music-50overlap-target-music*

Algoritmos de seleção	Kendall (MAE)		Kendall (RMSE)		Kendall (F-measure)	
	PreF	PostF	PreF	PostF	PreF	PostF
IG	+0,33	+0,33	+0,33	-0,33	-0,33	+0,33
χ^2	+0,33	+0,33	+0,33	-0,33	-0,33	+0,33
MRMR	+0,33	+0,33	+0,33	-0,33	-0,33	+0,33
MCFS	+0,33	+0,33	+0,33	-0,33	-0,33	+0,33

Fonte – O próprio autor

5.2.5 100% de sobreposição e livro como domínio alvo

A [Tabela 39](#) relata a classificação dos contextos (dia, cidade e companhia) que obtiveram o melhor desempenho pelos algoritmos de recomendação (PreF, PostF), ao utilizar as métricas MAE, RMSE e *F-Measure* (com N=5), sendo possível observar que o contexto *dia* atingiu o maior desempenho, em relação aos outros contextos, nas métricas MAE, *F-measure* e RMSE do algoritmo PostF. Enquanto, o contexto *companhia*, geralmente obteve o pior desempenho, exceto na métrica *F-Measure* (N=5) com o algoritmo de recomendação PreF.

Tabela 39 – Classificação segundo algoritmos de recomendação no conjunto de dados *book-music-100overlap-target-book*

MAE		RMSE		<i>F-measure</i> ($N=5$)	
PreF	PostF	PreF	PostF	PreF	PostF
1º - dia	1º - dia	1º - cidade	1º - dia	1º - dia	1º - dia
2º - cidade	2º - cidade	2º - dia	2º - cidade	2º - companhia	2º - cidade
3º - companhia	3º - companhia	3º - companhia	3º - companhia	3º - cidade	3º - companhia

Fonte – O próprio autor

Na [Tabela 40](#) é descrita como os algoritmos de seleção de contextos estabeleceram a classificação daqueles contextos considerados relevantes. Onde nota-se que todos os algoritmos apresentaram a mesma classificação.

Tabela 40 – Classificação segundo algoritmos de seleção no conjunto de dados *book-music-100overlap-target-book*

IG	χ^2	MRMR	MCFS
1º - cidade	1º - cidade	1º - cidade	1º - cidade
2º - dia	2º - dia	2º - dia	2º - dia
3º - companhia	3º - companhia	3º - companhia	3º - companhia

Fonte – O próprio autor

A [Tabela 41](#) demonstra a partir do Kendall, o quanto a classificação dos contextos nos algoritmos de seleção é similar à classificação nos algoritmos de recomendação pelas métricas MAE, RMSE e *F-measure* (com $N=5$). Todos os algoritmos de seleção de contextos possuíram a mesma ordem de relevância dos contextos ([Tabela 40](#)), diante disso, o resultado é o mesmo em todos os cenários e apresentaram concordância perfeita com o algoritmo de recomendação PreF na métrica RMSE.

Tabela 41 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados *book-music-100overlap-target-book*

Algoritmos de seleção	Kendall (MAE)		Kendall (RMSE)		Kendall (F-measure)	
	PreF	PostF	PreF	PostF	PreF	PostF
IG	+0,33	+0,33	+1	+0,33	-0,33	+0,33
χ^2	+0,33	+0,33	+1	+0,33	-0,33	+0,33
MRMR	+0,33	+0,33	+1	+0,33	-0,33	+0,33
MCFS	+0,33	+0,33	+1	+0,33	-0,33	+0,33

Fonte – O próprio autor

5.2.6 100% de sobreposição e música como domínio alvo

A [Tabela 42](#) relata a classificação dos contextos (dia, cidade e companhia) que obtiveram o melhor desempenho pelos algoritmos de recomendação (PreF, PostF), ao utilizar as métricas MAE, RMSE e *F-Measure* (com $N=5$), sendo possível observar que o contexto *dia* atingiu o maior desempenho, em relação aos outros contextos, na métrica *F-Measure* de ambos algoritmos e na métrica MAE do algoritmo PostF. Enquanto, o contexto *cidade* obteve o maior desempenho nas métricas MAE e RMSE do algoritmo PreF e o contexto *companhia* obteve maior desempenho na métrica RMSE do algoritmo PostF.

Tabela 42 – Classificação segundo algoritmos de recomendação no conjunto de dados *book-music-100overlap-target-music*

MAE		RMSE		<i>F-measure</i> ($N=5$)	
PreF	PostF	PreF	PostF	PreF	PostF
1º - cidade	1º - dia	1º - cidade	1º - companhia	1º - dia	1º - dia
2º - dia	2º - companhia	2º - dia	2º - dia	2º - cidade	2º - cidade
3º - companhia	3º - cidade	3º - companhia	3º - cidade	3º - companhia	3º - companhia

Fonte – O próprio autor

Na [Tabela 43](#) é descrita como os algoritmos de seleção de contextos estabeleceram a classificação daqueles contextos considerados relevantes. Onde nota-se que todos os algoritmos apresentaram a mesma classificação.

Tabela 43 – Classificação segundo algoritmos de seleção no conjunto de dados *book-music-100overlap-target-music*

IG	χ^2	MRMR	MCFS
1º - cidade	1º - cidade	1º - cidade	1º - cidade
2º - dia	2º - dia	2º - dia	2º - dia
3º - companhia	3º - companhia	3º - companhia	3º - companhia

Fonte – O próprio autor

A Tabela 44 demonstra a partir do Kendall, o quanto a classificação dos contextos nos algoritmos de seleção é similar à classificação nos algoritmos de recomendação pelas métricas MAE, RMSE e *F-measure* (com $N=5$). Todos os algoritmos de seleção de contextos possuíram a mesma ordem de relevância dos contextos (Tabela 43), diante disso, o resultado é o mesmo em todos os cenários e apresentaram concordância perfeita com o algoritmo de recomendação PreF nas métricas MAE e RMSE.

Tabela 44 – Grau de similaridade aplicando o coeficiente de correlação tau de Kendall (τ) no conjunto de dados *book-music-100overlap-target-music*

Algoritmos de seleção	Kendall (MAE)		Kendall (RMSE)		Kendall (F-measure)	
	PreF	PostF	PreF	PostF	PreF	PostF
IG	+1	-0,33	+1	-1	+0,33	+0,33
χ^2	+1	-0,33	+1	-1	+0,33	+0,33
MRMR	+1	-0,33	+1	-1	+0,33	+0,33
MCFS	+1	-0,33	+1	-1	+0,33	+0,33

Fonte – O próprio autor

5.3 Sumário

Nesta seção é apresentada os resumos dos resultados dos algoritmos de seleção de contexto nos conjuntos de dados com domínios *Livro* e *Televisão* e com domínios *Livro* e *Música*.

É possível verificar que o coeficiente de correlação tau de Kendall em classificações com 3 elementos pode obter 4 possíveis valores: +1, +0,33, -0,33 e -1, sendo +1 quando a ordem dos contextos entre as duas classificações são idênticas, +0,33 quando é necessário uma inversão de par de contextos para transformar a ordem de uma classificação na outra (ex.: a 1ª classificação é 1º - dia, 2º - cidade e 3º - companhia, enquanto a 2ª classificação é 1º - cidade, 2º - dia e 3º - companhia, se trocarmos a ordem dos contextos cidade e dia as classificações ficam iguais), -0,33 quando é necessário duas inversões de pares de

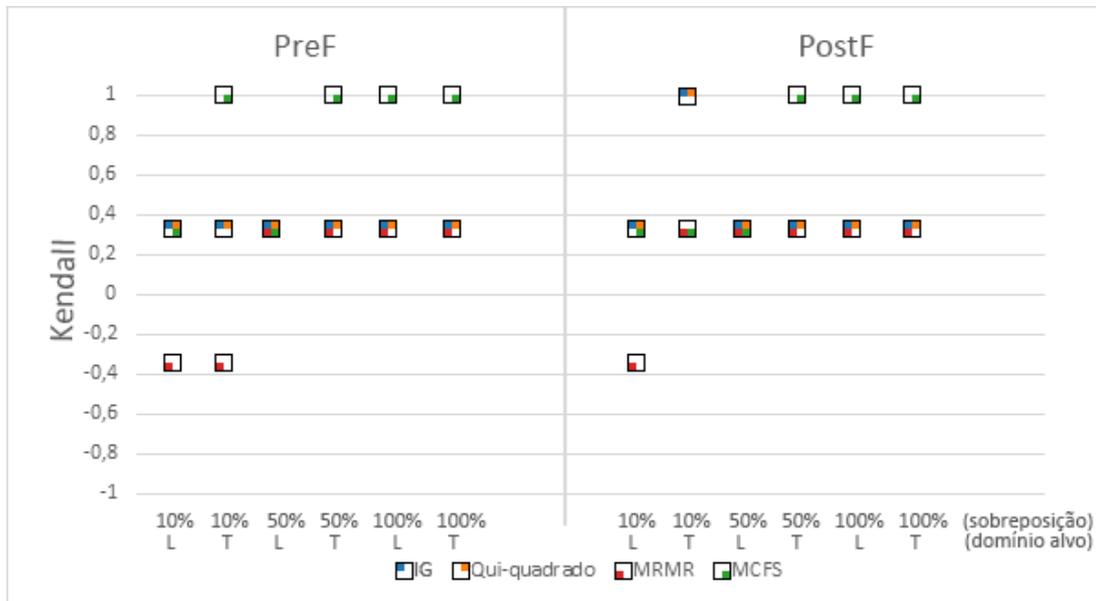
contextos para transformar a ordem de uma classificação na outra e -1 quando a ordem dos contextos de uma classificação é exatamente o inverso da outra.

Sendo assim, os quadros 3, 4 e 5 demonstram os coeficientes tau de Kendall obtidos pelas classificações dos contextos nos algoritmos de seleção em relação as classificações dos contextos aplicados nos algoritmos de recomendação (PreF e PostF) nas métricas adotadas respectivamente (MAE, RMSE e *F-Measure* (com N=5) variando o nível de sobreposição e o domínio alvo daqueles que possuem os domínios livro e televisão. Da mesma maneira, as figuras 7, 8 e 9 apresentam esses dados em forma de gráfico de dispersão, a fim de comparar os algoritmos de seleção de contextos em cada possível cenário.

Quadro 3 – Desempenho geral (**Kendall**) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica **MAE** nos conjuntos de dados com domínios livro e televisão

Algoritmo de Seleção	Domínio Alvo	Nível de sobreposição	Kendall (Pref)	Kendall (PostF)
IG	Livro	10%	0,33	0,33
	Televisão	10%	0,33	1
	Livro	50%	0,33	0,33
	Televisão	50%	0,33	0,33
	Livro	100%	0,33	0,33
	Televisão	100%	0,33	0,33
χ^2	Livro	10%	0,33	0,33
	Televisão	10%	0,33	1
	Livro	50%	0,33	0,33
	Televisão	50%	0,33	0,33
	Livro	100%	0,33	0,33
	Televisão	100%	0,33	0,33
MRMR	Livro	10%	-0,33	-0,33
	Televisão	10%	-0,33	0,33
	Livro	50%	0,33	0,33
	Televisão	50%	0,33	0,33
	Livro	100%	0,33	0,33
	Televisão	100%	0,33	0,33
MCFS	Livro	10%	0,33	0,33
	Televisão	10%	1	0,33
	Livro	50%	0,33	0,33
	Televisão	50%	1	1
	Livro	100%	1	1
	Televisão	100%	1	1

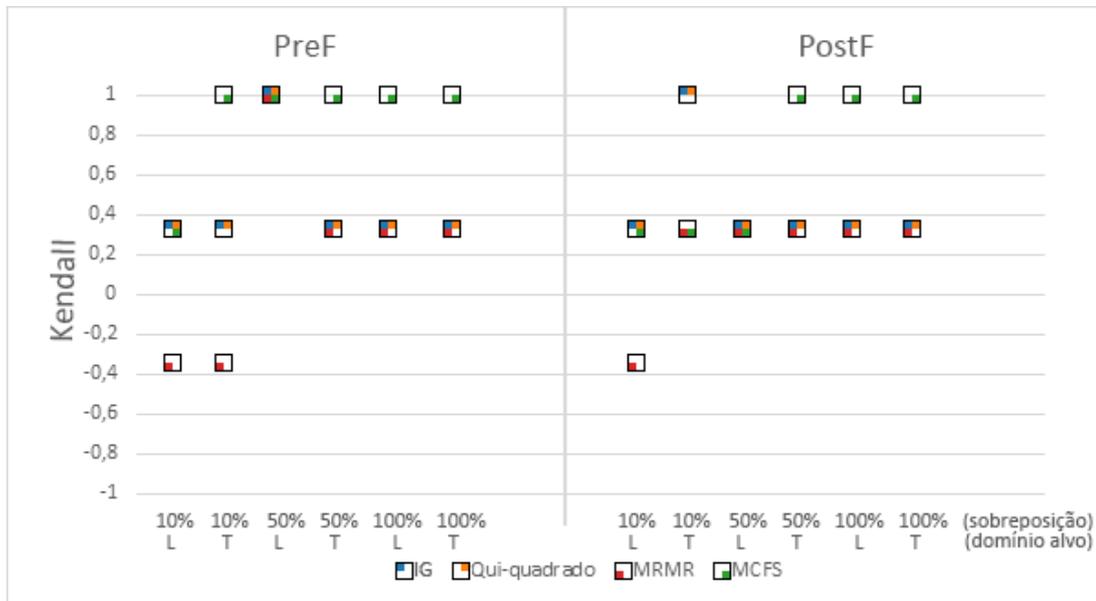
Figura 7 – Gráfico de dispersão do desempenho geral (**Kendall**) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica **MAE** nos conjuntos de dados com domínios livro e televisão



Quadro 4 – Desempenho geral (**Kendall**) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica **RMSE** nos conjuntos de dados com domínios livro e televisão

Algoritmo de Seleção	Domínio Alvo	Nível de sobreposição	Kendall (Pref)	Kendall (PostF)
IG	Livro	10%	0,33	0,33
	Televisão	10%	0,33	1
	Livro	50%	1	0,33
	Televisão	50%	0,33	0,33
	Livro	100%	0,33	0,33
	Televisão	100%	0,33	0,33
χ^2	Livro	10%	0,33	0,33
	Televisão	10%	0,33	1
	Livro	50%	1	0,33
	Televisão	50%	0,33	0,33
	Livro	100%	0,33	0,33
	Televisão	100%	0,33	0,33
MRMR	Livro	10%	-0,33	-0,33
	Televisão	10%	-0,33	0,33
	Livro	50%	1	0,33
	Televisão	50%	0,33	0,33
	Livro	100%	0,33	0,33
	Televisão	100%	0,33	0,33
MCFS	Livro	10%	0,33	0,33
	Televisão	10%	1	0,33
	Livro	50%	1	0,33
	Televisão	50%	1	1
	Livro	100%	1	1
	Televisão	100%	1	1

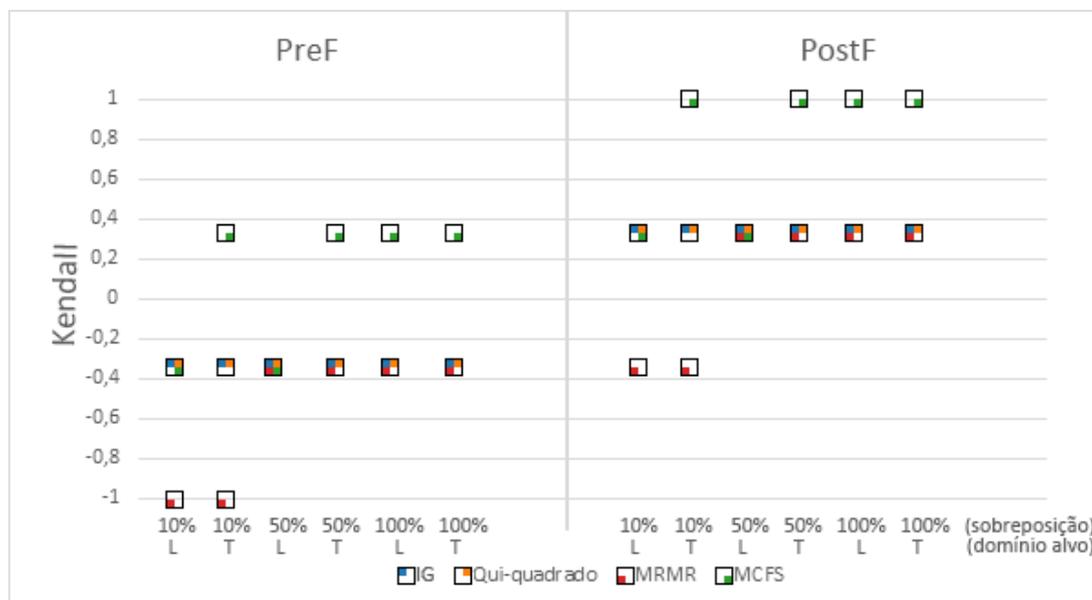
Figura 8 – Gráfico de dispersão do desempenho geral (**Kendall**) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica **RMSE** nos conjuntos de dados com domínios livro e televisão



Quadro 5 – Desempenho geral (**Kendall**) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica **F-Measure** nos conjuntos de dados com domínios livro e televisão

Algoritmo de Seleção	Domínio Alvo	Nível de sobreposição	Kendall (Pref)	Kendall (PostF)
IG	Livro	10%	-0,33	0,33
	Televisão	10%	-0,33	0,33
	Livro	50%	-0,33	0,33
	Televisão	50%	-0,33	0,33
	Livro	100%	-0,33	0,33
	Televisão	100%	-0,33	0,33
χ^2	Livro	10%	-0,33	0,33
	Televisão	10%	-0,33	0,33
	Livro	50%	-0,33	0,33
	Televisão	50%	-0,33	0,33
	Livro	100%	-0,33	0,33
	Televisão	100%	-0,33	0,33
MRMR	Livro	10%	-1	-0,33
	Televisão	10%	-0,33	-0,33
	Livro	50%	-0,33	0,33
	Televisão	50%	-0,33	0,33
	Livro	100%	-0,33	0,33
	Televisão	100%	-0,33	0,33
MCFS	Livro	10%	-0,33	0,33
	Televisão	10%	-1	1
	Livro	50%	-0,33	0,33
	Televisão	50%	0,33	1
	Livro	100%	0,33	1
	Televisão	100%	0,33	1

Figura 9 – Gráfico de dispersão do desempenho geral dos algoritmos de seleção de contextos, aplicando o coeficiente tau de **Kendall**, em relação aos algoritmos de recomendação pela métrica **F-Measure (com N=5)** nos conjuntos de dados com domínios livro e televisão



Além disso, a [Tabela 45](#) apresenta para cada algoritmo de seleção nos conjuntos de dados com domínios *Livro* e *Televisão*, a frequência absoluta (número de vezes em que coeficiente tau de Kendall assume um dos valores possíveis: +1, +0,33, -0,33 e -1) e a frequência relativa, sendo a razão entre a frequência absoluta e número total de cenários (36).

Tabela 45 – Distribuição das frequências absoluta e relativa da correlação tau de Kendall (τ) nos conjuntos de dados com domínios *Livro* e *Televisão*

Algoritmo de seleção	Kendall = +1	Kendall = +0,33	Kendall = -0,33	Kendall = -1
IG	3 (8,33%)	27 (75%)	6 (16,66%)	0 (0%)
χ^2	3 (8,33%)	27 (75%)	6 (16,66%)	0 (0%)
MRMR	1 (2,77%)	21 (58,33%)	12 (33,33%)	2 (5,55%)
MCFS	19 (52,77%)	15 (41,66%)	2 (5,55%)	0 (0%)

Fonte – O próprio autor

Como pode ser visto, o MCFS conseguiu classificar a relevância dos contextos majoritariamente da melhor maneira, sendo 52,77% de concordâncias perfeitas e obtendo os coeficientes tau de Kendall maiores ou iguais as outras técnicas de seleção, exceto em 2 cenários, com o algoritmo de Recomendação PostF nas métricas MAE e RMSE, tendo nível de sobreposição 10% e livro como domínio alvo. Enquanto o IG e χ^2 obtiveram

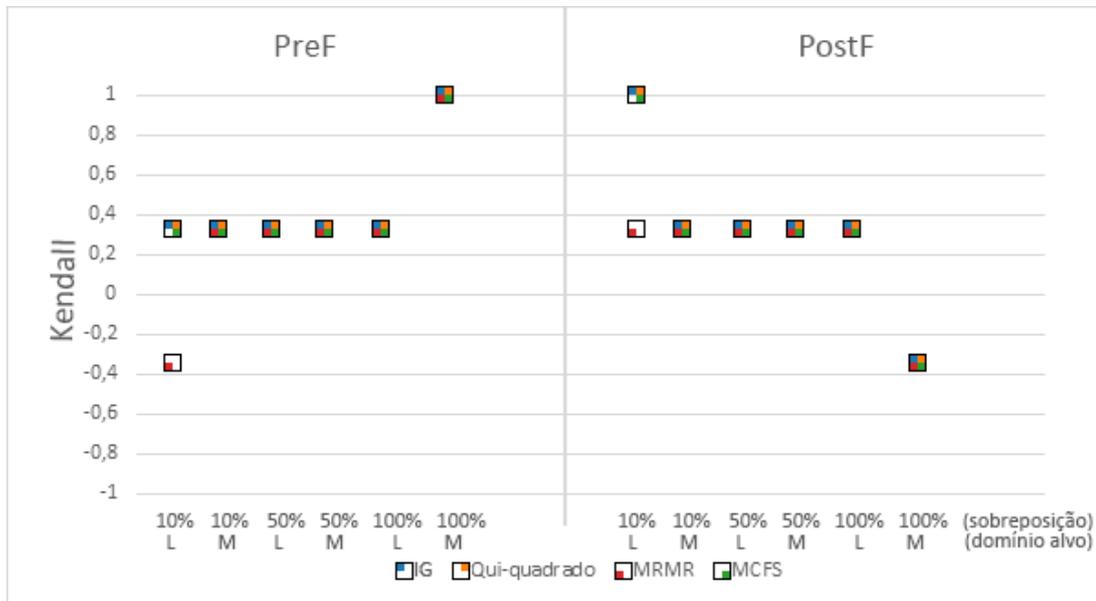
sempre os mesmos valores de coeficiente tau de Kendall, sendo 75% de coeficiente igual a $+0,3\bar{3}$ e 3 concordâncias perfeitas. Por fim, o MRMR apresentou os piores resultados, não conseguindo obter algum cenário onde seu coeficiente tau de Kendall fosse maior que as outras técnicas, além de possuir maior incidência de coeficientes negativos.

Por outro lado, os quadros 6, 7 e 8 demonstram os coeficientes tau de Kendall obtidos pelas classificações dos contextos nos algoritmos de seleção em relação às classificações dos contextos aplicados nos algoritmos de recomendação (PreF e PostF) nas métricas adotadas respectivamente (MAE, RMSE e *F-Measure*) variando o nível de sobreposição e o domínio alvo daqueles que possuem os domínios livro e música. Da mesma maneira, as figuras 10, 11 e 12 apresentam esses dados em forma de gráfico de dispersão, a fim de comparar os algoritmos de seleção de contextos em cada possível cenário.

Quadro 6 – Desempenho geral (**Kendall**) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica **MAE** nos conjuntos de dados com domínios livro e música

Algoritmo de Seleção	Domínio Alvo	Nível de sobreposição	Kendall (Pref)	Kendall (PostF)
IG	Livro	10%	$0,3\bar{3}$	1
	Música	10%	$0,3\bar{3}$	$0,3\bar{3}$
	Livro	50%	$0,3\bar{3}$	$0,3\bar{3}$
	Música	50%	$0,3\bar{3}$	$0,3\bar{3}$
	Livro	100%	$0,3\bar{3}$	$0,3\bar{3}$
	Música	100%	1	$-0,3\bar{3}$
χ^2	Livro	10%	$0,3\bar{3}$	1
	Música	10%	$0,3\bar{3}$	$0,3\bar{3}$
	Livro	50%	$0,3\bar{3}$	$0,3\bar{3}$
	Música	50%	$0,3\bar{3}$	$0,3\bar{3}$
	Livro	100%	$0,3\bar{3}$	$0,3\bar{3}$
	Música	100%	1	$-0,3\bar{3}$
MRMR	Livro	10%	$-0,3\bar{3}$	$0,3\bar{3}$
	Música	10%	$0,3\bar{3}$	$0,3\bar{3}$
	Livro	50%	$0,3\bar{3}$	$0,3\bar{3}$
	Música	50%	$0,3\bar{3}$	$0,3\bar{3}$
	Livro	100%	$0,3\bar{3}$	$0,3\bar{3}$
	Música	100%	1	$-0,3\bar{3}$
MCFS	Livro	10%	$0,3\bar{3}$	1
	Música	10%	$0,3\bar{3}$	$0,3\bar{3}$
	Livro	50%	$0,3\bar{3}$	$0,3\bar{3}$
	Música	50%	$0,3\bar{3}$	$0,3\bar{3}$
	Livro	100%	$0,3\bar{3}$	$0,3\bar{3}$
	Música	100%	1	$-0,3\bar{3}$

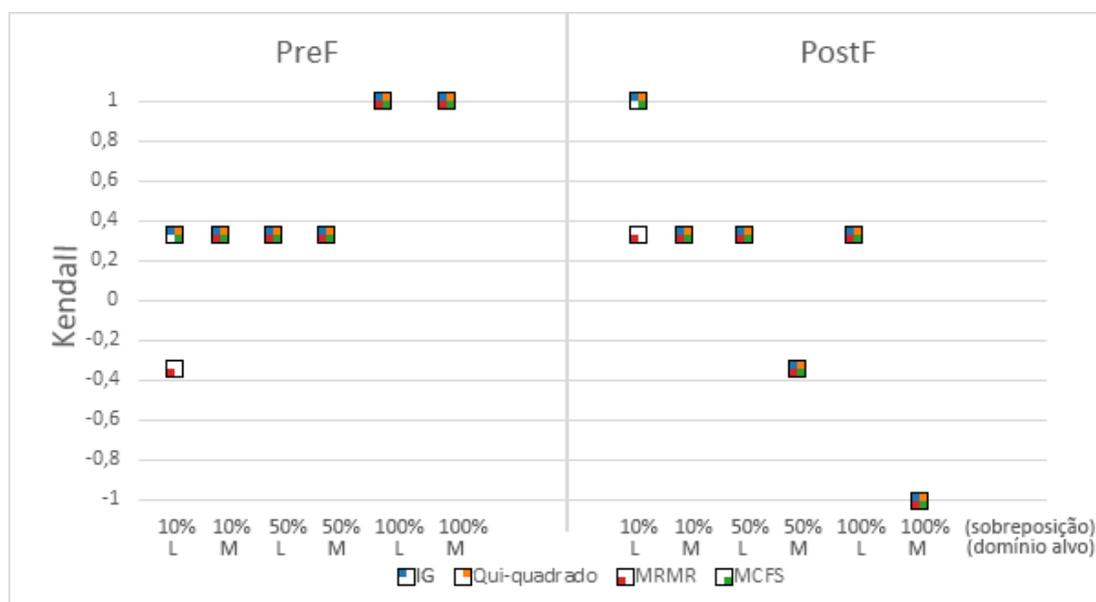
Figura 10 – Gráfico de dispersão do desempenho geral (**Kendall**) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica **MAE** nos conjuntos de dados com domínios livro e música



Quadro 7 – Desempenho geral (**Kendall**) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica **RMSE** nos conjuntos de dados com domínios livro e música

Algoritmo de Seleção	Domínio Alvo	Nível de sobreposição	Kendall (Pref)	Kendall (PostF)
IG	Livro	10%	0,33	1
	Música	10%	0,33	0,33
	Livro	50%	0,33	0,33
	Música	50%	0,33	-0,33
	Livro	100%	1	0,33
	Música	100%	1	-1
χ^2	Livro	10%	0,33	1
	Música	10%	0,33	0,33
	Livro	50%	0,33	0,33
	Música	50%	0,33	-0,33
	Livro	100%	1	0,33
	Música	100%	1	-1
MRMR	Livro	10%	-0,33	0,33
	Música	10%	0,33	0,33
	Livro	50%	0,33	0,33
	Música	50%	0,33	-0,33
	Livro	100%	1	0,33
	Música	100%	1	-1
MCFS	Livro	10%	0,33	1
	Música	10%	0,33	0,33
	Livro	50%	0,33	0,33
	Música	50%	0,33	-0,33
	Livro	100%	1	0,33
	Música	100%	1	-1

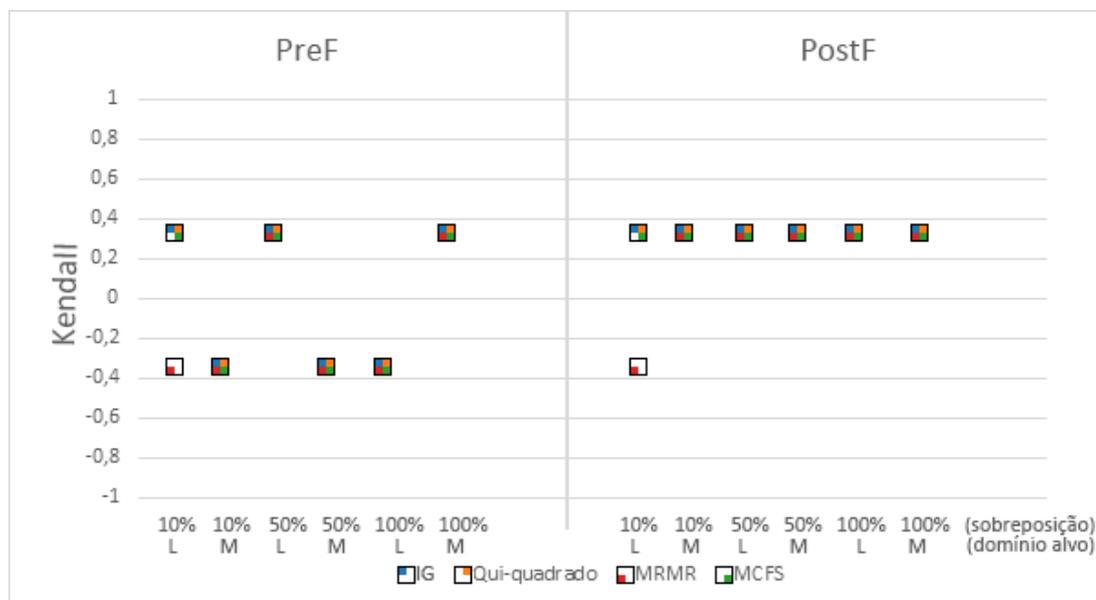
Figura 11 – Gráfico de dispersão do desempenho geral (**Kendall**) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica **RMSE** nos conjuntos de dados com domínios livro e música



Quadro 8 – Desempenho geral (**Kendall**) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica **F-Measure** nos conjuntos de dados com domínios livro e música

Algoritmo de Seleção	Domínio Alvo	Nível de sobreposição	Kendall (Pref)	Kendall (PostF)
IG	Livro	10%	0,33	0,33
	Música	10%	-0,33	0,33
	Livro	50%	0,33	0,33
	Música	50%	-0,33	0,33
	Livro	100%	-0,33	0,33
	Música	100%	0,33	0,33
χ^2	Livro	10%	0,33	0,33
	Música	10%	-0,33	0,33
	Livro	50%	0,33	0,33
	Música	50%	-0,33	0,33
	Livro	100%	-0,33	0,33
	Música	100%	0,33	0,33
MRMR	Livro	10%	-0,33	-0,33
	Música	10%	-0,33	0,33
	Livro	50%	0,33	0,33
	Música	50%	-0,33	0,33
	Livro	100%	-0,33	0,33
	Música	100%	0,33	0,33
MCFS	Livro	10%	0,33	0,33
	Música	10%	-0,33	0,33
	Livro	50%	0,33	0,33
	Música	50%	-0,33	0,33
	Livro	100%	-0,33	0,33
	Música	100%	0,33	0,33

Figura 12 – Gráfico de dispersão do desempenho geral (**Kendall**) dos algoritmos de seleção de contextos em relação aos algoritmos de recomendação pela métrica **F-Measure** (com **N=5**) nos conjuntos de dados com domínios livro e música



Ademais, a Tabela 46 apresenta para cada algoritmo de seleção nos conjuntos de dados com domínios *Livro* e *Música*, a frequência absoluta (número de vezes em que coeficiente tau de Kendall assume um dos valores possíveis: +1, +0,33, -0,33 e -1) e a frequência relativa, sendo a razão entre a frequência absoluta e número total de cenários (36).

Tabela 46 – Distribuição das frequências absoluta e relativa da correlação tau de Kendall (τ) nos conjuntos de dados com domínios *Livro* e *Música*

Algoritmo de seleção	Kendall = +1	Kendall = +0,33	Kendall = -0,33	Kendall = -1
IG	5 (13,88%)	25 (69,44%)	5 (13,88%)	1 (2,77%)
χ^2	5 (13,88%)	25 (69,44%)	5 (13,88%)	1 (2,77%)
MRMR	3 (8,33%)	23 (63,88%)	9 (25%)	1 (2,77%)
MCFS	5 (13,88%)	25 (69,44%)	5 (13,88%)	1 (2,77%)

Fonte – O próprio autor

Como pode ser visto, os algoritmos de seleção não apresentaram resultados convincentes, pois o MCFS, IG e χ^2 obtiveram sempre os mesmos valores de coeficiente tau de Kendall, em qualquer cenário, tendo atingido apenas 5 concordâncias perfeitas, ainda assim foram melhor que o MRMR, que obteve o coeficiente inferior nos cenários caracterizados por 10% de nível de sobreposição e livro como domínio alvo nas métricas MAE, RMSE e

F-Measure, obtendo apenas 3 concordâncias perfeitas e maior incidência de coeficientes negativos.

5.4 Discussão

Dados os resultados apresentados nas seções anteriores, podemos dizer que o uso de algoritmos de seleção de contextos contribuiu na análise da relevância dos contextos no processo da recomendação.

Verifica-se que entre os conjuntos que possuem os domínios livro e televisão, ao aumentar o nível de sobreposição e ao utilizar televisão como domínio alvo, os algoritmos de seleção obtêm um desempenho superior ou igual ao nível de sobreposição anterior, conseguindo classificar a relevância dos contextos de forma mais adequada, principalmente quando se refere ao algoritmo MCFS, que obteve o maior número de concordâncias perfeitas. Esses fatores podem ter ocorrido devido ao número maior de incidência dos atributos contextuais comparados aos conjuntos que têm livro como domínio alvo e o mesmo nível de sobreposição. Entretanto, nos conjuntos que possuem os domínios livro e música, não foram constatadas melhorias significativas nos coeficientes tau de Kendall ao aumentar o nível de sobreposição. Isso pode ser melhor investigado em trabalhos futuros, para verificar o motivo dos algoritmos de seleção não conseguirem obter uma percepção mais eficaz da relevância dos contextos e o quanto a relação do contexto com o domínio influencia na seleção.

Por outro lado, notou-se que os algoritmos de recomendação (PreF e PostF) obtiveram um comportamento consistente quando comparadas às técnicas de seleção, tanto nos conjuntos com domínios livro e televisão quanto nos conjuntos com domínio livro e música. Onde as técnicas de seleção conseguiram melhores coeficientes Kendall quando compararam-se ao PostF nas métricas MAE e *F-Measure* (com $N=5$), enquanto para o PreF na métrica RMSE. Dessa forma, constatou-se que os algoritmos de seleção previram os contextos relevantes de forma mais satisfatória para o PostF.

Foi observado que o contexto *dia* obteve um melhor desempenho para todos os conjuntos de dados pelos algoritmos de recomendação propostos no CD-CARS em [Véras \(2016\)](#) (PreF e PostF), enquanto o contexto *companhia* obteve o pior resultado, isso pode ter ocorrido devido a sua menor quantidade de incidências no conjunto de dados, prejudicando a análise de sua relevância. E, que, entre os algoritmos de seleção, o MCFS se sobressaiu, pois conseguiu classificar a ordem da relevância dos contextos similar à classificação dos contextos nos algoritmos de recomendação pelas métricas adotadas, principalmente no que se diz aos conjuntos de dados com domínios *livro* e *televisão*. No entanto, em relação aos conjunto de dados com domínios *livro* e *música*, foi verificado que 3 dos 4 algoritmos de seleção (MCFS, IG e χ^2) classificaram os contextos sempre na mesma ordem: 1^o -

cidade, 2º - dia e 3º - companhia, que acabaram não apresentando um desempenho ideal, pois, como foi supracitado, o contexto dia seria majoritariamente o mais relevante. Em contraposto, o MRMR considerou eventualmente o contexto *companhia* mais relevante que o contexto *dia*, tornando-se o algoritmo de seleção que apresentou o pior desempenho dentre os experimentos aplicados.

Neste trabalho foram executados a seleção através de abordagens pertencentes aos métodos *filter*, que geralmente são mais simples, mais rápidos e demandam menos tempo de processamento (SAEYS; INZA; LARRAÑAGA, 2007). Para avaliar o desempenho dessas abordagens, foi aplicado o coeficiente (τ) de Kendall, que demonstrou ser uma métrica robusta e eficiente (CROUX; DEHON, 2010). Mas futuramente poderá ser analisados abordagens de outros tipos de métodos de seleção (ex.: *wrapper e embedded*) e outras métricas de correlação (ex.: r de Pearson e ρ de Spearman), que podem apresentar resultados distintos.

5.5 Considerações Finais

Neste capítulo, apresentamos, discutimos e comparamos os resultados dos 4 algoritmos de seleção de contextos aplicados neste trabalho. A avaliação dos experimentos foi realizada considerando-se doze conjuntos de dados distintos (descritos na [subseção 4.1.1](#)). Os algoritmos foram avaliados quanto a similaridade entre a classificação resultante obtida sobre a classificação dos atributos contextuais (dia, cidade e companhia) que apresentaram os melhores índices de acordo com as métricas adotadas. Finalmente, as conclusões e trabalhos futuros deste trabalho serão descritos no próximo capítulo.

6 Conclusão

Neste trabalho foi analisada a importância do uso de métodos de seleção de características para determinar a relevância dos contextos, sendo aplicadas e comparadas as técnicas: *Information Gain* (IG), Teste qui-quadrado (χ^2), *Minimum Redundancy Maximum Relevance* (MRMR) e *Monte Carlo Feature Selection* (MCFS).

Os experimentos foram realizados em conjuntos de dados contendo dois domínios mais relacionados (livro e televisão) e dois domínios menos relacionados (livro e música). Observou-se que dentre as técnicas aplicadas, o MCFS possuiu um melhor desempenho na métrica coeficiente tau de Kendall, principalmente nos conjuntos de dados com domínios livro e televisão.

A partir dos resultados obtidos, constatou-se que a aplicação de técnicas de seleção contribuem para identificação e classificação da relevância das dimensões contextuais no processo de recomendação no tipo de sistema CD-CARS. Dessa forma, evita-se usar todos os contextos para desempenhar recomendações de itens aos usuários do sistema.

6.1 Limitações

As principais limitações deste trabalho são:

- Ausência da investigação do desempenho em relação às variações dos atributos de uma dimensão contextual (menor granularidade). Por exemplo, verificar o desempenho de todos atributos pertencentes a dimensão local (país, estado e cidade) e tempo (dia e tipo do dia).
- Ausência de experimentação na combinação de contextos relevantes (ex.: combinar os dois primeiros contextos em ordem de relevância estabelecidos por uma técnica de seleção e verificar o desempenho obtido).
- Os algoritmos de seleção de contextos não executam se a representação dos contextos for diferente de chave-valor.
- Não observou-se um limiar (“nota de corte”) possível para desconsiderar o uso de uma dimensão contextual.

6.2 Trabalhos futuros

Para sugestão de trabalhos futuros podemos enumerar:

- Verificar o desempenho das técnicas de seleção em relação aos diferentes níveis de granularidade dos contextos.
- Analisar a combinação de diferentes contextos, verificando se existe melhoria no desempenho em relação ao utilizar os contextos independentemente.
- Desenvolver ou alterar os algoritmos de seleção de contextos para permitir que sejam aceitos outros tipos de representação de contextos, como: linguagens de marcação, ontologias, etc.
- Verificar quando os contextos devem ser realmente descartados dos RSs (ex.: utilizar sempre o contexto considerado mais relevante pelo melhor algoritmo de seleção e desprezar os demais contextos).
- Analisar a aplicação das técnicas de seleção e da metodologia aplicada neste trabalho no tipo de sistema CARS.
- Utilizar algoritmos evolucionários para seleção dos contextos relevantes, eliminando a dependência do sistema de selecionar manualmente os contextos.
- Desenvolver ou alterar algoritmos de seleção de contextos relevantes para obtenção de melhores resultados. Por exemplo, o MRMR, que obteve o pior resultado dentre os algoritmos.
- Investigar o momento adequado para averiguar a relevância das informações contextuais e se seria apropriado realizá-la somente uma vez ou periodicamente.
- Aplicar testes estatísticos para determinar a significância dos resultados (ex.: utilizar o valor-p).

Referências

- ABDI, H. The kendall rank correlation coefficient. In: SALKIND, N. J. (Ed.). *Encyclopedia of Measurement and Statistic*. Newbury Park, California: SAGE Publications, 2007. cap. 11, p. 508–510. Citado na página 36.
- ADOMAVICIUS, G.; MOBASHER, B.; RICCI, F.; TUZHILIN, A. Context-aware recommender systems. *AI Magazine*, Association for the Advancement of Artificial Intelligence (AAAI), v. 32, n. 3, p. 67, oct 2011. Citado 3 vezes nas páginas 23, 24 e 27.
- ADOMAVICIUS, G.; SANKARANARAYANAN, R.; SEN, S.; TUZHILIN, A. Incorporating contextual information in recommender systems using a multidimensional approach. *ACM Transactions on Information Systems (TOIS)*, ACM, v. 23, n. 1, p. 103–145, 2005. Citado na página 21.
- 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, v. 17, n. 6, p. 734–749, 2005. Citado 2 vezes nas páginas 16 e 25.
- ADOMAVICIUS, G.; TUZHILIN, A. Context-aware recommender systems. In: *Recommender Systems Handbook*. Boston, MA: Springer US, 2015. p. 191–226. Citado 6 vezes nas páginas 17, 21, 22, 26, 27 e 28.
- ALDRICH, S. E. Recommender systems in commercial use. *AI Magazine*, Association for the Advancement of Artificial Intelligence (AAAI), v. 32, n. 3, p. 28, jun 2011. Citado na página 25.
- AMBROISE, C.; MCLACHLAN, G. J. Selection bias in gene extraction on the basis of microarray gene-expression data. *Proceedings of the national academy of sciences*, National Acad Sciences, v. 99, n. 10, p. 6562–6566, 2002. Citado na página 45.
- ARLOT, S.; CELISSE, A. A survey of cross-validation procedures for model selection. *Statistics Surveys*, The American Statistical Association, the Bernoulli Society, the Institute of Mathematical Statistics, and the Statistical Society of Canada, v. 4, p. 40–79, 2010. Citado na página 37.
- BALTRUNAS, L.; KAMINSKAS, M.; LUDWIG, B.; MOLING, O.; RICCI, F.; AYDIN, A.; LÜKE, K.-H.; SCHWAIGER, R. Incarmusic: Context-aware music recommendations in a car. In: *12th International Conference on Electronic Commerce and Web Technologies*. Berlin, Heidelberg: Springer, 2011. p. 89–100. Citado 3 vezes nas páginas 38, 40 e 41.
- BALTRUNAS, L.; LUDWIG, B.; PEER, S.; RICCI, F. Context relevance assessment and exploitation in mobile recommender systems. *Personal and Ubiquitous Computing*, Springer, v. 16, n. 5, p. 507–526, 2012. Citado 6 vezes nas páginas 21, 22, 26, 38, 40 e 41.
- BALTRUNAS, L.; LUDWIG, B.; RICCI, F. Matrix factorization techniques for context aware recommendation. In: ACM, 5., 2011, Chicago, USA. *Proceedings of the fifth ACM conference on Recommender systems*. Chicago, USA: ACM, 2011. p. 301–304. Citado 4 vezes nas páginas 17, 38, 40 e 41.

- BOBADILLA, J.; ORTEGA, F.; HERNANDO, A.; GUTIÉRREZ, A. Recommender systems survey. *Knowledge-Based Systems*, v. 46, p. 109–132, 2013. Citado na página 26.
- BORNELÖV, S.; KOMOROWSKI, J. Selection of significant features using monte carlo feature selection. In: *Challenges in Computational Statistics and Data Mining*. [S.l.]: Springer, 2016. p. 25–38. Citado na página 34.
- BOVO, A. B. *Um Modelo de descoberta de conhecimento inerente à evolução temporal dos relacionamentos entre elementos textuais*. 155 f. Tese (Doutorado em Engenharia e Gestão de Conhecimento) — Universidade Federal de Santa Catarina(UFSC), Florianópolis, 2011. Citado na página 33.
- BRAUNHOFER, M.; FERNÁNDEZ-TOBIÁS, I.; RICCI, F. Parsimonious and adaptive contextual information acquisition in recommender systems. In: CEUR-WS. *CEUR Workshop Proceedings*. [S.l.], 2015. Citado 5 vezes nas páginas 17, 23, 39, 40 e 41.
- BRAUNHOFER, M.; RICCI, F. Contextual information elicitation in travel recommender systems. In: *Information and Communication Technologies in Tourism 2016*. [S.l.]: Springer, 2016. p. 579–592. Citado 5 vezes nas páginas 22, 23, 39, 40 e 41.
- BRAUNHOFER, M.; RICCI, F. Selective contextual information acquisition in travel recommender systems. *Information Technology & Tourism*, Springer, v. 17, n. 1, p. 5–29, 2017. Citado 11 vezes nas páginas 16, 17, 19, 22, 23, 31, 38, 39, 40, 41 e 44.
- BURKE, R. Hybrid web recommender systems. In: *The adaptive web*. [S.l.]: Springer, 2007. p. 377–408. Citado 2 vezes nas páginas 25 e 26.
- CANTADOR, I.; FERNÁNDEZ-TOBIÁS, I.; BERKOVSKY, S.; CREMONESI, P. Cross-domain recommender systems. In: *Recommender Systems Handbook*. Boston, MA: Springer US, 2015. p. 919–959. Citado 2 vezes nas páginas 17 e 26.
- CORTIZO, J. C.; GIRALDEZ, I. Multi criteria wrapper improvements to naive bayes learning. In: SPRINGER. *International Conference on Intelligent Data Engineering and Automated Learning*. [S.l.], 2006. p. 419–427. Citado na página 30.
- COVER, T. M.; THOMAS, J. A. *Elements of information theory*. New York: John Wiley & Sons, 1991. ISBN 0-471-06259-6. Citado na página 31.
- CREMONESI, P.; KOREN, Y.; TURRIN, R. Performance of recommender algorithms on top-n recommendation tasks. In: ACM. *Proceedings of the fourth ACM conference on Recommender systems*. [S.l.], 2010. p. 39–46. Citado na página 36.
- CREMONESI, P.; TRIPODI, A.; TURRIN, R. Cross-domain recommender systems. In: IEEE. *2011 IEEE 11th International Conference on Data Mining Workshops*. [S.l.], 2011. p. 496–503. Citado 3 vezes nas páginas 26, 27 e 36.
- CROUX, C.; DEHON, C. Influence functions of the spearman and kendall correlation measures. *Statistical methods & applications*, Springer, v. 19, n. 4, p. 497–515, 2010. Citado na página 74.
- DARABI, S. A.; TEIMOURPOUR, B. A case-based-reasoning system for feature selection and diagnosing ashtma. In: *Handbook of Research on Data Science for Effective Healthcare Practice and Administration*. [S.l.]: IGI Global, 2017. p. 444–459. Citado na página 29.

DELEN, D.; WALKER, G.; KADAM, A. Predicting breast cancer survivability: a comparison of three data mining methods. *Artificial Intelligence in Medicine*, v. 34, n. 2, p. 113 – 127, 2005. Citado na página 37.

DEY, A. K. Understanding and using context. *Personal and ubiquitous computing*, Springer-Verlag, v. 5, n. 1, p. 4–7, 2001. Citado 2 vezes nas páginas 17 e 21.

DRAMÍŃSKI, M.; KIERCZAK, M.; KORONACKI, J.; KOMOROWSKI, J. Monte carlo feature selection and interdependency discovery in supervised classification. In: *Advances in Machine Learning II*. [S.l.]: Springer, 2010. p. 371–385. Citado 2 vezes nas páginas 33 e 34.

FERNÁNDEZ-TOBÍAS, I.; CANTADOR, I.; KAMINSKAS, M.; RICCI, F. Cross-domain recommender systems: A survey of the state of the art. In: *Proceedings of the 2nd Spanish Conference on Information Retrieval*. Valencia, Spain: ACM, 2012. p. 187–198. Citado na página 16.

FERNÁNDEZ-TOBÍAS, I.; CANTADOR, I.; PLAZA, L. An emotion dimensional model based on social tags: Crossing folksonomies and enhancing recommendations. In: *E-Commerce and Web Technologies*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013. p. 88–100. Citado na página 35.

FIELLER, E. C.; HARTLEY, H. O.; PEARSON, E. S. Tests for rank correlation coefficients. i. *Biometrika*, JSTOR, v. 44, n. 3/4, p. 470–481, 1957. Citado na página 35.

FLORENCIO FILHO, R. T. *Uma aplicação de mineração de dados ao programa bolsa escola da prefeitura da cidade do Recife*. 100 f. Dissertação (Mestrado em Ciência da Computação) — Universidade Federal de Pernambuco (UFPE), Recife, 2009. Citado na página 37.

GENUER, R.; POGGI, J.-M.; TULEAU-MALOT, C. Variable selection using random forests. *Pattern Recognition Letters*, Elsevier, v. 31, n. 14, p. 2225–2236, 2010. Citado na página 34.

GOGA, O.; LEI, H.; PARTHASARATHI, S. H. K.; FRIEDLAND, G.; SOMMER, R.; TEIXEIRA, R. Exploiting innocuous activity for correlating users across sites. In: *Proceedings of the 22nd International Conference on World Wide Web*. New York, NY, USA: ACM, 2013. p. 447–458. Citado na página 35.

GOLDBERG, D.; NICHOLS, D.; OKI, B. M.; TERRY, D. Using collaborative filtering to weave an information tapestry. *Communications of the ACM*, ACM, v. 35, n. 12, p. 61–70, 1992. Citado na página 25.

GUNAWARDANA, A.; SHANI, G. Evaluating recommender systems. In: *Recommender Systems Handbook*. [S.l.]: Springer, 2015. p. 265–308. Citado na página 35.

GUYON, I.; ELISSEEFF, A. An introduction to variable and feature selection. *Journal of machine learning research*, v. 3, p. 1157–1182, 2003. Citado 3 vezes nas páginas 17, 29 e 30.

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The weka data mining software: an update. *ACM SIGKDD explorations newsletter*, ACM, v. 11, n. 1, p. 10–18, 2009. Citado 4 vezes nas páginas 18, 32, 39 e 43.

- HALL, M. A. Correlation-based feature selection for discrete and numeric class machine learning. In: *Proceedings of the Seventeenth International Conference on Machine Learning*. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 2000. (ICML '00), p. 359–366. Citado na página 30.
- IHAKA, R.; GENTLEMAN, R. R. a language for data analysis and graphics. *Journal of computational and graphical statistics*, Taylor & Francis, v. 5, n. 3, p. 299–314, 1996. Citado na página 44.
- JI, K.; SHEN, H. Making recommendations from top-n user-item subgroups. *Neurocomputing*, Elsevier, v. 165, p. 228–237, 2015. Citado na página 17.
- JOVIĆ, A.; BRKIĆ, K.; BOGUNOVIĆ, N. A review of feature selection methods with applications. In: *2015 38th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*. [S.l.: s.n.], 2015. p. 1200–1205. Citado 2 vezes nas páginas 30 e 34.
- KAMAHARA, J.; ASAKAWA, T.; SHIMOJO, S.; MIYAHARA, H. A community-based recommendation system to reveal unexpected interests. In: *11th International Multimedia Modelling Conference*. [S.l.: s.n.], 2005. p. 433–438. Citado na página 26.
- KIM, H.-Y. Statistical notes for clinical researchers: Chi-squared test and fisher's exact test. *Restorative Dentistry & Endodontics*, The Korean Academy of Conservative Dentistry (KAMJE), v. 42, n. 2, p. 152, 2017. Citado na página 44.
- KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: *Proceedings of the 14th International Joint Conference on Artificial Intelligence - Volume 2*. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1995. p. 1137–1143. Citado na página 37.
- KOREN, Y.; BELL, R.; VOLINSKY, C. Matrix factorization techniques for recommender systems. *Computer*, IEEE, v. 42, n. 8, p. 30–37, 2009. Citado na página 25.
- KRAWCZUK, J.; ŁUKASZUK, T. The feature selection bias problem in relation to high-dimensional gene data. *Artificial Intelligence in Medicine*, v. 66, p. 63–71, 2016. Citado na página 45.
- LI, J.; CHENG, K.; WANG, S.; MORSTATTER, F.; TREVINO, R. P.; TANG, J.; LIU, H. Feature selection: A data perspective. *ACM Computing Surveys*, v. 50, n. 6, p. 1–45, jan. 2017. Citado 4 vezes nas páginas 30, 33, 34 e 44.
- LIU, C.; JIANG, D.; YANG, W. Global geometric similarity scheme for feature selection in fault diagnosis. *Expert Systems with Applications*, Elsevier, v. 41, n. 8, p. 3585–3595, 2014. Citado na página 30.
- MCHUGH, M. L. The chi-square test of independence. *Biochemia Medica*, Croatian Society for Medical Biochemistry and Laboratory Medicine, v. 23, p. 143–149, 2013. Citado na página 32.
- ODIC, A.; TKALCIC, M.; TASIC, J. F.; KOŠIR, A. Relevant context in a movie recommender system: Users' opinion vs. statistical detection. In: *Proceedings of the 4th International Workshop on Context-Aware Recommender Systems (CARS 2012)*. Dublin, Ireland: ACM, 2012. v. 12. Citado 6 vezes nas páginas 21, 22, 38, 40, 41 e 44.

- ODIĆ, A.; TKALČIČ, M.; TASIČ, J. F.; KOŠIR, A. Predicting and detecting the relevant contextual information in a movie-recommender system. *Interacting with Computers*, Oxford University Press, v. 25, n. 1, p. 74–90, 2013. Citado 7 vezes nas páginas 17, 19, 22, 39, 40, 41 e 44.
- PALMISANO, C.; TUZHILIN, A.; GORGOGNONE, M. Using context to improve predictive modeling of customers in personalization applications. *IEEE Transactions on Knowledge and Data Engineering*, v. 20, n. 11, p. 1535–1549, Nov 2008. ISSN 1041-4347. Citado na página 21.
- PATEL, M. S. A review on feature selection methods for datamining. *International Journal Of Advance Research And Innovative Ideas In Education*, IJARIIIE, v. 2, n. 3, p. 1912–1916, 2016. Citado na página 30.
- PENG, H.; LONG, F.; DING, C. Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy. *IEEE Transactions on pattern analysis and machine intelligence*, IEEE, v. 27, n. 8, p. 1226–1238, 2005. Citado 2 vezes nas páginas 30 e 31.
- REFAEILZADEH, P.; TANG, L.; LIU, H. Cross-validation. In: *Encyclopedia of Database Systems*. Boston, MA: Springer US, 2009. p. 532–538. Citado na página 37.
- RESNICK, P.; VARIAN, H. R. Recommender systems. *Communications of the ACM*, ACM, New York, NY, USA, v. 40, n. 3, p. 56–58, mar. 1997. Citado na página 24.
- RICCI, F.; ROKACH, L.; SHAPIRA, B. Recommender systems: introduction and challenges. In: *Recommender systems handbook*. [S.l.]: Springer, 2015. p. 1–34. Citado 3 vezes nas páginas 16, 25 e 26.
- SAEYS, Y.; INZA, I.; LARRAÑAGA, P. A review of feature selection techniques in bioinformatics. *Bioinformatics*, Oxford University Press, v. 23, n. 19, p. 2507–2517, 2007. Citado 4 vezes nas páginas 30, 34, 44 e 74.
- SCHEIN, A. I.; POPESCUL, A.; UNGAR, L. H.; PENNOCK, D. M. Methods and metrics for cold-start recommendations. In: ACM. *Proceedings of the 25th annual international ACM SIGIR conference on Research and development in information retrieval*. [S.l.], 2002. p. 253–260. Citado na página 26.
- SHARMA, A.; DEY, S. Performance investigation of feature selection methods and sentiment lexicons for sentiment analysis. *IJCA Special Issue on Advanced Computing and Communication Technologies for HPC Applications*, v. 3, p. 15–20, 2012. Citado na página 32.
- SPEARMAN, C. The proof and measurement of association between two things. *The American journal of psychology*, JSTOR, v. 15, n. 1, p. 72–101, 1904. Citado na página 35.
- TEKIN, C.; SCHAAR, M. van der. Contextual online learning for multimedia content aggregation. *IEEE Transactions on Multimedia*, IEEE, v. 17, n. 4, p. 549–561, 2015. Citado na página 17.
- TIBSHIRANI, R. Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society. Series B (Methodological)*, JSTOR, v. 58, n. 1, p. 267–288, 1996. Citado na página 34.

- VARGAS-GOVEA, B.; GONZÁLEZ-SERNA, G.; PONCE-MEDELLIN, R. Effects of relevant contextual features in the performance of a restaurant recommender system. In: *Proceedings of the 3rd International Workshop on Context-Aware Recommender Systems (CARS 2011)*. Chicago, USA: ACM, 2011. v. 11, n. 592. Citado 5 vezes nas páginas 22, 38, 40, 41 e 44.
- VÉRAS, D. *Cd-cars: cross domain context-aware recommender systems*. 241 f. Tese (Doutorado em Ciência da Computação) — Universidade Federal de Pernambuco (UFPE), Recife, 2016. Citado 16 vezes nas páginas 17, 18, 19, 22, 23, 25, 28, 29, 35, 39, 40, 41, 42, 44, 46 e 73.
- VERAS, D.; PRUDENCIO, R.; FERRAZ, C.; BISPO, A.; PROTA, T. Context-aware techniques for cross-domain recommender systems. In: IEEE. *2015 Brazilian Conference on Intelligent Systems (BRACIS)*. [S.l.], 2015. p. 282–287. Citado na página 42.
- VIEIRA, V.; TEDESCO, P.; SALGADO, A. C. Modelos e processos para o desenvolvimento de sistemas sensíveis ao contexto. In: *Jornadas de Atualização em Informática*. [S.l.: s.n.], 2009. p. 381–431. Citado na página 24.
- YU, L.; LIU, H. Feature selection for high-dimensional data: A fast correlation-based filter solution. In: *Proceedings of the 20th international conference on machine learning (ICML-03)*. [S.l.]: AAAI Press, 2003. p. 856–863. Citado na página 30.
- ZHANG, X.; CHENG, J.; YUAN, T.; NIU, B.; LU, H. Toprec: Domain-specific recommendation through community topic mining in social network. In: *Proceedings of the 22nd International Conference on World Wide Web*. New York, NY, USA: ACM, 2013. p. 1501–1510. Citado na página 35.
- ZOU, H. The adaptive lasso and its oracle properties. *Journal of the American statistical association*, Taylor & Francis, v. 101, n. 476, p. 1418–1429, 2006. Citado na página 34.

Apêndices

APÊNDICE A – Exemplo de arquivo .arff utilizado pelo WEKA

```
1 @relation dataset-cdcars
2
3 @attribute day {1,2,3,4,5,6,7}
4 @attribute city {0,1,2,3,4,5,6,7,8,9,10}
5 @attribute companion {0,1,2,3,4,5}
6 @attribute rating {1,2,3,4,5}
7
8 @data
9 6,3,4,2
10 4,2,1,3
11 6,0,3,5
```

APÊNDICE B – Exemplo de arquivo .csv sem cabeçalho

```
1 6,3,4,2  
2 4,2,1,3  
3 6,0,3,5
```



```
    print "Índice das Principais Características Seleccionadas",idx;
    # valor da função objetivo correspondente
    # das características seleccionadas
    print "J_CMI",J_CMI;
    # informações mútua correspondentes
    # entre as características seleccionadas
    print "MIfy",MIfy;

if __name__ == '__main__':
    main()
```

APÊNDICE D – Exemplo de arquivo .csv com cabeçalho

```
1 day, city, companion, rating  
2 6,3,4,2  
3 4,2,1,3  
4 6,0,3,5
```

APÊNDICE E – Código gerado para executar o algoritmo *Monte Carlo Feature Selection* (MCFS) na linguagem de programação R.

```
install.packages("rmcfs")
install.packages("caret")
library("rmcfs")
library("caret")
data <- read.csv(file.choose(), header = T, sep = ",")
foldsCrossValidation <- createFolds(factor(data$rating),
k=10, list = TRUE)
for (i in 1:length(foldsCrossValidation)){
  result <- mcfc(rating~., data[-foldsCrossValidation[[i]],])
}
```