



UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO

DEINFO

BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

RODRIGO JOSÉ GADELHA XAVIER MONTEIRO

**AVALIAÇÃO DO SISTEMA CD-CARS COM  
EXPERIMENTOS FOCADOS EM USUÁRIOS**

TRABALHO DE CONCLUSÃO DE CURSO

Recife

2017

RODRIGO JOSÉ GADELHA XAVIER MONTEIRO

## **AVALIAÇÃO DO SISTEMA CD-CARS COM EXPERIMENTOS FOCADOS EM USUÁRIOS**

Trabalho de Conclusão de Curso apresentado ao Bacharelado em Ciência da Computação, da Universidade Federal Rural de Pernambuco, como parte dos requisitos necessários à obtenção do título de Bacharel em Ciência da Computação.

Orientador: Prof. Dr. Douglas Vêras

Recife  
2017



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 Rodrigo José Gadelha Xavier Monteiro às 09 horas do dia 08 de fevereiro 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 **Avaliação do Sistema CD-CARS com Experimentos Focados em Usuários**, orientado por Douglas Vêras e Silva e aprovado pela seguinte banca examinadora:

Douglas Vêras e Silva  
DEINFO/UFRPE

Carlos Julian Menezes Araujo  
DEINFO/UFRPE

André Câmara Alves do Nascimento  
DEINFO/UFRPE

*Dedico esta tese a minha mãe Patrícia, meus irmãos João e Amanda e em memória de meu pai Fernando e meu avô Xavier.*

## Agradecimentos

Agradeço primeiramente aos meus pais, Fernando e Patrícia, aos meus avôs, Xavier, Antônio e Lindalva, meus irmãos João e Amanda, por sempre me incentivarem a enfrentar novos desafios e me apoiarem.

Agradeço aos meus colegas de turma, que estiveram ao meu lado durante esta jornada.

Agradeço ao meu orientador, Professor Douglas Vêras, pelos ensinamentos e compreensão, tornando possível a conclusão deste trabalho, e aos professores da Universidade Federal Rural de Pernambuco, que contribuíram em minha formação.

Agradeço a todos os meus amigos e familiares, pessoas muito importantes para mim, que torceram e contribuiriam diretamente ou indiretamente para que fosse possível alcançar esse objetivo.

## Resumo

Tradicionalmente, os sistemas de recomendações são avaliados utilizando as técnicas que fazem parte da abordagem *offline* de avaliação, ou seja, uma avaliação sem a participação de usuários. Essa abordagem mensura a acurácia dos algoritmos de recomendação de um sistema. Devido à grande quantidade de conteúdos disponíveis (filmes, livros, músicas, vídeos, jogos, entre outros) principalmente através da internet foram desenvolvidas aplicações práticas dos sistemas de recomendações, fazendo-se necessário avaliar os sistemas de recomendação com experimentos focados em usuários (abordagem *online* de avaliação). Este trabalho tem como objetivo aplicar as técnicas da abordagem *online* de avaliação para avaliar o sistema de recomendação CD-CARS e fazer um comparativo entre os resultados das avaliações *offline* e *online* do sistema. O sistema CD-CARS foi escolhido por se tratar de um sistema que utiliza técnicas complexas de recomendação, relacionando diversos domínios (filmes, livros e músicas), como também os contextos de companhia, localização e temporal dos usuários para fazer recomendações. Para atingir nosso objetivo, foi realizado um experimento dividido em duas etapas, com a participação de 34 usuários. Avaliando às recomendações propostas pelos algoritmos de recomendação do sistema CD-CARS em contextos temporais e de companhia. Os resultados dessa pesquisa convergem com os resultados da avaliação *offline* do sistema CD-CARS, onde os algoritmos que tiveram as maiores taxas de acerto, também foram escolhidos pelos usuários como os algoritmos com as recomendações mais satisfatórias nos cenários analisados.

Palavras-chave : Sistemas de recomendação, abordagem online de avaliação, abordagem *offline* de avaliação.

## Abstract

Traditionally, the recommender systems are evaluated with offline experiments, which means, an evaluation without involving users, this approach measures the accuracy of the recommender algorithms in a recommender system. Due to the huge amount of content available (movies, books, music, videos, games, etc.) principally on the internet, practical applications for recommender systems were developed, being necessary to evaluate the recommender systems with users experiments(online evaluation). In this paper, our main objective is to evaluate the CD-CARS recommender system with online evaluation experiments and compare with results from CD-CARS's offline evaluation. The CD-CARS system was chosen because of its complex techniques, associating several domains (movies, books, and music) and also the users' companion, location, and temporal contexts to make recommendations. To achieve our goal, we made an experiment in two steps, with 34 users. Evaluating the recommendations made by CD-CARS algorithms for companion and temporal contexts. Our results converge with offline evaluation results, showing that the most accurate algorithms were also chosen by users as the algorithms with most satisfying recommendations in the analyzed scenarios.

Keywords: recommender systems, evaluation, offline evaluation

## Lista de ilustrações

Figura 1 – Método de filtragem colaborativa . . . . .	19
Figura 2 – Método baseado em conteúdo . . . . .	20
Figura 3 – Definições de domínios . . . . .	22
Figura 4 – Cenários de sobreposição . . . . .	24
Figura 5 – Taxonomia de exploração de conhecimento em sistemas de recomendação cross-domain . . . . .	26
Figura 6 – Avaliação de sistemas de recomendação com Usuários . . . . .	34
Figura 7 – Avaliação do filme Forest Gump . . . . .	45
Figura 8 – Pergunta de contexto temporal e companhia. . . . .	46
Figura 9 – Gráfico avaliação dos usuários no contexto temporal . . . . .	47
Figura 10 – Gráfico avaliação dos usuários no contexto companhia . . . . .	48
Figura 11 – Gráfico de distribuição dos usuários em cada contexto temporal utilizado nas recomendações . . . . .	49
Figura 12 – Gráfico de distribuição dos usuários em cada contexto de companhia utilizado nas recomendações . . . . .	49
Figura 13 – Grau de satisfação dos usuários em relação às recomendações de contexto temporal feitas pelos algoritmos A,B e C . . . . .	53
Figura 14 – Quantidade de recomendações relevantes para o contexto temporal dos algoritmos A, B e C . . . . .	54
Figura 15 – Concordância com a ordem das recomendações para o contexto temporal dos algoritmos A, B e C . . . . .	54
Figura 16 – Grau de satisfação dos usuários em relação às recomendações de contexto de companhias feitas pelos algoritmos A, B e C . . . . .	55
Figura 17 – Quantidade de recomendações relevantes para o contexto de companhia dos algoritmos A, B e C . . . . .	56
Figura 18 – Quantidade de recomendações relevantes para o contexto de companhia dos algoritmos A, B e C . . . . .	56
Figura 19 – Gráfico de análise de aceitação do CD-CARS online . . . . .	58
Figura 20 – Gráfico de análise de plataforma do CD-CARS online . . . . .	59
Figura 21 – Gráfico de análise de domínio do CD-CARS online . . . . .	60
Figura 22 – Seção 1 - Questionário final de avaliação do CD-CARS com usuários	71
Figura 23 – Seção 1 - Questionário final de avaliação do CD-CARS com usuários	72
Figura 24 – Seção 1 - Questionário final de avaliação do CD-CARS com usuários	72
Figura 25 – Seção 1 - Questionário final de avaliação do CD-CARS com usuários	73
Figura 26 – Seção 1 - Questionário final de avaliação do CD-CARS com usuários	73
Figura 27 – Seção 1 - Questionário final de avaliação do CD-CARS com usuários	74



Figura 28 – Seção 1 - Questionário final de avaliação do CD-CARS com usuários	74
Figura 29 – Seção 1 - Questionário final de avaliação do CD-CARS com usuários	75
Figura 30 – Seção 2 - Questionário final de avaliação do CD-CARS com usuários	76
Figura 31 – Seção 2 - Questionário final de avaliação do CD-CARS com usuários	77
Figura 32 – Seção 2 - Questionário final de avaliação do CD-CARS com usuários	77
Figura 33 – Seção 2 - Questionário final de avaliação do CD-CARS com usuários	78
Figura 34 – Seção 2 - Questionário final de avaliação do CD-CARS com usuários	78
Figura 35 – Seção 2 - Questionário final de avaliação do CD-CARS com usuários	79
Figura 36 – Seção 2 - Questionário final de avaliação do CD-CARS com usuários	79
Figura 37 – Seção 2 - Questionário final de avaliação do CD-CARS com usuários	80
Figura 38 – Seção 3 - Questionário final de avaliação do CD-CARS com usuários	81
Figura 39 – Seção 3 - Questionário final de avaliação do CD-CARS com usuários	81
Figura 40 – Seção 3 - Questionário final de avaliação do CD-CARS com usuários	82
Figura 41 – Seção 3 - Questionário final de avaliação do CD-CARS com usuários	83
Figura 42 – CD-CARS WEB Login. . . . .	84
Figura 43 – CD-CARS WEB página inicial. . . . .	85
Figura 44 – CD-CARS Web filmes recomendados. . . . .	86

## Lista de tabelas

Tabela 1 – Comparação da avaliação focada em usuários dos trabalhos relacionados com o CD-CARS. . . . .	38
Tabela 2 – “book-television dataset” com 50% de sobreposição e programas de tv como domínio alvo . . . . .	42
Tabela 3 – “book-television dataset” dos usuários da pesquisa . . . . .	43
Tabela 4 – “book-television dataset” com 50% de sobreposição e programas de tv como domínio alvo com inclusão dos usuários da pesquisa . . . .	44
Tabela 5 – Avaliação CD-CARS offline MAE com 50% de sobreposição e contexto temporal e companhia em relação ao algoritmo base de comparação NNUserNgrbrtransClosure . . . . .	62
Tabela 6 – Comparação resultados das avaliações offline (MAE) x online do CD-CARS . . . . .	63

## Lista de abreviaturas e siglas

CA	context-aware
CARS	Context-aware Recommender System
CB	content-based
CD	CROSS-DOMAIN (Domínio Cruzado)
CD-CARS	CROSS-DOMAIN CONTEXT-AWARE RECOMMENDER SYSTEM
CDRS	Cross-Domain Recommender Systems
CDRS CF	Cross-Domain Recommender Systems Collaborative Filtering
CF	collaborative filtering
EXP	User Experience
INT	Interaction
MAE	Mean Absolute Error
OSAs	Objective System Aspects
PreF	Pre-filtering
RMSE	Root Mean Squared Error
RS	Recommender System
SD	SINGLE-DOMAIN (Domínio Único)
SD-CARS	Single-Domain Context-Aware Recommender System
SDRS	single-domain recommender systems
SSAs	Subjective System Aspects

## Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>13</b>
<b>1.1</b>	<b>Motivação</b>	<b>14</b>
<b>1.2</b>	<b>Problemática</b>	<b>15</b>
<b>1.3</b>	<b>Objetivos</b>	<b>16</b>
<b>1.4</b>	<b>Estrutura do Trabalho</b>	<b>16</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>18</b>
<b>2.1</b>	<b>Sistemas de Recomendação</b>	<b>18</b>
<b>2.2</b>	<b>Sistemas de Recomendação de Domínios Cruzados.</b>	<b>21</b>
<b>2.3</b>	<b>Sistemas de Recomendação Sensíveis à Contexto do Usuário</b>	<b>26</b>
<b>2.4</b>	<b>CD-CARS</b>	<b>29</b>
<b>2.5</b>	<b>Abordagens Online e Offline de Avaliação de sistemas de recomendação</b>	<b>31</b>
2.5.1	Abordagem Offline de avaliação de sistemas de recomendação	31
2.5.2	Abordagem Online de avaliação de sistemas de recomendação	32
<b>2.6</b>	<b>Trabalhos relacionados</b>	<b>34</b>
2.6.1	Comparação teórica entre abordagens de avaliação offline e online	34
2.6.2	Trabalhos relacionados avaliados com a abordagem online	35
<b>3</b>	<b>METODOLOGIA DE PESQUISA</b>	<b>40</b>
<b>3.1</b>	<b>Definição da metodologia de pesquisa</b>	<b>40</b>
<b>3.2</b>	<b>Coleta e análise de dados dos questionários.</b>	<b>44</b>
<b>3.3</b>	<b>Considerações finais</b>	<b>51</b>
<b>4</b>	<b>RESULTADOS</b>	<b>52</b>
<b>4.1</b>	<b>Resultados da análise de dados</b>	<b>52</b>
<b>4.2</b>	<b>Comparação avaliação <i>Online</i> x <i>Offline</i> do CD-CARS</b>	<b>62</b>
<b>5</b>	<b>CONCLUSÃO</b>	<b>65</b>
<b>5.1</b>	<b><i>Trabalhos futuros</i></b>	<b>65</b>
	<b>REFERÊNCIAS</b>	<b>66</b>

<b>APÊNDICES</b>	<b>70</b>
<b>APÊNDICE A – QUESTIONÁRIO FINAL DE AVALIAÇÃO DO CD-CARS COM USUÁRIOS . . . . .</b>	<b>71</b>
<b>APÊNDICE B – PROTÓTIPO CD-CARS WEB . . . . .</b>	<b>84</b>

## 1 Introdução

Os avanços tecnológicos permitiram ao usuário dispor de uma grande variedade de serviços onde gigantes da tecnologia e entretenimento como Amazon.com (LINDEN; SMITH; YORK, 2003), Netflix (BENNETT; LANNING, 2007), Google INC (DAS et al., 2007), Spotify (GOLDMANN; KREITZ, 2011) oferecem a um baixo custo ou de forma gratuita, serviços de “*streaming*” de diversos conteúdos como vídeos, músicas, filmes, programas de TV com qualidade e que possuem uma quantidade enorme de conteúdo.

É muito comum vermos em aplicações online sistemas capazes de aprender as preferências dos usuários e fazer recomendações. Uma quantidade significativa de usuários acredita na capacidade das aplicações em anteciparem suas vontades, antes mesmo de existirem (GROSSMAN, 2010).

Atualmente o foco principal de empresas e diversos projetos de pesquisa é desenvolver serviços e técnicas que possuam não apenas segurança e confiabilidade, mas principalmente comodidade e praticidade ao usuário, filtrando de forma autônoma e eficiente todo o tipo de conteúdo que possa interessá-lo (GOLDMANN; KREITZ, 2011). Por isso, incentivam e fomentam pesquisas para aprimorar cada vez mais seus sistemas de recomendação, aumentando o grau de satisfação do usuário com seus serviços, número de vendas, publicidade direcionada, entre outros benefícios (BENNETT; LANNING, 2007).

Com base neste e em outros aspectos, desde a década de noventa, durante a popularização da internet, são desenvolvidas pesquisas na área de Sistemas de Recomendação (RESNICK et al., 1994). Podendo ser aplicadas em várias áreas distintas como Publicidade (DAS et al., 2007), guias com avaliações de programas de TV, Filmes e Seriados (VÉRAS et al., 2015a), *Streamers* de Músicas (GOLDMANN; KREITZ, 2011) e aplicativos voltados para Turismo, Lazer, Comércio e Gastronomia (ZHENG et al., 2010), entre outros.

Os sistemas de recomendação que oferecem recomendações sobre uma única categoria específica (Livros, Filmes, Músicas, etc.) são classificados como *single-domain* (domínio único) (FERNÁNDEZ-TOBIÁS et al., 2012). Muitos sistemas de recomendação da atualidade focam em se especializar em determinados domínios, por exemplo, a Netflix com filmes e programas de TV (BENNETT; LANNING, 2007), essa característica de focar em apenas em um domínio não é vista pelos usuários como uma deficiência do sistema de recomendação, mas como uma especialização em um nicho de mercado (CANTADOR et al., 2015).

Os sistemas de recomendação que oferecem recomendações de várias catego-

rias são classificados como sistemas de recomendação de domínio cruzado (*cross-domain*), por exemplo, um sistema de recomendação que associa filmes e músicas para fazer recomendações de livros (FERNÁNDEZ-TOBIÁS et al., 2012). Os sistemas de recomendação de domínio cruzado foram desenvolvidos tanto pela necessidade dos usuários em contar com sistemas versáteis (FERNÁNDEZ-TOBIÁS et al., 2012) quanto para solucionar problemas clássicos dos sistemas de recomendação de domínio único, por exemplo, o problema do **cold-start** que começou a ser observado no começo dos anos 2000, onde não se sabe o que recomendar para o usuário recém cadastrado no sistema (BURKE, 2002).

Alguns Sistemas de Recomendação também levam em consideração os contextos do usuário, sendo denominados de sensíveis a contexto (*context-aware*) (SAHEBI; BRUSILOVSKY, 2013). Os Sistemas de Recomendação sensíveis a contexto analisam as informações de contexto de um usuário para fazer uma recomendação. Existem várias definições de contexto como podemos ver na Seção 2.3 deste trabalho, onde serão definidos os conceitos teóricos de contexto. Podemos considerar como contexto qualquer informação relevante ao usuário, sendo sua localização, dia da semana em que a recomendação será realizada, se o usuário está sozinho ou acompanhado de amigos, entre outros (ADOMAVICIUS; TUZHILIN, 2015).

Melhorar a qualidade e precisão das recomendações, utilizando contextos do usuário para associa-las mesmo que pertençam a domínios diferentes, tornando a recomendação mais completa e abrangente, ou utilizar técnicas que possam aprimorar as recomendações em domínios únicos são provavelmente os maiores desafios presente na área de sistemas de recomendação atualmente (VÉRAS, 2016).

## 1.1 Motivação

Um dos sistemas de recomendação sensíveis a contexto e de domínio cruzado que foi proposto para melhorar a qualidade das recomendações foi o Sistema O CD-CARS (*cross-domain context-aware recommender system*). O sistema utiliza técnicas de recomendação abordando desde a análise e associação de perfis dos usuários e itens recomendados pelo sistema, como também o contexto de cada usuário para cada recomendação (VÉRAS, 2016).

Os algoritmos e técnicas de recomendação que resultaram no sistema CD-CARS foram avaliados na abordagem *offline* de avaliação de sistema de recomendação (CANTADOR et al., 2015). Ou seja, todos os testes e treinamento dos algoritmos foram realizados sem o envolvimento de usuários (VÉRAS, 2016).

Por não se fazer necessário experimentos com a participação de usuários reais a maioria dos sistemas de recomendação assim como o Sistema CD-CARS

foram calibrados e o sistema avaliado utilizando apenas técnicas da abordagem *offline* de avaliação de sistema de recomendações (VÉRAS, 2016).

Apesar de a abordagem *offline* ser a mais utilizada, existe outra abordagem de avaliação de sistemas de recomendações, a abordagem *online* ou focada em usuários (BEEL; LANGER, 2015).

Na abordagem *online*, a avaliação das técnicas de recomendação de um sistema de recomendação é feita de acordo com a experiência de usuários reais em ambientes controlados (B.P.; M.C., 2015). Normalmente validada através de questionários, com o objetivo que os usuários analisem aspectos particulares ou gerais do sistema (BEEL; LANGER, 2015).

Segundo autores pioneiros na área de pesquisa de avaliação de sistemas de recomendação com usuários, no começo dos anos 2000, a principal métrica a ser avaliada é o grau de satisfação do usuário ao utilizar o sistema (MCNEE et al., 2002) e (TORRES et al., 2004).

Medir o grau de satisfação de usuários em um sistema de recomendação complexo como o CD-CARS, que leva em consideração os contextos e associa diferentes domínios para fazer recomendações mais assertivas contribui com a área de avaliação com usuários de sistemas de recomendação.

Aplicar em usuários reais técnicas de recomendação sensíveis a contexto, tendo a possibilidade de avaliar as recomendações feitas pelo sistema em contextos reais e coletar as opiniões dos usuários sobre os resultados, utilizar um caso de uso prático para relacionar domínios e coletar novas avaliações de usuários são algumas das contribuições feitas por esse trabalho de pesquisa para área de avaliação com usuários de sistemas de recomendação.

## 1.2 Problemática

O grau de satisfação é resultado de uma avaliação feita pelo usuário que engloba um conjunto de vários aspectos e funcionalidades de um sistema de recomendação, seja usabilidade, performance, diversidade das recomendações ou precisão em recomendar exatamente aquilo que o usuário esperava (TORRES et al., 2004).

O ponto de partida para (MCNEE et al., 2002) e (TORRES et al., 2004) vem de relatos durante experimentos de técnicas de recomendação. Onde usuários avaliaram como mais satisfatórias as recomendações feitas pelos sistemas que possuíam algoritmos com menor acurácia. O que para ambos os autores foi uma surpresa (MCNEE et al., 2002) e (TORRES et al., 2004).

Avaliar os Sistemas de Recomendação utilizando a abordagem *online* apesar de



ser um processo muito mais complexo resulta em sistemas de recomendação voltados para usuários reais que solucionam problemas reais (TORRES et al., 2004).

Diversos autores seguem a mesma linha de raciocínio, sendo assim foram consolidadas as técnicas que fazem parte da abordagem *online* ou focadas em usuários para avaliação de sistemas de recomendação (SHANI; GUNAWARDANA, 2011), (GAVALAS, 2013),(B.P.; M.C., 2015),(BEEL; LANGER, 2015).

Nosso trabalho diverge dos demais trabalhos relacionados citados acima, pois nossa avaliação com usuário foi realizada em um sistema de recomendação de domínio cruzado que utiliza técnicas de recomendação baseada em conteúdo e sensível a contexto, enquanto os autores analisaram sistemas de domínios únicos ou não especificaram a classificação em relação domínios.

### 1.3 Objetivos

Este trabalho tem como objetivo avaliar com usuários o sistema CD-CARS (VÉRAS, 2016), aplicando as técnicas da abordagem de avaliação focada em usuários de sistema de recomendação (*online*), medindo grau de satisfação dos usuários em relação a recomendações feitas pelo sistema.

Os Objetivos Específicos dessa pesquisa são:

- Fazer um comparativo dos resultados das duas abordagens de avaliação, online x offline do sistema CD-CARS. Com a finalidade de analisar se os resultados convergem ou divergem dos resultados obtidos pela avaliação *offline*.
- Enriquecer a base de dados de usuários utilizada pelo sistema CD-CARS adicionando novos usuários e contextos de avaliações (*ratings*) dos itens presentes da base dados do CD-CARS.
- Propor uma aplicação prática do CD-CARS através de um protótipo com arquitetura *web*, para possibilitar uma melhor escalabilidade do sistema e avaliação com novos usuários.

### 1.4 Estrutura do Trabalho

Este trabalho está organizado da seguinte forma:

- No Capítulo 2, são apresentados os conceitos teóricos relacionados ao tema deste trabalho, bem como os trabalhos relacionados que contribuíram para essa pesquisa.

- 
- No Capítulo 3 é descrita toda metodologia da pesquisa aplicada, desde a coleta até a análise dos dados da pesquisa.
  - No Capítulo 4 são apresentados os resultados dessa pesquisa.
  - No Capítulo 5, são apresentadas as considerações finais e os trabalhos futuros deste trabalho.

## 2 Fundamentação Teórica

Este capítulo é dividido em 3 seções para detalhar de forma mais aprofundada a definição dos conceitos e trabalhos que contribuíram com essa pesquisa.

Na Seção 2.1 foram definidos os conceitos e técnicas utilizadas em sistemas de recomendação. A Seção 2.2 foca nos conceitos de sistemas de recomendação de domínios cruzado (**CDRS**). A Seção 2.3 foca nos conceitos de sistemas de recomendação sensíveis à contexto (**CARS**). A seção 2.4 foi dedicada a definição do Sistema CD-CARS, conceitos e técnicas utilizadas pelo sistema. Na Seção 2.5 foram definidas as técnicas e métricas de avaliação das abordagens *offline* e *online* de avaliação para sistemas de recomendação.

### 2.1 Sistemas de Recomendação

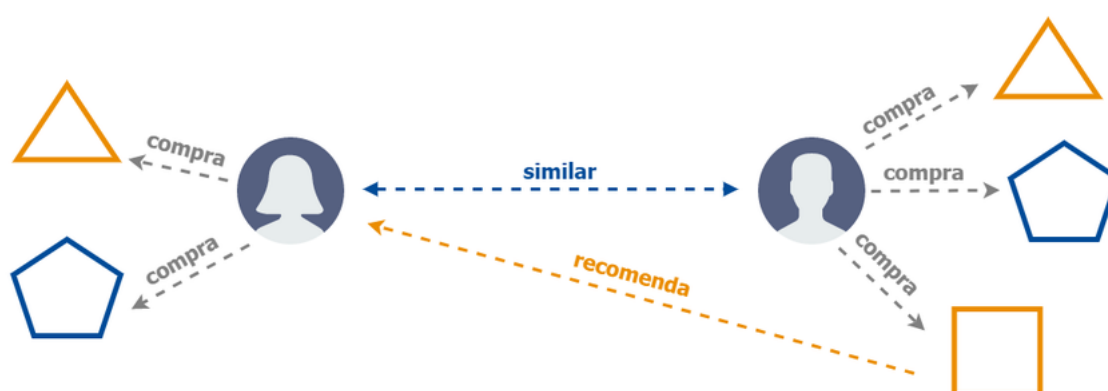
Um sistema de recomendação é um conjunto de ferramentas e técnicas que provêm sugestões para itens (livros, músicas, filmes, etc.) que se assemelham ao interesse de um usuário em particular (RICCI; ROKACH; SHAPIRA, 2015).

Abaixo serão definidos os paradigmas de recomendação mais utilizados, cada paradigma tem sua particularidade e utilizam critérios bastante distintos para fazer recomendações (VÉRAS, 2016), são eles:

***Collaborative Filtering (CF)*** — Considerada a mais popular e mais utilizada entre as técnicas em sistemas de recomendação (RS), leva em consideração as similaridades entre os perfis dos usuários ativos para fazer novas recomendações, a associação de preferência dos usuários é calculada com base nas avaliações dos itens feitas previamente pelos usuários (KOREN; BELL, 2015).

A Figura 1 abaixo, representa o modelo de Recomendação por Filtragem colaborativa, ilustrando uma recomendação feita baseada em similaridades entre os dois perfis analisados. No exemplo, temos os Usuários A e B que consomem os mesmos produtos e fazem avaliações semelhantes desses produtos, no momento em que um deles realizar uma nova compra, o sistema de recomendação entende que o outro usuário é também um potencial comprador daquele produto, fazendo recomendação do novo item para o mesmo.

Figura 1 – Método de filtragem colaborativa

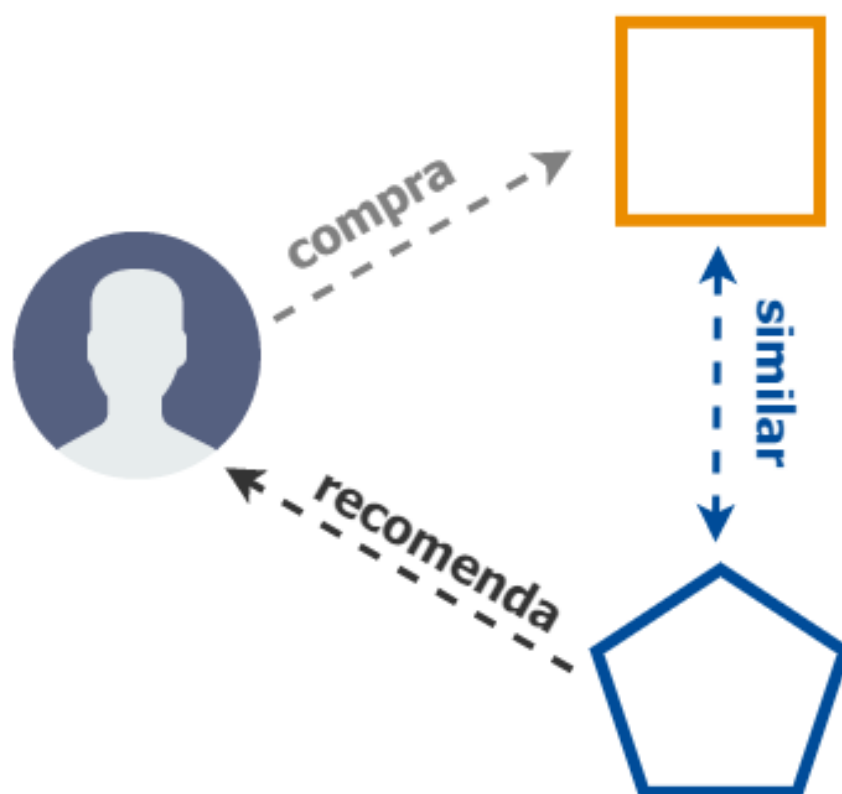


Adaptado de: Análise de grande conjunto de dados por trás de Sistemas de Recomendação Disponível em: <<https://indatalabs.com/blog/data-science/big-data-behind-recommender-systems>>. Acesso em: 12 dez. 2017.

**Content-based (CB)** — O princípio geral dos métodos cognitivos (baseados em conteúdo), é identificar similaridades entre os itens que receberam boas avaliações e depois recomendar itens que possuam essa mesma característica. Essa técnica geralmente tem dois grandes problemas, o primeiro é a análise limitada de conteúdo (**limited content analysis**), esse problema ocorre quando o sistema tem limitações em relação às informações de um conteúdo (ADOMAVICIUS; TUZHILIN, 2005). Por exemplo, um sistema tem um determinado elemento que não se associa com os demais por ser muito específico. Super especialização (*Over-specialization*), é um efeito colateral da análise de conteúdo, como leva em consideração a associação entre os itens, provavelmente o sistema só vai recomendar itens da mesma categoria, por exemplo, filmes do mesmo gênero ou com os mesmos atores/diretores, e o usuário pode já ter assistido ou consumido esses produtos recomendados, não sendo uma recomendação muito útil (WANG, 2017).

A Figura 2 abaixo, representa o modelo de recomendação pelo conteúdo, o sistema relaciona os itens disponíveis fazendo uma recomendação baseada na similaridade entre os itens.

Figura 2 – Método baseado em conteúdo



Adaptado de: Análise de grande conjunto de dados por trás de Sistemas de Recomendação Disponível em: <<https://indatalabs.com/blog/data-science/big-data-behind-recommender-systems>>. Acesso em: 12 dez. 2017.

**Context-Aware (CA)** — O contexto do usuário pode ser definido como os fatores relevantes em relação ao momento do usuário, sendo determinante para que o usuário aceite ou não uma recomendação feita pelo sistema. De maneira geral um sistema de recomendação que leva em consideração o contexto do usuário em relação à localização e companhia, por exemplo, tem uma chance maior de assertividade (ADOMAVICIUS; TUZHILIN, 2015). Por exemplo, um sistema que recomenda filmes e leva em consideração se o usuário está sozinho ou acompanhado pode prever qual seria a preferência do usuário de acordo com cada situação (contexto) (VÉRAS, 2016).

Além dos paradigmas citados descritos acima existem outros como Métodos de mineração de dados (**DMM**), Métodos baseados em semântica, Métodos Impessoais e etc (VÉRAS, 2016). Nesse trabalho enfatizamos os sistemas de recomendação que

utilizam técnicas de recomendações dos paradigmas **CF, CB** e **CA**.

A próxima seção será dedicada aos conceitos teóricos de sistemas de recomendação de domínios cruzados.

## 2.2 Sistemas de Recomendação de Domínios Cruzados.

Como definido na seção 1 deste documento, Um sistema de recomendação de domínio cruzado (CDRS) é um sistema de recomendação que utiliza técnicas de associação de itens e análise de conteúdo para classificar e associar itens de categorias distintas e fazer recomendações para os usuários, por exemplo, um sistema de recomendação que associa filmes e músicas para fazer recomendações de livros (FERNÁNDEZ-TOBIAS et al., 2012).

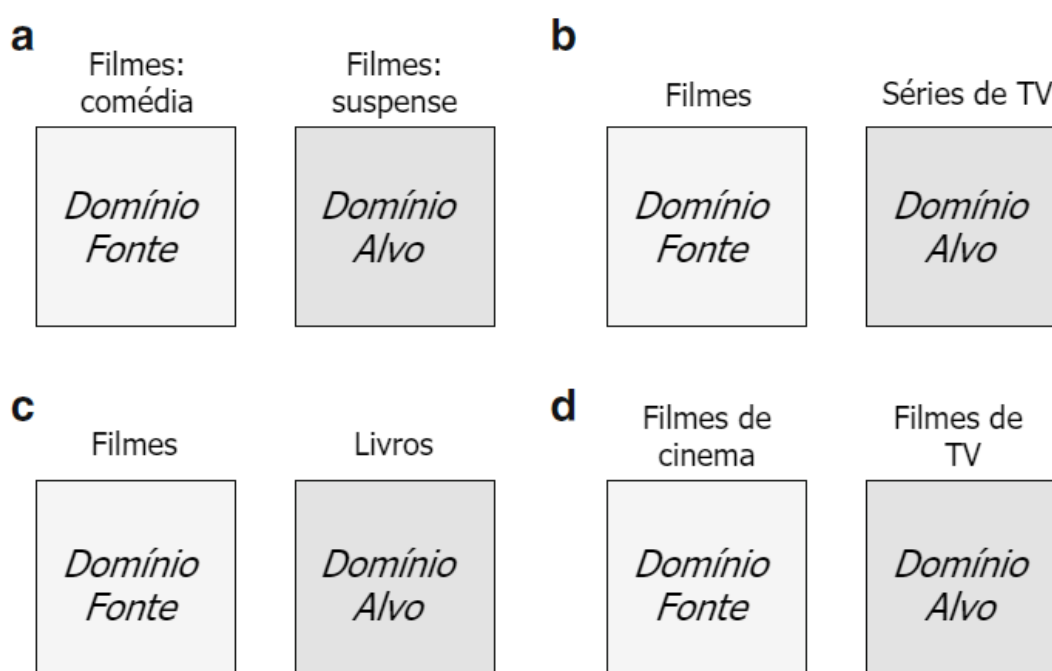
Não há consenso na literatura sobre a definição de domínios, alguns consideram itens como livros e filmes pertencendo a domínios distintos, enquanto outros consideram gêneros diferentes como filmes de comédia e filmes de ação como domínios distintos (CANTADOR et al., 2015). Os autores consideram que domínio pode ser definido em 4 níveis distintos (ver a ilustração na Figura 3), são eles:

- (Elemento) a nível de atributo (**Attribute level**): Os itens recomendados pertencem ao mesmo conjunto, tendo as mesmas características, porém, serão considerados de domínios distintos se tem atributos diferentes, por exemplo, filmes pertencentes a domínios distintos se forem de gêneros distintos. Por exemplo, podemos utilizar os gêneros dos filmes para aumentar a diversidade das recomendações, recomendando filmes de suspense para usuários que só assistiram filmes de romance (CAO; LIU; YANG, 2010).
- (Elemento) a nível de tipo (**Type level**): Os itens recomendados têm várias similaridades e compartilham alguns atributos, porém, serão considerados pertencentes a domínios distintos se pertencerem a conjuntos distintos, por exemplo, programas de TV e filmes, pertencem a domínios distintos mesmo possuindo alguns atributos em comum (gênero, título, etc.) ainda existem atributos distintos e características que os distinguem (LONI, 2014).
- (Elemento) a nível de item (**Item level**): Os itens recomendados têm atributos em comum (título, gênero, autor, etc.), mas são elementos de conjuntos distintos, por exemplo, mesmo que um filme seja baseado no livro e possua vários atributos em comum, livros e filmes pertencem a domínios distintos (ENRICH; BRAUNHOFER; RICCI, 2013).
- a nível de sistema (**System level**): Os itens recomendados que pertencem a sistemas distintos, são considerados domínios distintos, por exemplo, filmes avaliados

no Sistema de recomendação (PAN; XIANG; YANG, 2012). Por exemplo, podemos considerar o MovieLens (HARPER; KONSTAN, 2016) e o Netflix (BENNETT; LANNING, 2007) sendo domínios distintos.

Na Figura 3 abaixo, os autores ilustram as definições, sendo (a) domínio a nível de atributo, (b) domínio a nível de tipo, (c) domínio a nível de item e (d) domínio a nível de sistema.

Figura 3 – Definições de domínios



Adaptado de: CANTADOR, I. et al., 2015

Uma vez que entendemos as diferentes definições de domínio podemos nos aprofundar nas técnicas e objetivo dos CDRS. Os sistemas de recomendação de domínio cruzado recomendam itens nos domínios alvos (*target domain*), explorando os conhecimentos dos domínios fontes (*source domain*), por exemplo, recomendar filmes para usuários, baseado nas avaliações feitas em livros.

Os CDRS conseguem resolver problemas clássicos presentes em SDRS, por exemplo, o problema de **cold-start** (BURKE, 2002) onde o sistema tem dificuldades de fazer recomendação para usuários recém cadastrados no sistema, ou itens recém adicionados.

A diversidade de domínios também contribui com o aumento de precisão e diversificação nas recomendações, porém, o principal objetivo dos CDRS é enriquecer o modelo de usuários do sistema, uma vez atingido esse objetivo o sistema terá

uma melhora significativa em descobrir novas preferências dos usuários nos domínios alvos, aprimorar a associação entre usuários e itens e associação entre os perfis de usuários (CANTADOR et al., 2015).

Definido em (FERNÁNDEZ-TOBIÁS et al., 2012) as atribuições de contexto de um CDRS podem ser explicitamente ou implicitamente associadas por CB ou CF, associando as características de usuários e/ou itens, como avaliações, preferências, relações semânticas, etc.

Se enxergarmos o sistema de recomendações como um universo de conjuntos, onde os usuários pertencem a um conjunto de usuários, e cada domínio do sistema é um conjunto de itens. Podemos fazer uma associação entre os domínios  $D_s$  (domínios fontes) e  $D_t$  (domínios alvos), por exemplo, quando usuários que tem avaliações e recomendações em mais de um domínio ou quando há uma associação em itens pertencentes a domínios distintos, por exemplo, a associação de livros que foram adaptados para filmes, ou livros e filmes que pertencem a mesma categoria (ação, drama, romance, etc.) (FERNÁNDEZ-TOBIÁS et al., 2012).

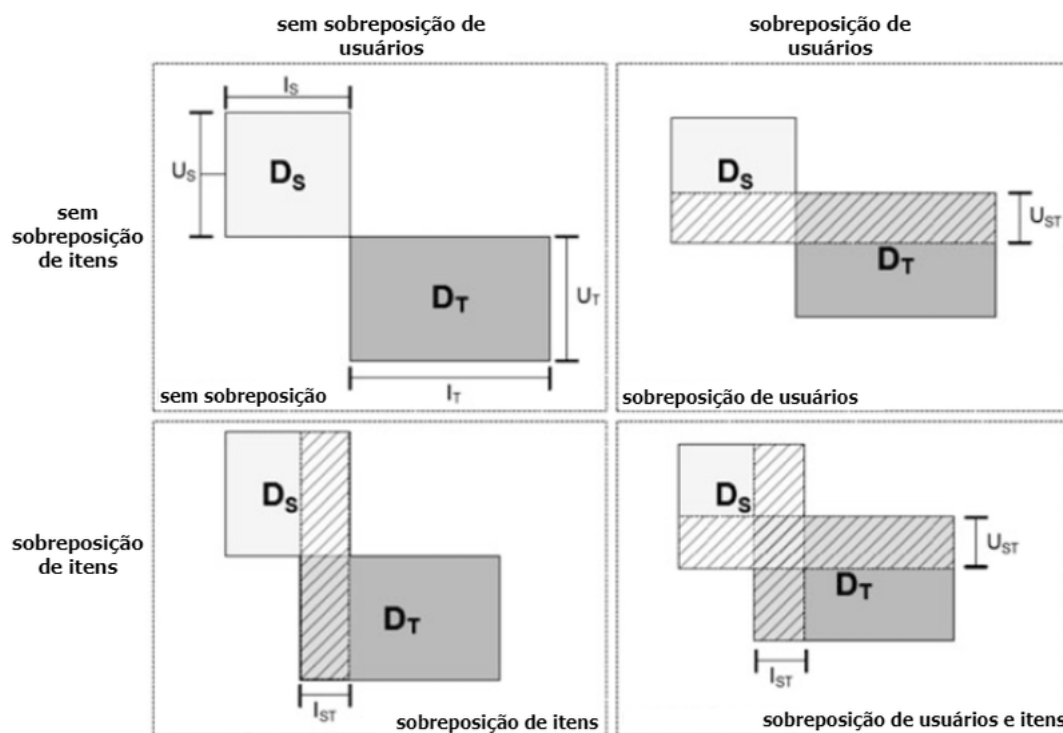
Em seguida (CANTADOR et al., 2015) descreve exemplos representativos de características dos usuários e itens, como as relações inter-domínios e os cenários de sobreposição de dados (***data overlap cenários***), sobreposição (*overlap*) mede o grau de duplicidade que existe em um conjunto.

- Relações baseadas em conteúdo (**CB**) entre domínios: nos sistemas que utilizam técnicas de recomendação baseadas em conteúdo, podemos definir como elementos do conjunto de conteúdo os atributos dos itens, por exemplo, as categorias e palavras-chave. Ao representarmos o perfil de um usuário através de um vetor, onde cada componente reflete o quanto cada usuário gosta ou está interessado em um elemento específico, podemos utilizar o mesmo raciocínio para definir que o perfil dos itens é composto por um vetor onde os componentes refletem as relevâncias dos atributos para o elemento. A sobreposição dos domínios  $D_s$  e  $D_t$  ocorrem quando um usuário possui recomendações em ambos os domínios e os itens recomendados para o usuário possuem atributos em comum.
- Relações de filtragem colaborativa (**CF**) entre domínios: nos sistemas que utilizam técnicas de recomendação de Filtragem colaborativa, as preferências do usuário são modeladas como uma matriz que relaciona os itens e as avaliações feitas pelos usuários, por exemplo, um usuário que avaliou muito bem filmes de ação, tende a receber recomendações de filmes de ação. A sobreposição *entre os domínios*  $D_s$  e  $D_t$  ocorre quando existem usuários com recomendações e avaliações em ambos os domínios e existem perfis similares para fazer a associação de novas recomendações.



Na Figura 4 abaixo, (CREMONESI; TRIPODI; TURRIN, 2011.) ilustra os possíveis cenários em relação a sobreposição entre os conjuntos de usuários e itens nos domínios  $D_s$  e  $D_t$ , são eles: sem sobreposição, sobreposição de usuários, sobreposição de itens e sobreposição de usuários e itens.

**Figura 4 – Cenários de sobreposição**



Adaptado de: CREMONESI, P. et al., 2011.

Segundo (CREMONESI; TRIPODI; TURRIN, 2011.) se generalizarmos os CDRS CF, nos deparamos com 4 cenários possíveis de sobreposição entre dois domínios  $D_s$  (source domain) e  $D_t$  (target domain) como mostrado na imagem acima.

- Sem sobreposição: Não há nenhuma sobreposição entre usuários e itens nos domínios.
- Sobreposição de usuários: Existem alguns usuários em comum que tem preferências de itens em ambos os domínios, contudo, todos os itens pertencem a um domínio único. Esse cenário pode ocorrer, por exemplo, quando os usuários avaliaram filmes e livros.
- Sobreposição de itens: Existem alguns itens em comum que foram avaliados por usuários de ambos os domínios, esse cenário pode ocorrer, por exemplo, quando dois serviços de "streaming" possuem itens em comum e foram avaliados em cada serviço.

- Sobreposição de usuários e itens: Existe Sobreposição entre os conjuntos de usuários e itens.

Uma vez que entendemos as definições de domínios, as técnicas e possíveis cenários de um CDRS, podemos entender a categorização das técnicas de recomendação de CDRS.

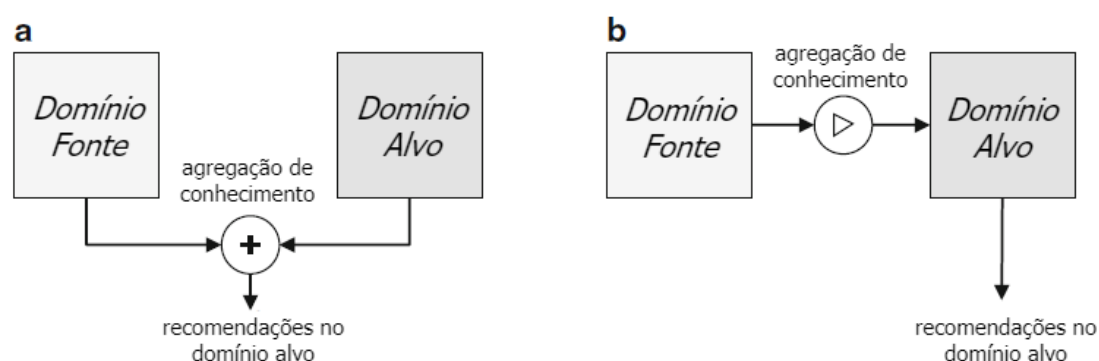
Os autores, (CANTADOR et al., 2015) após realizarem pesquisas em diversos trabalhos e perceberem a existência de várias categorizações para as técnicas de recomendação CD propuseram uma unificação dando origem a uma taxonomia de dois níveis, focada na exploração do conhecimento em recomendações de domínios cruzados.

Abaixo podemos ver a taxonomia proposta por (CANTADOR et al., 2015) :

- Agregação de conhecimento: O conhecimento de vários domínios fontes são agregados para realizar recomendações nos domínios alvos.
  - 1) Mesclando preferências dos usuários — Quando o conhecimento agregado consiste nas preferências do usuário (avaliações, histórico de compras, etc.) (SAHEBI; BRUSILOVSKY, 2013).
  - 2) Através do modelo de dados dos usuários — O conhecimento agregado sobre o modelo de dados do usuário coletados de vários sistemas de recomendação, por exemplo, similaridade entre usuários (SHAPIRA; ROKACH; FREILIKHMAN, 2013).
  - 3) Agregando Recomendações — O conhecimento agregado é composto por recomendações de domínios únicos (WINOTO; TANG, 2008).
- Vinculando/transferindo conhecimento: O vínculo ou transferência de conhecimento entre os domínios são estabelecidos pelas recomendações auxiliares.
  - 1) Vinculando domínios — Os domínios são vinculados pelo conhecimento em comum entre eles, por exemplo, atributos dos itens, correlação entre domínios, etc (WANG, 2017).
  - 2) Compartilhando características latentes — Os domínios fonte e alvos são relacionados através características latentes implícitas (TIROSHI et al., 2013).
  - 3) Transferindo padrões de avaliações — os padrões de avaliações do domínio fonte sejam eles explícitos ou implícitos são explorados no domínio alvo (NAKATSUJI et al., 2010).

Na Figura 5 abaixo, os autores ilustram a taxonomia proposta por eles. (a) Agregação de conhecimento. (b) Vinculando / transferindo conhecimento.

**Figura 5 – Taxonomia de exploração de conhecimento em sistemas de recomendação cross-domain**



z

Adaptado de: CANTADOR, I. et al., 2015

Dedicamos esta seção aos sistemas de recomendação de domínio cruzados e seus conceitos, principalmente os trabalhos (VÉRAS, 2016), (CREMONESI; TRIPODI; TURRIN, 2011.), (FERNÁNDEZ-TOBIÁS et al., 2012) e (CANTADOR et al., 2015).

### 2.3 Sistemas de Recomendação Sensíveis à Contexto do Usuário

Esta seção será dedicada a trabalhos relevantes na área de **CARS**, contendo a fundamentação teórica e exemplos de sistemas de recomendação que levam em consideração o contexto dos usuários na hora de realizar recomendações.

Sistemas de recomendação sensíveis a contexto, são sistemas de recomendações que analisam os momentos específicos dos usuários, podendo ser contexto em relação a companhia, onde as recomendações podem variar de acordo com a companhia se o usuário está sozinho ou acompanhado (TUNG; SOO, 2004), (RUOTSALOB et al., 2013), contexto temporal, onde as recomendações podem variar de acordo com o dia da semana ou estações do ano (ZHENG et al., 2010), (GUILLERMO FERNÁNDEZ et al., 2014), ou contexto de localização (YANG; HWANG, 2013), (ZHENG et al., 2012), onde as recomendações podem variar de acordo com a localização geográfica dos usuários, sejam países, estados ou cidades (ADOMAVICIUS; TUZHILIN, 2015).

Segundo (ADOMAVICIUS; TUZHILIN, 2015) existem várias abordagens para sistemas de recomendação focadas em recomendar os itens mais relevantes para um usuário individual, e essas abordagens não levam em consideração nenhuma informação de contexto como data, local, companhia de outras pessoas, informações

relevantes caso o usuário deseje assistir um filme ou escolher um lugar para jantar, por exemplo.

Em outras palavras, os sistemas de recomendação tradicionais tem apenas duas categorias de entidades, os usuários e os itens, e não levam em consideração o contexto do usuário no momento de fazer recomendações. Utilizando como exemplo um sistema que faz recomendações sobre pacotes de viagens, é importante incorporar as informações de contexto do usuário no momento da recomendação, pois, o usuário pode estar planejando suas férias, podendo viajar sozinho ou em família, no verão ou inverno, são contextos muito importantes na hora de tomar uma decisão sobre qual o destino ideal (ADOMAVICIUS; TUZHILIN, 2015).

Contexto é um conceito de múltiplas faces, tendo sido estudado e definido por diferentes pesquisadores, principalmente quando falamos de inteligência artificial e computação ubíqua. Segundo no início dos anos dois mil já existiam pesquisas apontando mais de 150 definições diferentes para contexto em diversas áreas de estudo (BAZIRE; BRÉZILLON, 2005).

Segundo (ADOMAVICIUS; TUZHILIN, 2015) uma questão tão importante quanto a definição de contexto, é definir como um sistema de recomendação fará a coleta e análise de contexto dos usuários, abaixo vamos definir algumas das técnicas de coleta de contexto:

- De maneira Explícita: Os usuários fornecem todas as informações de contexto utilizadas pelo sistema (LEE; KWON, 2014),(COLOMBO-MENDOZA, 2015). Essa coleta pode ser feita por forma de entradas ou cadastro no sistema, por exemplo, um usuário pode solicitar ao sistema uma atração turística de acordo com sua localização (YANG; HWANG, 2013)
- De maneira Implícita: Os usuários não fornecem de forma voluntária as informações de contexto e muitas vezes não estão cientes que o sistema faz uso dessas informações (OH, 2014),(PHAM; JUNG; VU, 2014). O próprio sistema faz essa análise, por exemplo, levando em consideração o GPS do *smart-phone* para fazer as recomendações (ZHENG et al., 2010).
- Por inferência: Utilizando as técnicas de inferência de contexto, as informações também são coletadas de forma implícita, porém, com o acréscimo de análises estatísticas e mineração de dados, uma vez que os contextos não podem ser coletados de forma explícita (SHEPSTONE; TAN; JENSEN, 2014). Por exemplo, um sistema de recomendações que lê informações do GPS do celular e faz inferências do contexto do usuário baseado nos lugares que ele já visitou (ZHENG et al., 2012).

Além da forma de obter informações de contexto dos usuários (ADOMAVICIUS; TUZHILIN, 2015) também definem que existem três paradigmas de recomendação contextual, sendo eles:

- Pré-filtragem contextual: Esse paradigma de recomendação contextual consiste em analisar os dados para cada contexto específico, organizando um conjunto de informações (avaliações dos usuários, por exemplo) relevantes para cada contexto do usuário (VÉRAS et al., 2015b). Sendo possível prever novas avaliações de usuários em determinados contextos, por exemplo, utilizando um sistema de recomendação de filtragem colaborativa no conjunto de informações filtradas(VÉRAS, 2016).
- Pós-filtragem contextual: Ao contrário do paradigma anterior, as informações de contexto dos usuários não são analisadas inicialmente, primeiro é utilizando um sistema de recomendação de filtragem colaborativa em toda a base de informação disponível e após o processamento dessas informações os resultados das avaliações feitas pelos usuários ou recomendações feitas pelo sistema, por exemplo, são ajustados(filtraados) para se encaixar da melhor forma no contexto dos usuários (PANNIELLO, 2009),(VÉRAS, 2016).
- Modelagem contextual: Nesse paradigma a informação contextual é tratada como um conjunto a parte, distinto do conjunto de itens e usuários, as recomendações são feitas de forma multi-dimensional, sendo as informações de contexto aplicadas diretamente nas recomendações e predições de avaliações, por exemplo (ADOMAVICIUS; TUZHILIN, 2015). Existem várias abordagens que podem ser aplicadas a este paradigma, por exemplo, árvores de decisão(OKU, 2006), tensores (matrizes)(HIDASI; TIKK, 2012) entre outros.

Os paradigmas definidos acima por (ADOMAVICIUS; TUZHILIN, 2015) não são os únicos existentes na literatura de Sistemas de Recomendação, (VÉRAS et al., 2015b) define outros paradigmas, que chama de “*Ad-hoc*” ou específicos, por exemplo, paradigmas de aprendizado supervisionado, baseado em similaridades e ontologia contextual.

No CD-CARS foram utilizadas apenas os paradigmas definidos por (ADOMAVICIUS; TUZHILIN, 2015) segundo o autor existe uma dificuldade em utilizar os paradigmas “*Ad-hoc*” em domínios distintos, pelo fato de terem sido desenvolvidos para domínios específicos (VÉRAS, 2016).

A próxima seção será dedicada ao Sistema CD-CARS, abordando seus conceitos teóricos, implementação e avaliação sistema.

## 2.4 CD-CARS

O CD-CARS (Cross-Domain Context-Aware Recommender System) é um sistema de recomendação desenvolvido seguindo os conceitos de Sistemas de recomendação de domínios cruzados (CDRS) e de sistema de recomendação sensíveis a contexto (CARS). Foi proposto um sistema que possui três domínios distintos sendo eles: filmes, livros e músicas. A classificação de domínio utilizada no Sistema é a nível de elemento (*Item Level*) definido na Seção 2.1.1 (VÉRAS, 2016).

Mesmo com uma quantidade enorme de sistema de recomendação baseados em CF, a combinação com entre eles e as técnicas de análise de contexto ainda são pouco exploradas. Com base nisso, Vérias direcionou as pesquisas do CD-CARS para a perspectiva de CF e CA. Considerando a avaliação do usuário em relação aos itens como uma função tridimensional.

$$CR: User \times Item \times Context \longrightarrow Contextual Ratings$$

O Sistema CD-CARS utiliza técnicas baseadas em **CF** e **CA** para associar similaridades de perfis e contextos dos usuários e entre atributos dos itens presentes na base de dados do sistema, por exemplo, se um usuário avaliou muito bem filmes e livros de romance com contexto de companhia em casal, o Sistema irá realizar recomendações com base no que foi recomendado para outros usuários com perfis similares, associando novos itens que tenham características (gênero do filme, atores, contexto de companhia etc.) similares, mas que ainda não foram avaliados pelo usuário em questão.

A seguir vamos definir os algoritmos utilizados por Vérias para o Sistema CD-CARS e quais os contextos do usuário são analisados pelo Sistema.

O sistema CD-CARS possui três algoritmos de recomendação, um algoritmo base de comparação, e os algoritmos de recomendação de domínio cruzado de pré e pós filtragem, que utilizam técnicas de análise de contexto e associação de usuários e elementos para fazer recomendações baseadas nas recomendações feitas pelo algoritmo base de compração, sendo eles:

- algoritmo base de comparação **NNUserNgb-transClosure**: O algoritmo escolhido por Vérias como base comparação foi o **NNUserNgb-transClosure**, um aprimoramento do algoritmo *NNUserNgb* proposto em (CREMONESI; TRIPODI; TURRIN, 2011.).

O algoritmo proposto por Cremonesi computa uma vizinhança formada a partir dos 'n' usuários mais próximos de um dado usuário. Usuários "mais próximos" são definidos por métricas de similaridades, em outras palavras, as recomendações são

derivadas a partir de uma vizinhança dos 'n' usuários com maior similaridade (VÉRAS, 2016).

A diferença do algoritmo **NNUserNgr-transClosure**, utilizado por Vêras como base de comparação para o CD-CARS, é que a vizinhança é calculada de maneira mais ampla, utilizando o método de "proximidade transitiva". O método relaciona aspectos indiretos de itens e usuários, analisando todos usuários e itens em pares de usuário-usuário e item-item, classificando os similares como vizinhos. Ampliando a vizinhança em relação ao algoritmo NNUserNgr (VÉRAS, 2016).

- Algoritmo Domínio Cruzado PreF: O algoritmo de Pré-filtragem definido em (VÉRAS, 2016) recebe como entrada os contextos de companhia, localização e dia da semana para cada avaliação de itens feitas pelos usuários presentes na base de dados utilizada pelo sistema. A recomendação é feita através do agrupamento dos usuários e itens presentes na base de dados em pares. Após o agrupamento é feita a associação dos pares usuários-itens em diversos contextos distintos. O algoritmo então, analisa quais seriam os itens mais relevantes em cada contexto de acordo com as avaliações dos usuários e faz recomendações. Podemos resumir a execução do algoritmo de Pré-filtragem em três passos:
  - 1) Inicialmente as informações contextuais e de avaliação dos itens pertencentes ao domínio alvo são agrupadas em uma matriz multi-dimensional, sendo possível obter as avaliações dos usuários para itens do domínio alvo de acordo com os contextos.
  - 2) As informações do mesmo par elemento-usuário são agregadas em múltiplos contextos, sendo priorizado o contexto da recomendação atual.
  - 3) Aplica-se o algoritmo de domínio cruzado utilizado como base de comparação na matriz, prevendo quais seriam as possíveis avaliações dos itens e retornando a recomendação para os contextos analisados.
- Algoritmo Domínio Cruzado PostF: O algoritmo de Pós-filtragem definido em (VÉRAS, 2016) permite a utilização de várias estratégias em sua implementação. Na implementação no CD-CARS a filtragem é feita de acordo as categorias dos itens do domínio alvo favoritas dos usuários em determinados contextos. Por exemplo, de acordo com análise das avaliações o algoritmo identifica que um usuário tem preferência por filmes de ação no contexto da recomendação atual, ao realizar a recomendação o algoritmo irá priorizar filmes de ação. Podemos resumir a execução do algoritmo de Pós-filtragem em três passos:

- 1) Inicialmente o algoritmo produz uma matriz única unificando matrizes de avaliação de usuários agregando as avaliações para o mesmo par elemento-usuário em diferentes contextos, priorizando a avaliação do usuário com o mesmo contexto da recomendação.
- 2) Aplica-se o algoritmo de domínio cruzado utilizado como base de comparação recebendo como entrada as matrizes de avaliação agregadas.
- 3) As informações contextuais são utilizadas para filtrar as avaliações resultantes do algoritmo CD. A filtragem é concluída considerando itens pertencentes ao conjunto de categorias de gêneros favoritas do usuário (comédia, ação, rock, etc.) de acordo com o contexto do usuário.

Esta seção foi dedicada a definição de conceitos teóricos e os algoritmos utilizados pelo sistema CD-CARS. A próxima seção será dedicada as abordagens *offline* e *online* de avaliação de sistemas de recomendação.

## 2.5 Abordagens Online e Offline de Avaliação de sistemas de recomendação

A seguir veremos os conceitos teóricos das abordagens de avaliação de sistemas de recomendação offline (Seção 2.5.1) e online (Seção 2.5.2).

### 2.5.1 Abordagem Offline de avaliação de sistemas de recomendação

Uma vez que entendemos os algoritmos e técnicas de recomendação que são utilizados no Sistema CD-CARS (**Seção 2.4**), podemos entender quais técnicas que foram utilizadas para treinamento e avaliação dos algoritmos do Sistema CD-CARS.

Cantador (CANTADOR et al., 2015) define algumas dessas técnicas adaptadas para Sistemas de Recomendação como:

**Hold-out** — Esta técnica é utilizada quando os perfis de testes dos algoritmos fazem parte do conjunto de perfis de treinamento dos algoritmos e as avaliações das recomendações são previamente conhecidas, utilizado para avaliar/calibrar a precisão e taxa de acerto entre perfil e recomendações feitas pelo sistema.

**Leave-some-users-out** — Esta técnica é utilizada quando os perfis de teste diferem dos perfis de treinamento, utilizada para avaliar/calibrar o algoritmo em relação a novos usuários cadastrados no sistema.

**Leave-all-users-out** — Esta técnica foca especificamente nos itens e domínios que serão utilizados para recomendações do sistema, serve para avaliar/calibrar os algoritmos responsáveis por classificar novos itens adicionados ao sistema e como associá-los a itens já classificados.



A abordagem Offline consiste em diferentes técnicas de calibragem (treinamento) dos algoritmos de recomendação, utilizando bases de dados de perfis e itens cujo resultado das avaliações das recomendações é previamente conhecido (CANTADOR et al., 2015).

A maioria dos sistemas são avaliados dessa maneira pois há uma praticidade e agilidade maior no processo de treinamento e calibragem dos algoritmos. Utilizar técnicas que pertencem à abordagem offline como **Hold-out**, **Leave-some-users-out**, **Leave-all-users-out**, torna coleta de dados e resultados praticamente instantânea por não se fazer necessária a interação humana (CANTADOR et al., 2015).

### 2.5.2 Abordagem Online de avaliação de sistemas de recomendação

Esta seção será dedicada a trabalhos relevantes em técnicas da abordagem de avaliação focada em usuários de sistema de recomendação (**online**), ao longo da seção vamos analisar sistemas de recomendação que foram avaliados com usuários e ao final da seção será ilustrada uma comparação com os principais trabalhos relacionados desse projeto de pesquisa.

Sendo o grau de satisfação de satisfação do usuário considerada a métrica principal para avaliar a qualidade e eficiência de Sistemas de Recomendação (MCNEE et al., 2002), utilizaremos como base teórica os conceitos definidos por Bart Knijnenburg e Martijn C. Willemsen (B.P.; M.C., 2015).

Tradicionalmente, os pesquisadores da área de sistemas de recomendação avaliam os resultados de seus trabalhos utilizando métricas de precisão e acurácia dos algoritmos propostos. Empresas como a Netflix (BENNETT; LANNING, 2007) organizam eventos com prêmios milionários com o objetivo de melhorar a precisão dos algoritmos utilizados pelo sistema, contudo, cada vez pesquisadores salientam que o objetivo principal de um sistema de recomendação vai muito além da acurácia em previsões, o objetivo principal é aplicado no mundo real, propondo recomendações personalizadas para que o usuário descubra novos itens relevantes, aumentando o seu grau de satisfação com o sistema (B.P.; M.C., 2015).

Autores como (MCNEE et al., 2002) e (TORRES et al., 2004) ratificam o fato de que usuários avaliaram o seu Sistema que possuía os algoritmos com maiores taxas de acerto o menos útil, e se sentiram mais satisfeitos utilizando o Sistema que tinha algoritmos com taxas de acerto menor, Mcnee argumenta que ter precisão não é o bastante, um sistema de recomendação para ser eficiente tem que ser relevante para os usuários (MCNEE et al., 2002). Segundo Knijnenburg e Willemsen a relevância que Mcnee se referiu é uma combinação de aspectos do sistema que agradem ao usuário (B.P.; M.C., 2015).

Abaixo serão definidas as técnicas que fazem parte da abordagem online de avaliação de sistemas de recomendação, propostas por (B.P.; M.C., 2015).

São elas: *Objective System Aspects (OSAs)*, *Subjective System Aspects (SSAs)*, *User Experience (EXP)* e *Interaction (INT)* e com a combinação dessas técnicas podemos fazer uma avaliação completa de um sistema de recomendação

***Objective System Aspects (OSAs)*** — Esta técnica consiste em pedir para os usuários avaliarem objetivamente alguma funcionalidade específica do sistema. Por exemplo, em relação às recomendações feitas pelo sistema, podemos avaliar o grau de satisfação do usuário em relação aos algoritmos de recomendação do sistema ou a frequência com que ele recebe novas recomendações.

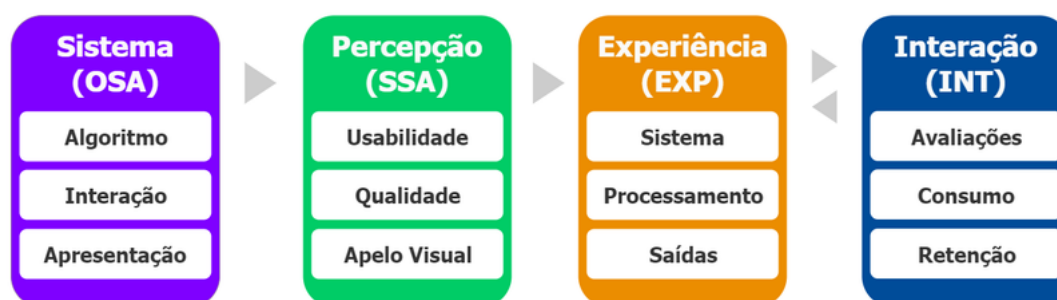
***Subjective System Aspects (SSAs)*** — Esta técnica consiste em pedir que o usuário avalie o sistema de maneira geral. Esta técnica normalmente é validada com questionários e podemos obter informações importantes como satisfação do usuário em relação ao sistema (qualidade, relevância, quantidade e diversidade de recomendações, interface, etc.).

***User Experience (EXP)*** — A técnica consiste em medir o grau de satisfação do usuário em relação à utilização do sistema, levando em consideração os fatores humanos e pessoais dos usuários, por exemplo, se os domínios de recomendações agradaram o usuário, se o usuário concorda com a maneira que o sistema disponibiliza as recomendações, também é validada com questionário.

***Interaction (INT)*** — Esta técnica leva em consideração a interação do usuário com o sistema, por exemplo: forma de fazer as avaliações, medir a retenção avaliando se o usuário continuaria utilizando ou utilizaria uma nova versão ou protótipo do sistema, performance do sistema em relação a execução, consumo de recursos, etc.

A Figura 6 abaixo, descreve o “*framework*” de avaliação de sistemas de recomendações com usuários, proposto em (B.P.; M.C., 2015). Ilustrando como cada técnica da abordagem *online* se relaciona com a outra podendo inclusive formar um fluxo lógico para avaliar um sistema de recomendação da forma mais completa possível, e quais aspectos, particularidade ou característica do sistema que podem ser avaliados pelas técnicas de avaliação como nos exemplos definidos acima.

Figura 6 – Avaliação de sistemas de recomendação com Usuários



Adaptado de: Knijnenburg B.P.; Willemsen M.C., 2015

Nesta seção nos baseamos nos trabalhos de (B.P.; M.C., 2015), (MCNEE et al., 2002) e (TORRES et al., 2004) para definir os conceitos teóricos, demonstrar os principais desafios de conectar sistemas de recomendação e pessoas, frisando a importância de avaliarmos os sistemas de recomendação utilizando a abordagem focada em usuários.

Na próxima seção serão detalhados os trabalhos relacionados a este trabalho.

## 2.6 Trabalhos relacionados

Durante o desenvolvimento do CD-CARS, foram realizadas pesquisas e comparações com trabalhos relacionados na área de sistemas de recomendação, sendo analisados sistemas de recomendações de domínios únicos e domínios cruzados que utilizam técnicas de recomendação de filtragem colaborativa, baseadas em conteúdo e sensíveis a contexto (VÉRAS, 2016).

Como o foco desse projeto de pesquisa é avaliar o CD-CARS utilizando a abordagem de avaliação focada em usuários, portanto, esta seção será organizada em duas partes. A Seção 2.6.1 dedicada a uma análise comparativa entre os aspectos teóricos das abordagens *Online* e *Offline* de avaliação. A Seção 2.6.2 dedicada a apenas a sistemas de recomendação que foram avaliados com a abordagem *online*, a fim de fazer um comparativo com o CD-CARS, em relação as abordagens da avaliação utilizadas.

### 2.6.1 Comparação teórica entre abordagens de avaliação offline e online

Esta seção será dedicada a comparação teórica entre as abordagens online e offline, compilada na pesquisa de (BEEL; LANGER, 2015) e em seguida iremos

comparar o CD-CARS com outros sistemas de recomendação que foram avaliados com a abordagem *online* de avaliação.

Na pesquisa de (BEEL; LANGER, 2015) os autores focam em demonstrar comparativos de performance em diferentes aspectos do sistema na avaliação *online* e *offline* do sistema de recomendações de artigos acadêmicos da biblioteca digital Docear e uma comparação geral entre as duas abordagens.

Durante a pesquisa os autores afirmam que fizeram uma extensa pesquisa sobre as duas abordagens e aplicaram técnicas das duas abordagens de avaliação acreditando que os resultados seriam similares em relação a avaliação do sistema em ambas as abordagens.

No artigo os autores descrevem que a hipótese deles estava errada, concluindo que cada uma das abordagens tem suas particularidades e se relacionam muito melhor de forma complementar do que de forma comparativa.

Os autores também enfatizam que para um sistema como o Docear que tem um foco em artigos acadêmicos e uma aplicação prática para usuários, a avaliação offline por si só não seria suficiente para avaliar o sistema. Os resultados obtidos pela avaliação online ajudaram a melhorar vários aspectos como usabilidade, experiência dos usuários, aprimoramento das técnicas de recomendação baseadas em filtragem colaborativa e conteúdo e outras melhorias do ponto de vista qualitativo que não foram detectadas durante a avaliação com a abordagem offline.

Por outro lado, quando se avalia as métricas de acurácia e calibragem dos algoritmos a abordagem online não teve a mesma eficiência que a abordagem offline, por ser uma abordagem mais subjetiva e validada com questionários, não é simples de obter as métricas de acurácia, concluindo que a avaliação online não poderia ser medida pela taxa de acerto dos algoritmos propostos e sim a satisfação do usuário ao utilizar o sistema.

A seguir iremos analisar trabalhos relacionados que descrevem como foram realizados seus experimentos focados em usuários, completando a segunda parte da seção de trabalhos relacionados.

### 2.6.2 Trabalhos relacionados avaliados com a abordagem online

Nesta Seção serão analisados trabalhos que utilizaram técnicas da abordagem online de avaliação de sistemas de recomendação para avaliar com usuários os sistemas de recomendação propostos. Fazendo um comparativo com a avaliação do sistema CD-CARS com usuários, em nossa pesquisa.

***“Let’s go to the cinema! A movie recommender system for ephemeral groups***

**of users**“ (GUILLERMO FERNÁNDEZ et al., 2014), no artigo é proposto o desenvolvimento de um sistema de recomendação de domínio único e sensível a contexto de usuários(SD-CARS) que consiste em uma ferramenta *mobile* de interação social, onde os usuários são capazes de adicionar grupos sociais para receber recomendações de filmes em cartaz.

O algoritmo desenvolvido leva em consideração os filmes que estão em exibição no cinema e interesses individuais dos usuários que formam o grupo, o objetivo é definir através das informações disponíveis qual seria o filme mais indicado para que todos possam assistir juntos e atinjam o grau máximo de satisfação coletiva.

O teste com usuários foi feito com um protótipo de um cinema fictício com filmes da base de dados em cartaz durante 14 dias um grupo de 6 usuários sendo 4 homens e duas mulheres com idades entre 23 e 35 anos foi selecionado para utilizar o sistema, para evitar o problema de **cold-start** os usuários avaliaram entre 10 e 20 filmes da base de dados em uma escala de 1 até 5, sendo 1 — **“Não iria de jeito nenhum”** e 5 — **“Eu adoraria ir”**.

A partir dos 6 usuários foi gerado uma combinação de 57 grupos distintos, onde o número de integrantes de cada grupo variava de 2 até 6 usuários, os integrantes de cada grupo tinham que avaliar os filmes em cartaz e em seguida o sistema realizava uma recomendação com base nas avaliações.

Os usuários não avaliaram outros aspectos do sistema como usabilidade, interface, performance etc. O questionário focava na avaliação dos aspectos objetivos e subjetivos do sistema OSA (algoritmos) e SSA (recomendações).

**“A web-based pervasive recommendation system for mobile tourist guides”** (GAVALAS; KENTERIS, 2011) e **“A Survey on Mobile Tourism Recommender Systems”** (GAVALAS, 2013) Os autores descrevem o MTRS (**Mobile Tourism Recommender System**), desenvolvido em 2011 e revisado em 2013, a avaliação focada com usuários teve como foco o grau de satisfação e quantidade de recomendações realizadas pelo sistema.

O MTRS, utilizou técnicas de filtragem colaborativa e associação para criar perfis de usuários e fazer recomendações de atrações turísticas da cidade Mytilene, os autores definem o MTRS como um sistema sensível a contexto de usuários, que coleta por inferência as informações de contexto de usuários, com base no histórico de visitas do GPS.

Foram utilizados 5 algoritmos de base comparação e vários testes, 45 usuários participaram da pesquisa, mas não é detalhado como foi feita a distribuição dos questionários e nem o número de perguntas. Os autores também não entram no mérito de domínios, então não é possível inferir se eles consideram o MTRS como um sistema

de domínio único (a nível de sistema) ou domínio cruzado (a nível de itens), visto que cada atração turística da cidade é um item e pode pertencer a domínios distintos (museus, restaurantes, praias, praças, parques, etc).

A conclusão dos experimentos foi que a coleta e análise das informações de contexto dos usuários por inferência na aplicação móvel melhorou o grau de satisfação dos usuários em relação a qualidade das recomendações em comparação ao grau de satisfação dos usuários na plataforma web utilizada como base no experimento. Os usuários avaliaram aspectos objetivos, interação com interface e experiência do usuário OSA (algoritmos) e SSA (qualidade da recomendações) e EXP (comparando a experiência do usuário da plataforma *mobile* com a *web*).

Em (ZHENG et al., 2010) e (ZHENG et al., 2012) os autores abordam técnicas de filtragem colaborativa de recomendação e coleta de contexto através de inferência nos dados de GPS do usuário para prover seus interesses em determinados lugares e atividades.

Segundo os autores, a proposta da aplicação desenvolvida utiliza sistemas de domínios cruzados, onde dois ou mais tipos de interesses distintos são utilizados como parâmetros na recomendação (ex: compras e filmes, alimentação e turismo). O algoritmo cruza os dados dos filtros dos interesses do usuário com sua localização e procura os melhores lugares para indicar de acordo com os resultados obtidos, durante a pesquisa foram realizados testes com 162 usuários na cidade de Beijing entre 2010 e 2012.

Sendo satisfatório os resultados, a aplicação tinha como principal objetivo responder duas possíveis perguntas do usuário a primeira relacionada ao cotidiano de um usuário em sua cidade (4, tradução nossa): “Quero fazer alguma atividade, onde devo ir? ” E a segunda em relação turismo “estou indo para algum lugar, o que devo conhecer? ”.

Os usuários não avaliaram outros aspectos do sistema como usabilidade, interface, performance etc. O questionário focava na avaliação dos aspectos objetivos e subjetivos do sistema OSA( algoritmos) e SSA (recomendações).

Os trabalhos acima mostram sistemas de recomendação que foram avaliados por usuários em aplicações reais, a tabela 1 abaixo mostra um comparativo dos sistemas com o Sistema CD-CARS.

Conforme a tabela acima podemos ver uma comparação geral entre a avaliação *online* do CD-CARS e avaliação com usuários em cada um dos trabalhos.

**Tabela 1 – Comparação da avaliação focada em usuários dos trabalhos relacionados com o CD-CARS.**

Sistemas de recomendação	Comparação abordagens online x offline?	Quantidade de usuários no experimento	Objetivos	Coleta de contexto	Técnica de avaliação com usuários
Este Trabalho	Sim	34	Medir o grau de satisfação do usuários	Explícita, Implícita e Inferência	<b>OSA, SSA, EXP e INT</b>
(GAVALAS, 2013)	Sim	45	Medir o grau de satisfação do usuários	Inferência	<b>OSA, SSA e EXP</b>
(GUILLERMO FERNÁNDEZ et al., 2014)	Não	6	Medir o grau de satisfação do usuários	Explícita	<b>OSA e SSA</b>
(ZHENG et al., 2012)	Não	164	Medir a precisão dos algoritmos	Inferência	<b>OSA e SSA</b>

Em relação à comparação Online e Offline, nossa avaliação e (GAVALAS, 2013) são as únicas que fazem comparações entre os resultados das duas abordagens. Em relação ao objetivo, podemos ver que nossa avaliação, (GAVALAS, 2013) e (GUILLERMO FERNÁNDEZ et al., 2014) tem o mesmo objetivo que é mensurar a qualidade das recomendações feitas pelos sistemas, através do grau de satisfação dos usuários, enquanto (ZHENG et al., 2012) foca apenas nos aspectos mais objetivos, analisando os algoritmos e técnicas de recomendações.

A coleta de contextos, no CD-CARS temos a combinação das 3 técnicas, onde o usuário insere dados de contexto, mas o sistema também consegue fazer inferência de localização e análises implícitas de recomendações, por exemplo, em (GUILLERMO FERNÁNDEZ et al., 2014) o usuário precisa informar a localização os dados dos usuários que formam o grupo, em (GAVALAS, 2013) e (ZHENG et al., 2012) o contexto de localização é obtido por inferência, baseado nos lugares que o usuário visitou e está localizado.

Os aspectos analisados na abordagem online pela nossa pesquisa, OSA (grau de satisfação com as recomendações feitas por cada algoritmo do sistema), SSA (quantidade de recomendações relevantes para cada algoritmo do sistema), EXP (análise da ordem das recomendações feitas pelos algoritmos do sistema) e INT

(retenção do usuário, se o usuário utilizaria uma versão *online* do sistema) como podemos ver na Seção 3.2 o detalhamento do Questionário final de avaliação do CD-CARS com usuários (ver Apêndice A). enquanto (GUILLERMO FERNÁNDEZ et al., 2014) e (ZHENG et al., 2012) focam apenas em OSA e SSA, e (GAVALAS, 2013) foca sua pesquisa em OSA, SSA e EXP.

Podemos concluir que a avaliação de sistema de recomendação focada em usuários abrange sistemas de características diferentes e diversas finalidades, onde cada técnica de avaliação analisa uma característica particular do sistema com usuário e cada autor define qual é a principal métrica para avaliar seu sistema de recomendação.

No Capítulo 3 iremos detalhar toda metodologia de pesquisa desse trabalho, desde a sua concepção até a coleta de dados.



### 3 Metodologia de Pesquisa

Como explicado na Seção 1.2 deste trabalho, a motivação da nossa pesquisa é avaliar o Sistema CD-CARS utilizando as técnicas de abordagem focadas em usuários, dessa forma poderemos avaliar a solução proposta em (VÉRAS, 2016) e aplicá-la em casos de usos reais solucionando problemas de usuários reais.

Este Capítulo será dividido em três seções, são elas, a Seção 3.1 onde iremos definir a metodologia de pesquisa. A Seção 3.2 dedicada aos questionários utilizados em nossa pesquisa, entrevistas presenciais e coleta de dados. A Seção 3.3 contendo as considerações finais deste capítulo.

#### 3.1 Definição da metodologia de pesquisa

O primeiro passo foi definir quais aspectos do sistema seriam avaliados pelos usuários. Por se tratar de um sistema de recomendação de domínio cruzado e sensível a contexto, poderíamos avaliar qualquer aspecto relacionado as técnicas de avaliação online OSA, SSA, INT e EXP. Por exemplo, aspectos como domínios, qualidade ou quantidade de recomendações, retenção dos usuários, etc. definidas na Seção 2.5.

Para esse projeto de pesquisa escolhemos quatro aspectos principais que englobam sub-aspectos do sistema, analisados por cada técnica de avaliação *online* nos contextos de companhia e temporal dos usuários e com domínios livros (domínio fonte) e filmes (domínio alvo), são eles:

- 1) A satisfação dos usuários em relação às recomendações feitas pelos algoritmos do sistema (OSA).
- 2) A quantidade dos filmes considerados como relevantes nas recomendações feitas pelos algoritmos de recomendação do sistema (SSA).
- 3) A concordância do usuário em relação a ordem das recomendações feitas pelos algoritmos de recomendação do sistema (EXP).
- 4) A retenção dos usuários, avaliando a aceitação dos usuários em relação a proposta de um protótipo da versão online do CD-CARS. Onde os usuários opinaram se utilizariam esse sistema, qual seria a plataforma ideal entre web, mobile e/ou aplicação para TV digital/ smart TV (INT).

Utilizamos o grau de satisfação dos usuários como métrica de avaliação, mensurado através de 23 perguntas no Questionário final de avaliação do CD-CARS com

usuários (ver Apêndice A). Respondido por 34 usuários, com idades entre 19 e 53 anos, sendo 6 mulheres e 28 homens, todos residentes em Recife-PE.

Após a análise dos resultados obtidos pelo Questionário final de avaliação do CD-CARS também foram realizadas entrevistas presenciais com 6 dos 34 usuários. O objetivo das entrevistas foi confirmar a veracidade dos dados obtidos no questionário e ouvir a opinião dos usuários em relação ao sistema CD-CARS e os experimentos realizados em nossa pesquisa.

Uma vez que definimos quais os aspectos que iríamos avaliar, quais seriam as métricas utilizadas e formas de validação dos resultados, foi necessário pensar em uma arquitetura capaz de escalar o CD-CARS e disponibilizá-lo para que os usuários pudessem realizar os testes e avaliação do sistema. Para entendermos os desafios desta etapa precisamos entender o processo de implementação do CD-CARS e sua base de dados.

O CD-CARS possui duas bases de dados, chamadas de “**book-television dataset**” e “**book-music dataset**”, extraídas a partir da base de dados utilizada por (LESKOVEC, J.; ADAMIC, L. A.; HUBERMAN, B. A., 2007) em (VÉRAS, 2016).

Sendo a “**book-television dataset**” utilizada na avaliação e calibragem dos algoritmos em domínios relacionados (livros e programas de televisão, podendo ser filmes, desenhos, seriados, etc.) e a base de dados “**book-music dataset**” em domínios menos relacionados (livros e músicas). Foram coletadas apenas as informações de avaliações em relação aos elementos e quais os contextos tempoal de companhia e de localização para essas avaliações. A partir das duas bases com 100% de sobreposição de avaliação dos usuários nos domínios analisados, foram criados outros cenários para testar os algoritmos em diferentes níveis de sobreposição das avaliações, cada base de dados deu origem a 4 cenários (um para cada domínio como sendo o domínio alvo) sendo eles com 10% e 50% de sobreposição (VÉRAS, 2016).

Neste trabalho utilizamos apenas a base de dados “**book-television dataset**” sendo o domínio de livros o domínio fonte e filmes/programas de tv o domínio alvo.

As tabelas 2 e 3 abaixo mostram o cenário de sobreposição em 50% dos usuários na base de dados utilizado como base em nossa pesquisa e os usuários que responderam o questionário “Classificação de itens e contextos”.

**Tabela 2 – “book-television dataset” com 50% de sobreposição e programas de tv como domínio alvo**

Base de dados	Usuários	Itens	Avaliações	Avaliações por usuários	Avaliações por itens
Cross-domain (ambos os domínios)	15341	188402	1011324	65.92	5.37
Livros (SD)	15341	165896	805102	52.48	4.85
Programas de TV (SD)	7671	22506	206222	26.88	9.16
Contexto temporal (ambos os domínios)	15341	188402	1011324	65.92	5.37
Contexto de Localização (cidade) (ambos os domínios)	7405	113049	446297	60.27	3.95
Contexto de companhia (ambos os domínios)	13012	73353	206512	15.87	2.82
Contexto de localização e Companhia (ambos os domínios)	6571	49216	106664	16.24	2.17

D. Vêras, 2016

**Tabela 3 – “book-television dataset” dos usuários da pesquisa**

Base de dados	Usuários	Itens	Avaliações	Avaliações por usuários	Avaliações por itens
Cross-domain (ambos os domínios)	34	20	680	20.00	34.00
Livros (SD)	34	5	170	5.00	34.00
Programas de TV (SD)	34	15	510	15.00	34.00
Contexto temporal (ambos os domínios)	34	20	680	20.00	34.00
Contexto de Localização (cidade) (ambos os domínios)	34	20	680	20.00	34.00
Contexto de companhia (ambos os domínios)	34	20	680	20.00	34.00
Contexto de localização e Companhia (ambos os domínios)	34	20	680	20.00	34.00

Em nossa pesquisa decidimos utilizar o domínio alvo de filmes por ser um domínio mais comum para os usuários. A escolha por um cenário com 50% de sobreposição nas avaliações deu-se por ser um cenário intermediário. Onde podemos evitar um enviesamento dos resultados em um cenário onde 100% dos usuários possuem avaliações em ambos os domínios, como também, evitar um cenário onde poucos usuários possuíssem avaliações em ambos os domínios.

Um cenário de 50% de sobreposição teve um equilíbrio satisfatório, para aplicarmos as técnicas de filtragem colaborativa, e uma amostra de dados suficiente para que os algoritmos de recomendação em domínios cruzados com pré-filtragem e pós-filtragem do CD-CARS pudessem ser aplicados.

A tabela 4 a seguir, ilustra base de dados utilizada nessa pesquisa. A como podemos ver na tabela, a base de dados utilizada originou-se a partir da base de dados utilizada em (VÉRAS, 2016) com a inclusão dos usuários que participaram do nosso projeto de pesquisa.

**Tabela 4 – “book-television dataset” com 50% de sobreposição e programas de tv como domínio alvo com inclusão dos usuários da pesquisa**

Base de dados	Usuários	Itens	Avaliações	Avaliações por usuários	Avaliações por itens
Cross-domain (ambos os domínios)	15375	188402	1011494	65.78	5.37
Livros (SD)	15375	165896	805272	52.37	4.85
Programas de TV (SD)	7705	22506	206732	26.83	9.18
Contexto temporal (ambos os domínios)	15375	188402	1012004	65.82	5.37
Contexto de Localização (cidade) (ambos os domínios)	7439	113049	446997	60.08	3.95
Contexto de companhia (ambos os domínios)	13046	73353	207192	15.88	2.82
Contexto de localização e Companhia (ambos os domínios)	6605	49216	107334	16.25	2.18

Após definida a metodologia da pesquisa, iremos descrever a fase de coleta e análise dos resultados dos questionários dessa pesquisa.

### 3.2 Coleta e análise de dados dos questionários.

Nossa pesquisa foi dividida em três etapas com coleta de dados através de questionários e entrevistas presenciais. A primeira etapa, de coleta de avaliações e contextos, com o “Questionário classificação de itens e contextos”. Na segunda foi realizada a avaliação das recomendações feitas pelo sistema através do “Questionário final de avaliação do CD-CARS com usuários”. Na terceira etapa concluímos nossa coleta de dados fazendo 6 entrevistas presenciais com usuários.

O questionário “Classificação de itens e contextos” teve como o objetivo coletar informações de contexto e avaliações sobre 20 itens da base de dados foi feita de maneira explícita, onde cada usuário avaliou individualmente 15 filmes e 5 livros,

respondendo também qual a cidade em que estão localizados, e qual seria o contexto ideal em relação a dia da semana e companhia para assistir ou ler os filmes e livros presentes no questionário.

A coleta de informações do questionário “Classificação de itens e contextos”, serviu como base dos dados iniciais para podermos executar o sistema CD-CARS.

As Figuras 7 e 8 abaixo mostram exemplos de duas perguntas presentes no questionário “Classificação de itens e contextos”, a Figura 7 ilustra a pergunta sobre a avaliação do usuário em relação ao filme Forrest Gump: O contador de Histórias. Já a Figura 82, ilustra a pergunta sobre o contexto de companhia e temporal que o usuário assistiria ou assistiu a este filme.

**Figura 7 – Avaliação do filme Forest Gump**

9 - Como você avalia o filme "Forrest Gump: O Contador de Histórias" \*



	1	2	3	4	5	
Péssimo	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Excelente

Fonte: Questionário Classificação de elementos e contextos Disponível em: <<https://goo.gl/forms/1tRzgNcyGwdr4yn03>>. Acesso em: 26 fev. 2018.

**Figura 8 – Pergunta de contexto temporal e companhia.**

Selecione apenas UMA opção indicando qual o dia da semana e o seu contexto em relação a companhias no momento de assistir esse filme.

	Sozinho(a)	Casal	Acompanhado(a) de parentes	Acompanhado(a) amigos	Conhecidos e companhias (outros)	Não sei
Segunda-feira	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Terça-feira	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Quarta-feira	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Quinta-feira	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Sexta-feira	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Sábado	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Domingo	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Não sei	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>


Fonte: Questionário Classificação de elementos e contextos Disponível em: <<https://goo.gl/forms/1tRzgNcyGwdr4yn03>>. Acesso em: 26 fev. 2018.

As perguntas foram feitas para se adequar ao formato de entrada do sistema, então, foi desenvolvido um *script* capaz de ler os dados coletados através de questionário, organizando-os em uma planilha. Após a execução do *script* foi possível agrupar os dados no formato de entrada do arquivo utilizado pelo sistema e inserir os novos usuários e suas avaliações no arquivo.

Após inserir todos os usuários na base de dados do sistema, o próximo passo foi decidir quais seriam os cenários de contextos ideais para que o sistema realizasse recomendações, para chegar a essa decisão, analisamos os dados de entrada dos usuários. Como todas as avaliações vieram de Recife, Pernambuco-Brasil, o contexto de localização não foi considerado nessa decisão, pois, não houve variação de valores possíveis.

Em relação ao contexto temporal, os contextos “Desconhecido”, “Sábado” e “Domingo”, foram maioria absoluta, como podemos ver na figura 9 abaixo:

Figura 9 – Gráfico avaliação dos usuários no contexto temporal



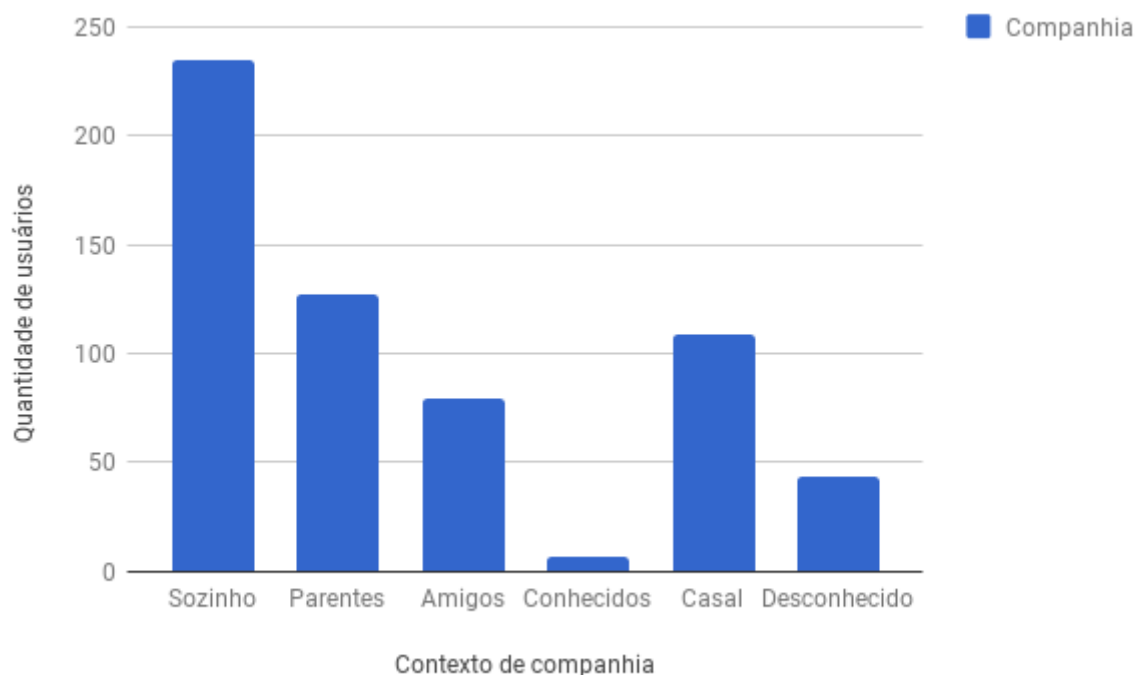
Fonte: O autor.

Portanto, decidimos que o contexto temporal utilizado seria o dia da semana em que o usuário tivesse mais avaliações, para que o sistema faça recomendações baseadas no contexto temporal em que cada usuário assiste ou lê filmes e livros com maior frequência.

Quanto ao contexto de companhia, como podemos ver na figura 10, os dados mostram um equilíbrio maior, sendo “sozinho” o contexto com maior incidência, portanto, utilizamos o mesmo critério do contexto temporal, fazendo recomendações de acordo com o contexto de companhia mais comum para cada usuário.



Figura 10 – Gráfico avaliação dos usuários no contexto companhia




Fonte: O autor.

Após a etapa da coleta e análise dos dados do questionário para definição de entradas e contextos de recomendação do sistema, seguimos para a parte de execução do sistema. Para executar o sistema CD-CARS precisamos informar quais serão os algoritmos de recomendação utilizados, a base de dados, indicar o domínio fonte e as informações de contexto que serão analisados nas recomendações.

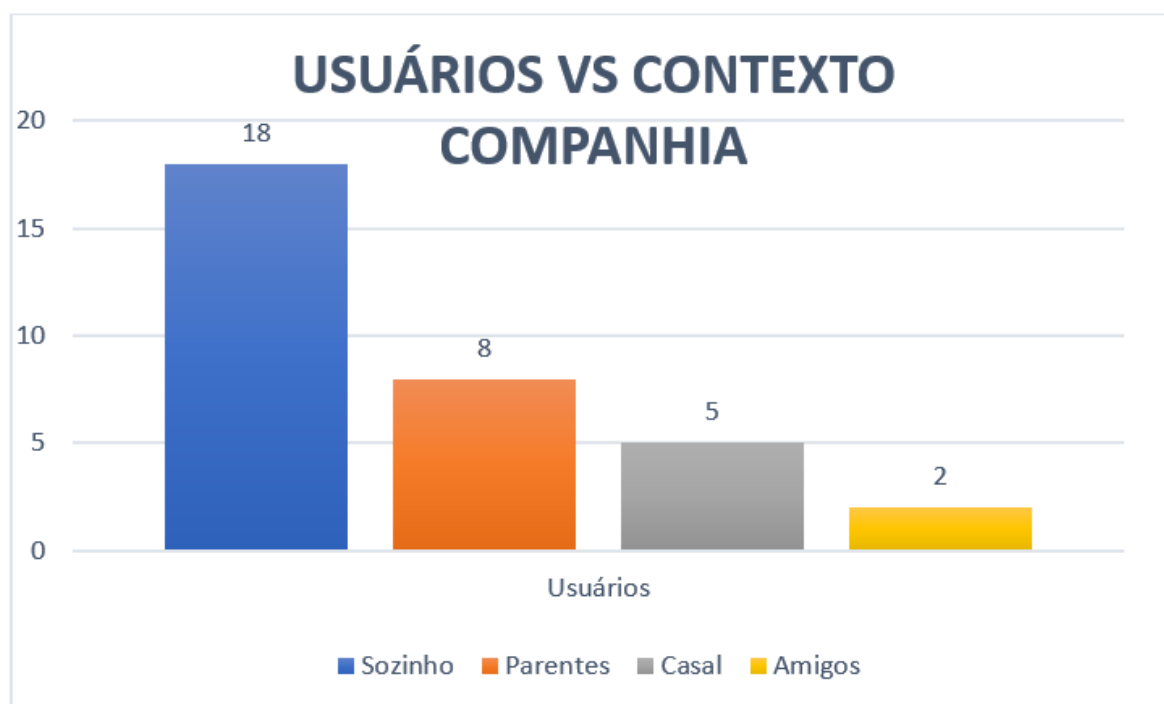
Realizamos todas as execuções do sistema para cada um dos 34 novos usuários inseridos na base de dados do sistema, como podemos ver nos gráficos abaixo, representados pelas Figuras 11 e 12, a distribuição de usuários em relação a contextos temporais e de companhia nas execuções do sistema.

**Figura 11 – Gráfico de distribuição dos usuários em cada contexto temporal utilizado nas recomendações**



Fonte: O autor.

**Figura 12 – Gráfico de distribuição dos usuários em cada contexto de companhia utilizado nas recomendações**



Fonte: O autor.

Dos 34 usuários, a maioria deles tiveram contextos de companhia “Sozinho” e

temporal “Fim de semana”.

Os resultados foram enviados para o e-mail de cada um dos usuários juntamente com o questionário “Questionário final de avaliação do CD-CARS com usuários”, que será detalhado a seguir.

O “Questionário final de avaliação do CD-CARS com usuários” foi respondido pelos mesmo 34 usuários da que participaram de nossa pesquisa. Formado por 23 perguntas e agrupadas em 3 seções, sendo as duas primeiras seções direcionadas para coletar informações sobre os conjuntos de recomendações de acordo com cada contexto analisado e a última seção dedicada as funcionalidades e trabalhos futuros do CD-CARS, como podemos ver na descrição abaixo:

- Seção 1: Teve como objetivo avaliar recomendações no contexto temporal, onde os usuários responderam 9 perguntas para avaliar o seu grau de satisfação em relação às recomendações feitas pelos algoritmos propostos pelo Sistema CD-CARS para o seu contexto de dia da semana.
- Seção 2: Teve como objetivo avaliar recomendações no contexto de companhia, onde os usuários responderam 9 perguntas semelhantes as perguntas da Seção 1, em relação às recomendações feitas pelo algoritmos do sistema para o seu contexto de companhia.
- Seção 3: Organizada em 5 perguntas focadas na opinião dos usuários sobre o interesse em utilizar uma aplicação online do sistema CD-CARS, qual seria a plataforma ideal para utilizar o sistema, quantidade de recomendações que o sistema deveria fazer e quais seriam os domínios recomendados.

Em nosso questionário foi decidido ocultar o nome dos algoritmos para que os usuários não tivessem conhecimento de qual o algoritmo fez a recomendação, essa decisão foi tomada para que a análise de satisfação fosse feita apenas baseada nos filmes recomendados, abstraindo os algoritmos do sistema.

A abstração do nome dos algoritmos se deu pelas letras “A”, “B” e “C” do alfabeto, como podemos ver abaixo:

- ***NNUserNgr-transClosure*** — ***Algoritmo A***
- ***Algoritmo Domínio Cruzado PreF*** — ***Algoritmo B***
- ***Algoritmo Domínio Cruzado PostF*** — ***Algoritmo C***

Após os usuários responderem ao Questionário final de avaliação do CD-CARS com usuários selecionamos 6 dos 34 usuários para realizar entrevistas presenciais.

Durante as entrevistas foram feitas perguntas sobre a satisfação dos usuários em relação às recomendações para verificar a veracidade das repostas do questionário. Também foram feitas perguntas referentes a metodologia de nossa pesquisa, e quais seriam os principais pontos positivos e negativos do sistema CD-CARS.

Esta seção foi dedicada aos questionários de Classificação de itens e contextos, Questionário final de avaliação do CD-CARS com usuários (ver Apêndice A) e as entrevistas presenciais, que foram nossos instrumentos de coleta de dados.

A Seção 3.3 contém as considerações finais desse capítulo, sobre a nossa metodologia de pesquisa.

### 3.3 Considerações finais

Um dos principais desafios desse projeto de pesquisa foi escalar o CD-CARS disponibilizando o sistema para que os usuários pudessem utilizá-lo. Pois, o sistema foi todo planejado em uma arquitetura *desktop*, e sem elementos de interface gráfica. Apesar das dificuldades, conseguimos abstrair as barreiras de implementação através da coleta de dados com os questionários e execução do sistema em uma máquina local, assim foi possível prosseguir com nosso projeto de pesquisa e fazer a avaliação do CD-CARS com a abordagem *online* de avaliação.

O capítulo 4 trará os resultados obtidos no “**Questionário final de avaliação do CD-CARS com usuários**” (ver Apêndice A) e toda a análise de dados para fazermos os comparativos com a avaliação offline e online do sistema CD-CARS.

## 4 Resultados

Neste capítulo serão apresentados os resultados obtidos através da coleta e análise das respostas feitas ao “questionário final de avaliação do CD-CARS com usuários”.

Este capítulo é dividido em duas seções, a Seção 4.1 onde serão detalhados os resultados obtidos com os experimentos da abordagem *online* de avaliação e a Seção 4.2, contendo o comparativo entre os resultados das avaliações *online* e *offline* do CD-CARS.<sup>1</sup>

### 4.1 Resultados da análise de dados

A seguir iremos ilustrar através de gráficos os resultados obtido pelo Questionário final de avaliação do CD-CARS com usuários. Os resultados de cada seção do questionário analisados individualmente.

Para que fosse possível mensurar uma métrica subjetiva como o grau de satisfação dos usuários de uma forma quantitativa, foi necessário adotar uma escala para quantificá-la. A escala que utilizamos variou de 1 até 5, sendo 1 — extremamente insatisfeito e 5 — extremamente satisfeito, assim, adotamos como métricas respostas concedidas pelos usuários para cada algoritmo em relação aos contextos analisados pelas Seções 1 e 2 do questionário.

De acordo com as respostas positivas, neutras ou negativa em cada pergunta do questionário, o grau de satisfação do usuário foi classificado como alto, mediano ou baixo de acordo com a escala de satisfação. Ao final da análise das respostas de cada seção do questionário foi possível fazer um comparativo entre o grau de satisfação de cada algoritmo para o contexto analisado como podemos ver abaixo.


Ao analisarmos as repostas da seção 1, podemos inferir o grau de satisfação dos usuários em relação às recomendações feitas pelos algoritmos A,B e C para o contexto temporal.

As perguntas 1, 2 e 3 do Questionário final de avaliação do CD-CARS com usuários, perguntam objetivamente o quão satisfeito o usuário se sentiu em relação as recomendações dos algoritmos A, B e C respectivamente. Na Figura 13 abaixo, podemos ver a distribuição da quantidade de usuários em relação a satisfação com as recomendações feitas:

---

<sup>1</sup> As respostas do questionário final de avaliação, base de dados utilizada em nossa pesquisa e os resultados das recomendações do CD-CARS para os usuários que participaram da pesquisa podem ser acessados através do link : <http://bit.ly/2oGbTO2>.

**Figura 13 – Grau de satisfação dos usuários em relação às recomendações de contexto temporal feitas pelos algoritmos A,B e C**




Fonte: O autor.

Como podemos ver no gráfico acima, o algoritmo A foi o que atingiu o menor de grau de satisfação em suas recomendações, o algoritmo B foi o que atingiu o maior grau de satisfação, com 9 recomendações que deixaram os usuários extremamente satisfeitos.


Em relação à quantidade de recomendações relevantes e se os usuários concordaram com a ordem das recomendações feitas pelos algoritmos no contexto temporal. O algoritmo B foi melhor avaliado, pois segundo os usuários foi o algoritmo quem mais fez recomendações relevantes e obteve maior concordância na ordem das recomendações. Seguido do algoritmo C e por último o algoritmo A reforçando os dados do gráfico da Figura 13, como podemos ver nas Figuras 14 e 15 abaixo:

**Figura 14 – Quantidade de recomendações relevantes para o contexto temporal dos algoritmos A, B e C**



Fonte: O autor.

**Figura 15 – Concordância com a ordem das recomendações para o contexto temporal dos algoritmos A, B e C**




Fonte: O autor.

Ao analisarmos o resultado da seção 1 do Questionário final de avaliação do CD-CARS com usuários, podemos concluir que o algoritmo que atingiu o maior grau de satisfação dos usuários em relação ao contexto temporal foi o algoritmo B — PreF, seguido do algoritmo C — PostF e o algoritmo A — NNUserNgrbr-transClosure.

A seguir iremos analisar os resultados da seção 2 do questionário, para podermos inferir o grau de satisfação dos usuários em relação às recomendações feitas pelos algoritmos A, B e C para o contexto de companhia.

As perguntas da seção 2 do questionário são as mesmas perguntas presentes na seção 1, abaixo podemos ver o gráfico de satisfação dos usuários no contexto de companhia representado na Figura 16 abaixo:

**Figura 16 – Grau de satisfação dos usuários em relação às recomendações de contexto de companhias feitas pelos algoritmos A, B e C**




Fonte: O autor.

O resultado da avaliação do grau de satisfação no contexto de companhia não foi semelhante ao contexto temporal, onde podemos ver o algoritmo C preF com o maior grau de satisfação, seguido do algoritmo B e o algoritmo A se mantendo como algoritmo de menor grau de satisfação.

As Figuras 17 e 18 abaixo, representam os gráficos de quantidade de recomendações relevantes e concordância com a ordem das recomendações de A, B e C para o contexto de companhia.

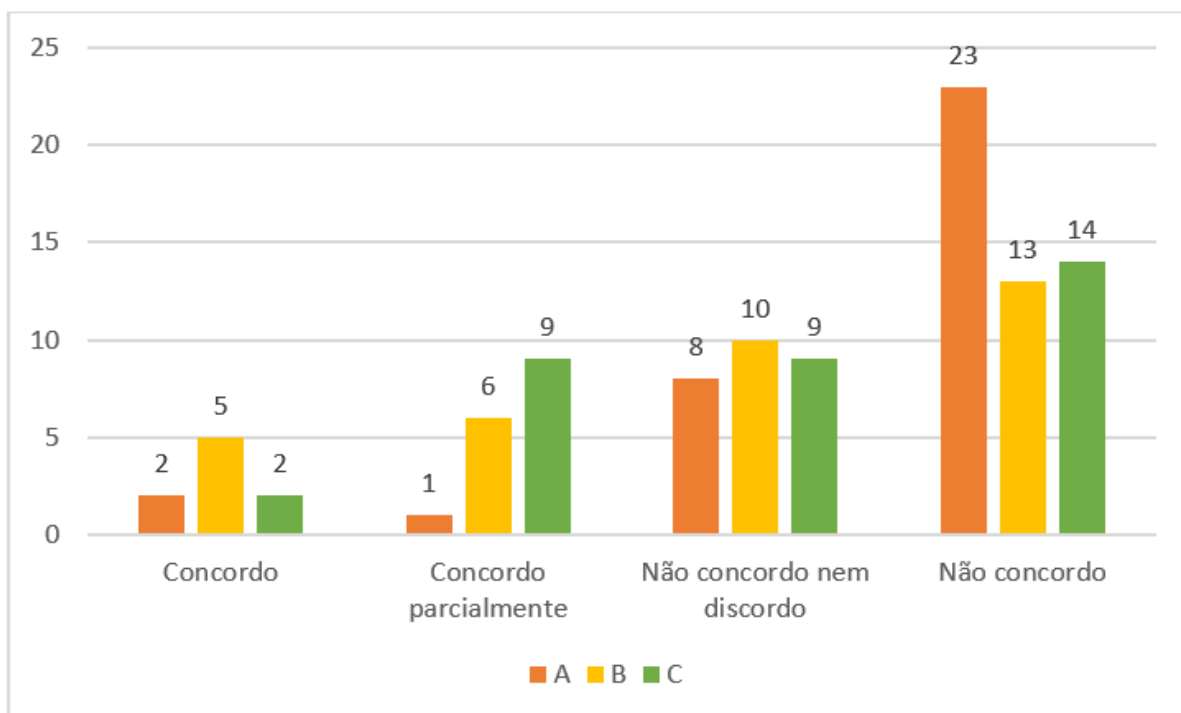


**Figura 17 – Quantidade de recomendações relevantes para o contexto de companhia dos algoritmos A, B e C**



Fonte: O autor.

**Figura 18 – Quantidade de recomendações relevantes para o contexto de companhia dos algoritmos A, B e C**



Fonte: O autor.

Ao compararmos os resultados das seções 1 e 2 do Questionário final de avaliação do CD-CARS com usuários, podemos tirar conclusões das recomendações para contexto temporal foram melhor avaliadas de maneira geral em relação as do con-

texto de companhia, com menos avaliações “insatisfeitos” e “extremamente insatisfeitos” e maior concordância com a ordem das recomendações.

Para o contexto temporal o Algoritmo B — PreF foi com maior grau de satisfação e no contexto de companhia o algoritmo C PosF foi o algoritmo com maior grau de satisfação.

Podemos destacar alguns fatores, o algoritmo A não foi bem avaliado pelos usuários, pois, realizou poucas recomendações relevantes e apresentou as mesmas recomendações independentemente do contexto do usuário, por ser o algoritmo base de comparação era esperado uma performance inferior aos algoritmos de pré e pós-filtragem.

Em algumas recomendações para o contexto de companhia o algoritmo B, fez recomendações já avaliadas pelos usuários no questionário de avaliação, tornando as recomendações repetitivas, esse cenário só foi descoberto na avaliação com usuários. Em um primeiro momento pensamos se tratar de uma falha do sistema, porém, percebemos que ocorria sempre que a recomendação era feita para um contexto distinto ao avaliado pelo usuário.

Como definido anteriormente nas Seções 1.2 e 2.5.2, o grau de satisfação é uma métrica subjetiva, sendo um conjunto de vários fatores que levam o usuário a desenvolver empatia pelo sistema de recomendação, em (BEEL; LANGER, 2015) vimos que a abordagem online e offline se relacionam de forma complementar. Não sendo aconselhável tentar utilizar métricas subjetivas avaliadas pelos usuários, como, por exemplo, o grau de satisfação, para fazer comparações objetivas com os resultados de acurácia obtido dos algoritmos na abordagem offline (BEEL; LANGER, 2015).

A Seção 3 do questionário, foca em coletar a opinião dos usuários em relação a implementação de um sistema online que utilize as técnicas de recomendação do CD-CARS.

Perguntamos aos 34 usuários se eles utilizariam uma versão online do CD-CARS, qual seria a plataforma ideal desse sistema e quais os domínios deveriam ser recomendados, os resultados podem ser vistos nas Figuras 19, 20 e 21 abaixo:

Dos 34 usuários, 24 dos usuários entrevistados (70.58%) afirmaram que utilizariam a versão online do CD-CARS como podemos ver na Figura 19 abaixo.

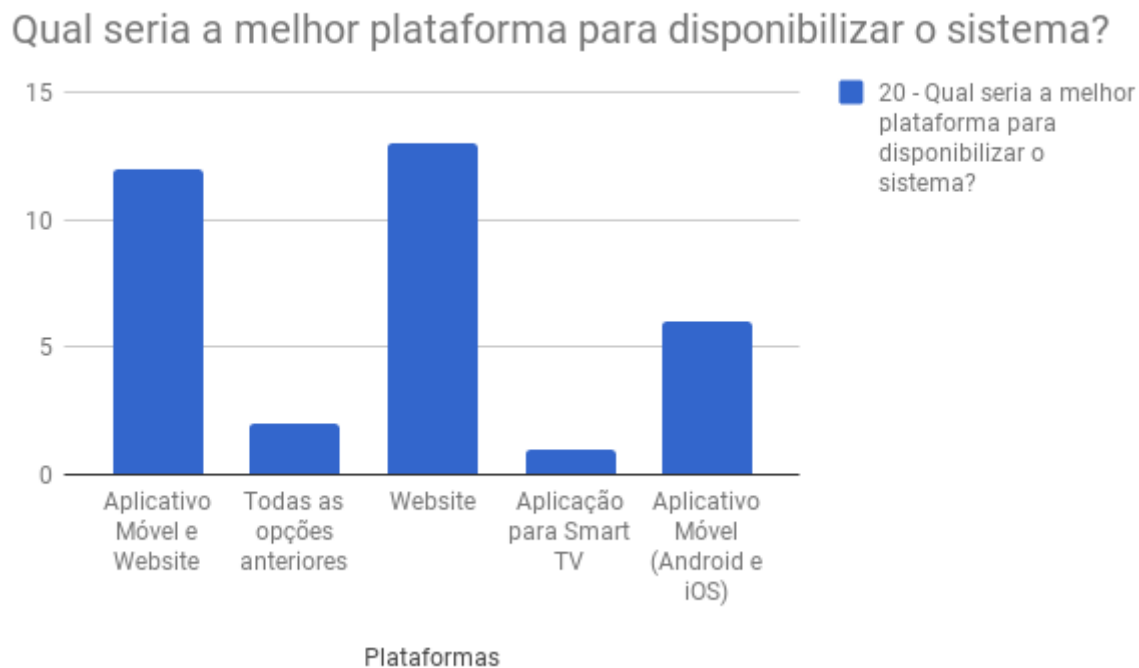
Figura 19 – Gráfico de análise de aceitação do CD-CARS online



Fonte: O autor.

Na Figura 20, podemos perceber que o website foi eleita a melhor plataforma para o sistema online segundo 13 dos 34 usuários entrevistados (38.23%), em segundo lugar a combinação de Website e Aplicativo móvel escolhido por 12 usuários, 6 usuários escolheram apenas aplicativo móvel e apenas um usuário escolheu SmartTV enquanto 2 usuários escolheram todas as plataformas.


Figura 20 – Gráfico de análise de plataforma do CD-CARS online



Fonte: O autor.

Em relação a possíveis domínios, apenas filmes liderou a pesquisa segundo 13 dos 34 usuários entrevistados (38.23%), em segundo lugar filme, livros e músicas com 10 votos, filmes e livros com 9 votos e finalizando outros com apenas 2 votos, como podemos ver na Figura 21.

Figura 21 – Gráfico de análise de domínio do CD-CARS online



Fonte: O autor.

Durante a pesquisa também foi feita uma etapa de entrevistas presenciais, com 6 usuários participantes, para coleta de *opiniões* em relação ao sistema e recomendações.

O objetivo da entrevista presencial com alguns usuários, confirmando a veracidade das respostas do **Questionário final de avaliação do CD-CARS com usuários** (ver Apêndice A) e coletar a opinião dos usuários participantes em relação ao sistema CD-CARS e nossa pesquisa. Pelo fato da maioria das respostas convergirem para o mesmo ponto de vista, abaixo iremos citar algumas respostas e compilar os principais pontos positivos e negativos de acordo com os usuários que participaram da etapa de entrevistas presenciais.

Segundo a Usuária 2, “Diversificar as recomendações de acordo com o dia da semana ou companhia da pessoa é uma funcionalidade muito bacana”.

O Usuário 4 afirmou que : “É muito interessante que o sistema tem a capacidade de relacionar as preferências de livros e filmes para recomendar filmes”.

O usuário 1 disse : “Não me senti muito satisfeito com as recomendações pois não conhecia a maioria dos filmes recomendados pelo sistema”.

A usuária 5 disse : “Gostaria de ter tido contato com o sistema para poder receber mais recomendações em diversos contextos, achei”.

- Pontos positivos do Sistema na visão dos usuários:
  - 1) Relacionar preferências por livros e filmes para fazer recomendações de filmes e a possibilidade de inclusão de outros domínios. Pontos positivos do Sistema na visão dos usuários:
  - 2) Considerar os contextos dos usuários, variando a recomendação de acordo com o dia da semana e companhia.
  
- Pontos negativos do Sistema na visão dos usuários:
  - 1) Muitos filmes antigos e desconhecidos, que não despertaram o interesse dos usuários.
  - 2) Recomendações repetitivas, principalmente nos algoritmos A (para ambos os contextos) e B para cenários específicos de companhia.
  - 3) Ausência de interface, os usuários alegaram que não conseguiram criar empatia pelo sistema CD-CARS, por não ter uma interface para interagir e customizar as recomendações com facilidade.

Como podemos ver nos resultados da seção 3, o desenvolvimento de um sistema “*web*” com as técnicas de recomendações do CD-CARS foi bem aceito, indicando que 70.58% dos usuários teriam interesse em utilizá-lo.

Com o objetivo de solucionar os pontos negativos apontados pelos usuários, iremos desenvolver o protótipo da versão online do CD-CARS, o CD-CARS Web. Um sistema projetado em uma arquitetura *web*, utilizando *web-services* e uma estrutura de dados mais robusta com conteúdos mais atuais para que os usuários possam ter uma melhor experiência e interagir com o sistema.

O protótipo proposto (ver Apêndice A) irá solucionar os problemas de escalabilidade do sistema, com uma infra-estrutura e arquitetura adequadas o sistema poderá suportar o cadastro de novos usuários e recomendações simultâneas.

Com o sistema CD-CARS Web será possível aumentar a base de dados já existente no sistema CD-CARS, incluindo novos usuários, domínios, itens e contextos de recomendações. O incremento da base de dados possibilitará uma melhor associação entre perfis de usuários, domínios e conteúdos dos itens recomendados pelo sistema, através técnicas de recomendação de filtragem colaborativa, baseadas em conteúdo e sensíveis a contextos já utilizadas no CD-CARS, pois, teremos uma base de comparação muito maior para ser analisada.

O desenvolvimento do protótipo também possibilita avaliar os aspectos de usabilidade, interface e experiência de usuário do sistema. Além de reforçar e manter em constante evolução os resultados obtidos por esse trabalho, medindo o grau de satisfação dos usuários em relação aos aspectos de qualidade das recomendações e outros aspectos do sistema que foram analisados em nosso trabalho de pesquisa.

Na próxima seção será feita a comparação em relação aos resultados obtidos na avaliação do CD-CARS utilizando a abordagem offline.

#### 4.2 Comparação avaliação *Online* x *Offline* do CD-CARS

Tomando como base as pesquisas de (MCNEE et al., 2002), (TORRES et al., 2004) (B.P.; M.C., 2015) e (BEEL; LANGER, 2015) o objetivo dessa pesquisa é avaliar o grau de satisfação dos usuários em relação às recomendações feitas pelo sistema CD-CARS e fazer um comparativo de forma complementar com os resultados da avaliação offline do sistema.

Na seção anterior foi feita a análise dos resultados obtidos através de nossa pesquisa com usuários e aferimos o grau de satisfação dos usuários em relação a cada algoritmo de recomendação proposto pelo sistema aplicados a contextos distintos de companhia e dia da semana.

Para conseguirmos fazer uma comparação dos resultados obtidos na avaliação do CD-CARS nas abordagens *offline* e *online*, temos que entender quais os pontos fortes e fracos de cada abordagem de avaliação. Sendo a abordagem *offline* mais adequada para treinamento e acurácia dos algoritmos, e a abordagem *online* em aspectos sensíveis aos usuários.

Na tabela abaixo podemos ver os resultados obtidos durante a calibragem do CD-CARS em sua avaliação *offline* utilizando a métrica **MAE** (*Mean Average Error*), com a base de dados “book-television dataset” em um cenário de 50% de sobreposição de avaliações de elementos, domínio alvo Filmes para os contextos temporal e de companhia, os mesmos utilizados em nossa pesquisa.

**Tabela 5 – Avaliação CD-CARS offline MAE com 50% de sobreposição e contexto temporal e companhia em relação ao algoritmo base de comparação NUserNgrtransClosure**

Dimensão contextual	Domínio alvo	Nível de sobreposição de usuários	Algoritmo PreF	Algoritmo PostF
---------------------	--------------	-----------------------------------	----------------	-----------------

Dimensão contextual	Domínio alvo	Nível de sobreposição de usuários	Algoritmo PreF	Algoritmo PostF
Temporal	Filmes	50%	48.4%	18%
Companhia	Filmes	50%	-207.9%	8.2%

Analisando os dados da Tabela 5, podemos notar que utilizando a métrica de avaliação **MAE** no cenário de contexto temporal, o algoritmo PreF teve a maior taxa de acerto, sendo quase 50% mais preciso do que o algoritmo base de comparação, o algoritmo PostF foi o segundo mais preciso com uma performance quase 20% melhor do que o algoritmo base comparação.

Quando olhamos para o contexto de companhia, o cenário muda drasticamente, o PreF que foi o mais assertivo no contexto temporal, é o algoritmo menos eficiente para o contexto de companhia, sendo o PostF o algoritmo com melhor performance.

Quando comparamos os algoritmos PostF e NNUserNgrbrtransClosure, notamos um cenário muito mais equilibrado, com uma pequena vantagem para o PostF.

Na Seção anterior, foram mostrados que para o contexto temporal o algoritmo com maior grau de satisfação foi o PreF e para o contexto de companhia o algoritmo com maior grau de satisfação foi o PostF.

Os algoritmos que tiveram a maior taxa de acerto em cada contexto foram os algoritmos escolhidos pelos usuários com maior grau de satisfação, e para o contexto temporal os resultados foram exatamente os mesmos, enquanto que para o contexto de companhia o PreF teve uma performance inferior em relação à acurácia, porém, foi o algoritmo que ficou em segundo lugar em relação ao grau de satisfação dos usuários, como podemos ver abaixo:

**Tabela 6 – Comparação resultados das avaliações offline (MAE) x online do CD-CARS.**

Contexto temporal avaliação offline	Contexto temporal avaliação online	Contexto de companhia avaliação offline	Contexto de companhia avaliação online
--	---------------------------------------	---	--



Contexto temporal avaliação offline	Contexto temporal avaliação online	Contexto de companhia avaliação offline	Contexto de companhia avaliação online
1 — PreF	1 — PreF	1 — PostF	1 — PostF
2 — PostF	2 — PostF	2 — NNUser	2 — PreF
3 — NNUser	3 — NNUser	3 — PreF	3 — NNUser

Mesmo obtendo resultados semelhantes para o contexto temporal e distintos para o contexto de companhia, conseguimos entender que através das duas avaliações percebemos através dos dados obtidos que existe uma relação entre as variáveis onde o algoritmo com maior assertividade também foi o melhor avaliado pelos usuários. Porém, como vimos nos trabalhos de (BURKE, 2002) e (TORRES et al., 2004) nem sempre isso acontece.

Como dito na seção anterior, as abordagens *online* e *offline* devem ser utilizadas de forma complementar, pois, uma aborda os aspectos objetivos do sistema como a precisão dos algoritmos e a outra os aspectos subjetivos que correspondem aos usuários do sistema. Não fazendo sentido, por exemplo, quereremos utilizar os resultados da nossa pesquisa para invalidar ou refutar os resultados obtidos através dos testes sem usuários mesmo que os resultados fossem completamente distintos.

Ao invés disso podemos, trazer aspectos únicos de cada abordagem. Por exemplo, mensuração da acurácia dos algoritmos, cenários de treinamentos das técnicas e algoritmos de recomendação, avaliação de base de dados da abordagem *offline* com os aspectos subjetivos de usabilidade, experiência do usuário, interação com o sistema, mensuração da qualidade das recomendações em cenários não controlados com resultados previamente conhecidos, entre outros, para evoluirmos cada vez mais o Sistema CD-CARS, com técnicas de recomendação mais precisas e melhor usabilidade do sistema.

No Capítulo 5 serão feitas as conclusões e considerações finais e na Seção 5.1 serão descritos os trabalhos futuros desta pesquisa.

## 5 Conclusão

O objetivo principal do trabalho foi avaliar os algoritmos de recomendação propostos no sistema CD-CARS utilizando a abordagem *online* de avaliação de sistemas de recomendação.

Foram realizados experimentos com participação de 34 usuários, através de questionários e entrevistas presenciais cumprindo com o objetivo principal de nosso trabalho.

Os resultados obtidos através de nossa pesquisa convergem com os resultados da avaliação *offline* do sistema CD-CARS com a métrica **MAE**. Uma vez que os algoritmos que tiveram as maiores taxas de acerto, nos mesmos cenários analisados neste trabalho também foram escolhidos pelos usuários como os algoritmos com as recomendações mais satisfatórias.

Os resultados obtidos também se assemelham com os resultados e conclusões dos trabalhos relacionados a esta pesquisa, corroborando a importância de avaliar os sistemas de recomendação com as duas abordagens, mergindo os aspectos objetivos da avaliação *offline* com os aspectos humanos da avaliação *online*, resultando em sistemas de recomendações mais completos e eficientes.

Os resultados obtidos em nosso trabalho se limitam apenas ao cenário de 50% de sobreposição de avaliações, contextos temporal e de companhia com recomendações de filmes. Na etapa de análise e comparação dos resultados, foi feita a comparação com apenas uma métrica de avaliação da abordagem *offline* a **MAE**.

### 5.1 Trabalhos futuros

Propomos como trabalhos futuros desta pesquisa a comparação dos resultados obtidos, com os resultados da avaliação *offline* do CD-CARS com as métricas RMSE (**Root-mean-square Error**) e F-1, levando em consideração todos os cenários de sobreposição de avaliações dos itens utilizados na avaliação *offline* do CD-CARS.

Utilizar o protótipo para adicionar novos itens nos domínios de livros, filmes e músicas já existentes na base de dados do Sistema, adicionar novos domínios (jogos, lugares, seriados, etc.) e analisar outros contextos como (horário, previsão do tempo, etc.).

Fazer uma nova avaliação com usuários, mais completa, analisando aspectos de usabilidade e interação do sistema.

## Referências

- ADOMAVICIUS, G.; TUZHILIN, A. Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *Knowledge and Data Engineering, IEEE Transactions on. IEEE*, v. 17, n. 6, p. 734 – 749, 2005.
- ADOMAVICIUS, G.; TUZHILIN, A. Context-aware recommender systems. In: *Recommender systems handbook (Second Edition)*. [S.l.]: Springer. p. 191 – 226, 2015.
- BAZIRE, M.; BRÉZILLON, P. Understanding context before using it. In: *Modeling and using context*. [S.l.]: Springer, p. 29 – 40, 2005.
- BEEL, J.; LANGER, S. A Comparison of Offline Evaluations, Online Evaluations, and User Studies in the Context of Research-Paper Recommender Systems. In: Kapidakis S., Mazurek C., Werla M. (eds) *Research and Advanced Technology for Digital Libraries. Lecture Notes in Computer Science*, Springer, Cham., v. 9316, p. 153 – 168, 2015.
- BENNETT, J.; LANNING, S. The netflix prize. In: *Proceedings of KDD cup and workshop*. [S.l.: s.n.], v. 2007, p. 35 – 36, 2007.
- B.P., K.; M.C., W. Evaluating Recommender Systems with User Experiments. In: Ricci F., Rokach L., Shapira B. (eds) *Recommender Systems Handbook*. Springer, Boston, MA). 2015.
- BURKE, R. Hybrid recommender systems: Survey and experiments. *User modeling and user-adapted interaction, Springer*, v. 12, n. 4, p. 331 – 370, 2002.
- CANTADOR, I. et al. Cross-domain recommender systems. In: *Recommender Systems Handbook*. [S.l.]: Springer. p. 919 – 959, 2015.
- CAO, B.; LIU, N. N.; YANG, Q. Transfer learning for collective link prediction in multiple heterogenous domains. [S.l.: s.n.]. *Proceedings of the 27th International Conference on Machine Learning (ICML-10)*, p. 159 – 166, 2010.
- COLOMBO-MENDOZA, L. O. et al. Recommetz: A context-aware knowledge-based mobile recommender system for movie showtimes. *Expert Systems with Applications*, Elsevier, v. 42, n. 3. p. 1202 – 1222, 2015.
- CREMONESI, P.; TRIPODI, A.; TURRIN, R. Cross-domain recommender systems. In: *IEEE 11th International Conference on Data Mining Workshops (ICDMW)*. p. 496 – 503, 2011.
- DAS, A. S. et al. Google news personalization: scalable online collaborative filtering. In: *ACM. Proceedings of the 16th international conference on World Wide Web*. [S.l.], p. 271 – 280, 2007.
- ENRICH, M.; BRAUNHOFER, M.; RICCI, F. Cold-start management with cross-domain collaborative filtering and tags. In: *E-Commerce and Web Technologies*. [S.l.]: Springer. p. 101 – 112, 2013.

FERNÁNDEZ-TOBÍAS et al. Cross-domain Recommender Systems: A Survey of the State of the Art. *Spanish Conference on Information Retrieval*, v. 2nd, p. 187 – 198, 2012.

GAVALAS, D.; KENTERIS, M. A web-based pervasive recommendation system for mobile tourist guides. *Personal and Ubiquitous Computing*, v. 15, n. 7, p. p. 759 – 770, 2011.

GAVALAS, D. et al. A survey on mobile tourism recommender systems. In: *Communications and Information Technology (ICCIT), Third International Conference on. IEEE*, p. 131 – 135, 2013.

GOLDMANN, M.; KREITZ, G. Measurements on the Spotify Peer-Assisted Music-on-Demand Streaming System. In: *IEEE International Conference on Peer-to-Peer Computing (P2P)*, 2011.

GROSSMAN, L. How computers know what we want before we do. 2010.

GUILLERMO FERNÁNDEZ et al. Let's go to the cinema! A movie recommender system for ephemeral groups of users. In: *Computing Conference (CLEI), 2014 XL Latin American. IEEE*, p. 1 – 12, 2014.

HARPER, F. M.; KONSTAN, J. A. The movielens datasets: History and context. *ACM Transactions on Interactive Intelligent Systems (TiiS)*, v. 5, n. 4, p. 19 –, 2016.

HIDASI, B.; TIKK, D. Fast als-based tensor factorization for context-aware recommendation from implicit feedback. In: *Machine Learning and Knowledge Discovery in Databases. [S.l.]: Springer*, p. 67 – 82, 2012.

KOREN, Y.; BELL, R. Advances in collaborative filtering. *Recommender systems handbook. Springer US*, p. 77 – 118, 2015.

LEE, H.; KWON, J. Personalized tv contents recommender system using collaborative context tagging-based user's preference prediction technique. *International Journal of Multimedia & Ubiquitous Engineering*, v. 9, n. 5. p. 231 – 240, 2014.

LESKOVEC, J.; ADAMIC, L. A.; HUBERMAN, B. A. The dynamics of viral marketing. *ACM Transactions on the Web (TWEB), ACM*, v. 1, n. 1, p. 5 – 5, 2007.

LINDEN, G.; SMITH, B.; YORK, J. Amazon.com recommendations: Item-to-item collaborative filtering. *Internet Computing, IEEE, IEEE*, v. 7, n. 1, p. 76 – 80, 2003.

LONI, B. et al. Cross-domain collaborative filtering with factorization machines. In: *Advances in Information Retrieval. [S.l.]: Springer*. p. 656 – 661, 2014.

MCNEE, S. et al. On the recommending of citations for research papers. In: *Proceedings of the 2002 ACM conference on Computer supported cooperative work*, pp. 116–125. New Orleans, LA (2002). DOI 10.1145/587078.587096. 2002.

NAKATSUJI, M. et al. Recommendations Over Domain Specific User Graphs. *European Conference on Artificial Intelligence*, v. 19th, p. 607 – 612, 2010.

- OH, S. et al. Comparison of techniques for time aware tv channel recommendation. In: IEEE. Soft Computing and Intelligent Systems (SCIS), 2014 Joint 7th International Conference on and Advanced Intelligent Systems (ISIS), 15th International Symposium on. [S.l.]. p. 989 – 992, 2014.
- OKU, K. et al. Context-aware svm for context-dependent information recommendation. In: IEEE COMPUTER SOCIETY. *Proceedings of the 7th international Conference on Mobile Data Management*. [S.l.], p. 109 – 109, 2006.
- PAN, W.; XIANG, E. W.; YANG, Q. Transfer learning in collaborative filtering with uncertain ratings. In: AAAI. [S.l.: s.n.]. 2012.
- PANNIELLO, U. et al. Experimental comparison of pre-vs. post-filtering approaches in context-aware recommender systems. In: ACM. *Proceedings of the third ACM conference on Recommender systems*. [S.l.], p. 265 – 268, 2009.
- PHAM, X. H.; JUNG, J. J.; VU, S. P. L. A. Exploiting social contexts for movie recommendation. *Malaysian Journal of Computer Science*, v. 27, n. 1, p. 68 – 79, 2014.
- RESNICK, P. et al. GroupLens: An open architecture for collaborative filtering of Netnews. *Proceedings of the Conference on Computer Supported Cooperative Work*. ACM., n. 464, p. 175 – 186, 1994.
- RICCI, F.; ROKACH, L.; SHAPIRA, B. Introduction to Recommender Systems Handbook, *Recommender Systems Handbook*, Springer,. p. 1 – 35, 2015.
- RUOTSALOB, T. et al. SMARTMUSEUM: A mobile recommender system for the Web of Data. *Web semantics: Science, services and agents on the world wide web*, v. 20, p. 50 – 67, 2013.
- SAHEBI, S.; BRUSILOVSKY, P. Cross-Domain Collaborative Recommendation in a Cold-Start Context: The Impact of User Profile Size on the Quality of Recommendation. *21st International Conference on User Modeling, Adaptation, and Personalization*, p. 289 – 295, 2013.
- SHANI, G.; GUNAWARDANA, A. Evaluating Recommendation Systems. In: Ricci F., Rokach L., Shapira B., Kantor P. (eds) *Recommender Systems Handbook*. Springer, Boston, MA. p. 257 – 297, 2011.
- SHAPIRA, B.; ROKACH, L.; FREILIKHMAN, S. Facebook Single and Cross Domain Data for Recommendation Systems. *User Modeling and User-Adapted Interaction*. n. 23(2–3), p. 211 – 247, 2013.
- SHEPSTONE, S.; TAN, Z.; JENSEN, S. Using audio-derived affective offset to enhance tv recommendation. *Multimedia, IEEE Transactions*, v. 16, n. 7, p. 1999 – 2010, Nov 2014. ISSN 1520-9210.
- TIROSHI, A. et al. Cross Social Networks Interests Predictions Based on Graph Features. *7th ACM Conference on Recommender Systems*, p. 319 – 322, 2013.
- TORRES, R. et al. Enhancing digital libraries with TechLens. In: *Proceedings of the 2004 joint ACM/IEEE conference on Digital libraries - JCDL '04*, pp. 228–236. Tuscon, AZ, USA (2004). DOI 10.1145/996350.996402. 2004.

TUNG, H.; SOO, V. A personalized restaurant recommender agent for mobile e-service. *In: e-Technology, e-Commerce and e-Service, 2004. EEE'04. 2004 IEEE International Conference on. IEEE*, p. 259 – 261, 2004.

VÉRAS, D. CD-CARS: CROSS-DOMAIN CONTEXT-AWARE RECOMMENDER SYSTEMS. *Tese (Doutorado em Ciência da Computação) - Centro de Informática. Universidade Federal de Pernambuco*, 2016.

VÉRAS, D. et al. A literature review of recommender systems in the television domain. *Expert Systems with Applications, Elsevier*, v. 42, n. 22, p. 9046 – 9076, 2015.

VÉRAS, D. et al. Context-aware techniques for cross-domain recommender systems. *In: IEEE. 2015 Brazilian Conference on Intelligent Systems (BRACIS). [S.l.]*, p. 282 – 287, 2015.

WANG, C. et al. Content-Based Top-N Recommendations With Perceived Similarity. 2017.

WINOTO, P.; TANG, T. If You Like the Devil Wears Prada the Book, Will You also Enjoy the Devil Wears Prada the Movie? A Study of Cross-Domain Recommendations. *New Generation Computing*, v. 26, p. 209 – 225, 2008.

YANG, W.; HWANG, S. iTravel: A recommender system in mobile peer-to-peer environment. 2013.

ZHENG, V. W. et al. Collaborative Filtering Meets Mobile Recommendation: A User-Centered Approach. *In: AAAI*, p. 236 – 241, 2010.

ZHENG, V. W. et al. Towards mobile intelligence: Learning from GPS history data for collaborative recommendation. *Artificial Intelligence*, v. 184, p. 17 – 37, 2012.

## Apêndices

## APÊNDICE A – Questionário final de avaliação do CD-CARS com usuários

Abaixo podemos ver as **Figuras 22, 23, 24, 25, 26, 27, 28 e 29** que representam as perguntas da Seção 2 do Questionário final de avaliação do CD-CARS com usuários referentes à avaliação das recomendações para o contexto temporal :

**Figura 22 – Seção 1 - Questionário final de avaliação do CD-CARS com usuários**

# Questionário final de avaliação do CD-CARS com usuários.

\* Required

## 1 - Avaliação dos algoritmos de recomendação em relação ao contexto temporal

Esta seção será dedicada a perguntas para avaliar o seu grau de satisfação em relação às recomendações feitas pelos algoritmos de recomendação no cenário de contexto temporal, onde as recomendações foram feitas de acordo com o seu perfil e um contexto de dia da semana informado no e-mail junto com o resultado da recomendação.

1 - Em relação às recomendações feitas pelo algoritmo A, você se considera: \*

	1	2	3	4	5	
Extremamente insatisfeito	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Extremamente satisfeito

Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EsWsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.



**Figura 23 – Seção 1 - Questionário final de avaliação do CD-CARS com usuários**

2 - Em relação as recomendações feitas pelo algoritmo B, você se considera: \*

	1	2	3	4	5	
Extremamente insatisfeito	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Extremamente satisfeito

3- Em relação as recomendações feitas pelo algoritmo C, você se considera: \*

	1	2	3	4	5	
Extremamente insatisfeito	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Extremamente satisfeito

Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EswsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.

**Figura 24 – Seção 1 - Questionário final de avaliação do CD-CARS com usuários**

4 - Levando em consideração todas as recomendações feitas feitas pelo algoritmo A, quantas você considerou como relevantes? \*

- Todas as recomendações
- 4 recomendações
- 3 recomendações
- 2 recomendações
- 1 recomendação
- Nenhuma recomendação

Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EswsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.

**Figura 25 – Seção 1 - Questionário final de avaliação do CD-CARS com usuários**

5 - Levando em consideração todas as recomendações feitas feitas pelo algoritmo B, quantas você considerou como relevantes? \*

- Todas as recomendações
- 4 recomendações
- 3 recomendações
- 2 recomendações
- 1 recomendação
- Nenhuma recomendação

Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EswsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.

**Figura 26 – Seção 1 - Questionário final de avaliação do CD-CARS com usuários**

6 - Levando em consideração todas as recomendações feitas feitas pelo algoritmo C, quantas você considerou como relevantes? \*

- Todas as recomendações
- 4 recomendações
- 3 recomendações
- 2 recomendações
- 1 recomendação
- Nenhuma recomendação

Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EswsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.

**Figura 27 – Seção 1 - Questionário final de avaliação do CD-CARS com usuários**

7 - Você concorda com a ordem dos filmes recomendados pelo algoritmo A? Considerando que os filmes estão organizados em ordem decrescente de relevância para o seu perfil.

- Concordo
- Concordo parcialmente
- Não concordo nem discordo
- Não concordo

Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EswsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.

**Figura 28 – Seção 1 - Questionário final de avaliação do CD-CARS com usuários**

8 - Você concorda a com ordem dos filmes recomendados pelo algoritmo B? Considerando que os filmes estão organizados em ordem decrescente de relevância para o seu perfil.

- Concordo
- Concordo parcialmente
- Não concordo nem discordo
- Não concordo

Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EswsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.

**Figura 29 – Seção 1 - Questionário final de avaliação do CD-CARS com usuários**

9 - Você concorda com a ordem dos filmes recomendados pelo algoritmo C? Considerando que os filmes estão organizados em ordem decrescente de relevância para o seu perfil.

- Concordo
- Concordo parcialmente
- Não concordo nem discordo
- Não concordo

Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EswsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.

Abaixo podemos ver as **Figuras 30, 31, 32, 33, 34, 35, 36 e 37** que representam as perguntas da Seção 2 do Questionário final de avaliação do CD-CARS com usuários referentes à avaliação das recomendações para o contexto de companhia :

Figura 30 – Seção 2 - Questionário final de avaliação do CD-CARS com usuários

## Questionário final de avaliação do CD-CARS com usuários.

\* Required

### 2 - Avaliação dos algoritmos de recomendação em relação ao contexto de companhia

Esta seção será dedicada a perguntas para avaliar o seu grau de satisfação em relação às recomendações feitas pelos algoritmos de recomendação no cenário de contexto de companhia, onde as recomendações foram feitas de acordo com o seu perfil e um contexto de companhia informado no e-mail junto com o resultado da recomendação.

10 - Em relação às recomendações feitas pelo algoritmo A, você se considera: \*

	1	2	3	4	5	
Extremamente insatisfeito	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Extremamente satisfeito

Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EswsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.

**Figura 31 – Seção 2 - Questionário final de avaliação do CD-CARS com usuários**

11 - Em relação as recomendações feitas pelo algoritmo B, você se considera: \*

	1	2	3	4	5	
Extremamente insatisfeito	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Extremamente satisfeito

12 - Em relação as recomendações feitas pelo algoritmo C, você se considera: \*

	1	2	3	4	5	
Extremamente insatisfeito	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Extremamente satisfeito

Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EswsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.

**Figura 32 – Seção 2 - Questionário final de avaliação do CD-CARS com usuários**

13 - Levando em consideração todas as recomendações feitas feitas pelo algoritmo A, quantas você considerou como relevantes? \*

- Todas as recomendações
- 4 recomendações
- 3 recomendações
- 2 recomendações
- 1 recomendação
- Nenhuma recomendação

Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EswsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.

**Figura 33 – Seção 2 - Questionário final de avaliação do CD-CARS com usuários**

14 - Levando em consideração todas as recomendações feitas feitas pelo algoritmo B, quantas você considerou como relevantes? \*

- Todas as recomendações
- 4 recomendações
- 3 recomendações
- 2 recomendações
- 1 recomendação
- Nenhuma recomendação

Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EswsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.

**Figura 34 – Seção 2 - Questionário final de avaliação do CD-CARS com usuários**

15 - Levando em consideração todas as recomendações feitas feitas pelo algoritmo C, quantas você considerou como relevantes? \*

- Todas as recomendações
- 4 recomendações
- 3 recomendações
- 2 recomendações
- 1 recomendação
- Nenhuma recomendação

Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EswsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.

**Figura 35 – Seção 2 - Questionário final de avaliação do CD-CARS com usuários**

16 - Você concorda com a ordem dos filmes recomendados pelo algoritmo A? Considerando que os filmes estão organizados em ordem decrescente de relevância para o seu perfil.

- Concordo
- Concordo parcialmente
- Não concordo nem discordo
- Não concordo

Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EswsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.

**Figura 36 – Seção 2 - Questionário final de avaliação do CD-CARS com usuários**

17 - Você concorda com a ordem dos filmes recomendados pelo algoritmo B? Considerando que os filmes estão organizados em ordem decrescente de relevância para o seu perfil.

- Concordo
- Concordo parcialmente
- Não concordo nem discordo
- Não concordo

Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EswsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.



**Figura 37 – Seção 2 - Questionário final de avaliação do CD-CARS com usuários**

18 - Você concorda com a ordem dos filmes recomendados pelo algoritmo C? Considerando que os filmes estão organizados em ordem decrescente de relevância para o seu perfil.

- Concordo
- Concordo parcialmente
- Não concordo nem discordo
- Não concordo

Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EswsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.

Abaixo podemos ver as **Figuras 38, 39, 40, 41** que representam as perguntas da Seção 3 do Questionário final de avaliação do CD-CARS com usuários referentes à avaliação das recomendações para o contexto de companhia :

Figura 38 – Seção 3 - Questionário final de avaliação do CD-CARS com usuários

## Questionário final de avaliação do CD-CARS com usuários.

\* Required

### Trabalhos futuros

Nesta seção serão feitas perguntas relevantes para o desenvolvimento da versão online do sistema CD-CARS.

19 - Você utilizaria uma versão Online do CD-CARS? \*

- Sim
- Não

Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EswsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.

Figura 39 – Seção 3 - Questionário final de avaliação do CD-CARS com usuários

20 - Qual seria a melhor plataforma para disponibilizar o sistema? \*

- Aplicativo Móvel (Android e iOS)
- Website
- Aplicativo Móvel e Website
- Aplicação para Smart TV
- Todas as opções anteriores

Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EswsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.

**Figura 40 – Seção 3 - Questionário final de avaliação do CD-CARS com usuários**

21 - Na sua opinião, qual seria o número ideal de recomendações para cada execução do sistema? \*

- Mais de 20 recomendações
- Entre 16 e 20 recomendações
- Entre 11 e 15 recomendações
- Entre 6 e 10 recomendações
- Até 5 recomendações

Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EswsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.

**Figura 41 – Seção 3 - Questionário final de avaliação do CD-CARS com usuários**

22 - Na sua opinião, quais seriam as categorias relevantes de recomendações feitas pelo sistema? \*

Apenas Filmes

Apenas Livros

Filmes e Livros

Filmes, Livros e Músicas

Outras

Other: \_\_\_\_\_

23 - Caso tenha respondido a Opção E) Outras na pergunta anterior, por favor deixe sua sugestão abaixo:

Your answer  
\_\_\_\_\_


Fonte: Questionário final de avaliação do CD-CARS com usuários Disponível em: <<https://goo.gl/forms/EswsvUQLP9vLXGGw2>>. Acesso em: 26 fev. 2018.

## APÊNDICE B – Protótipo CD-CARS WEB

As Figuras abaixo representam as telas do protótipo do CD-CARS WEB.

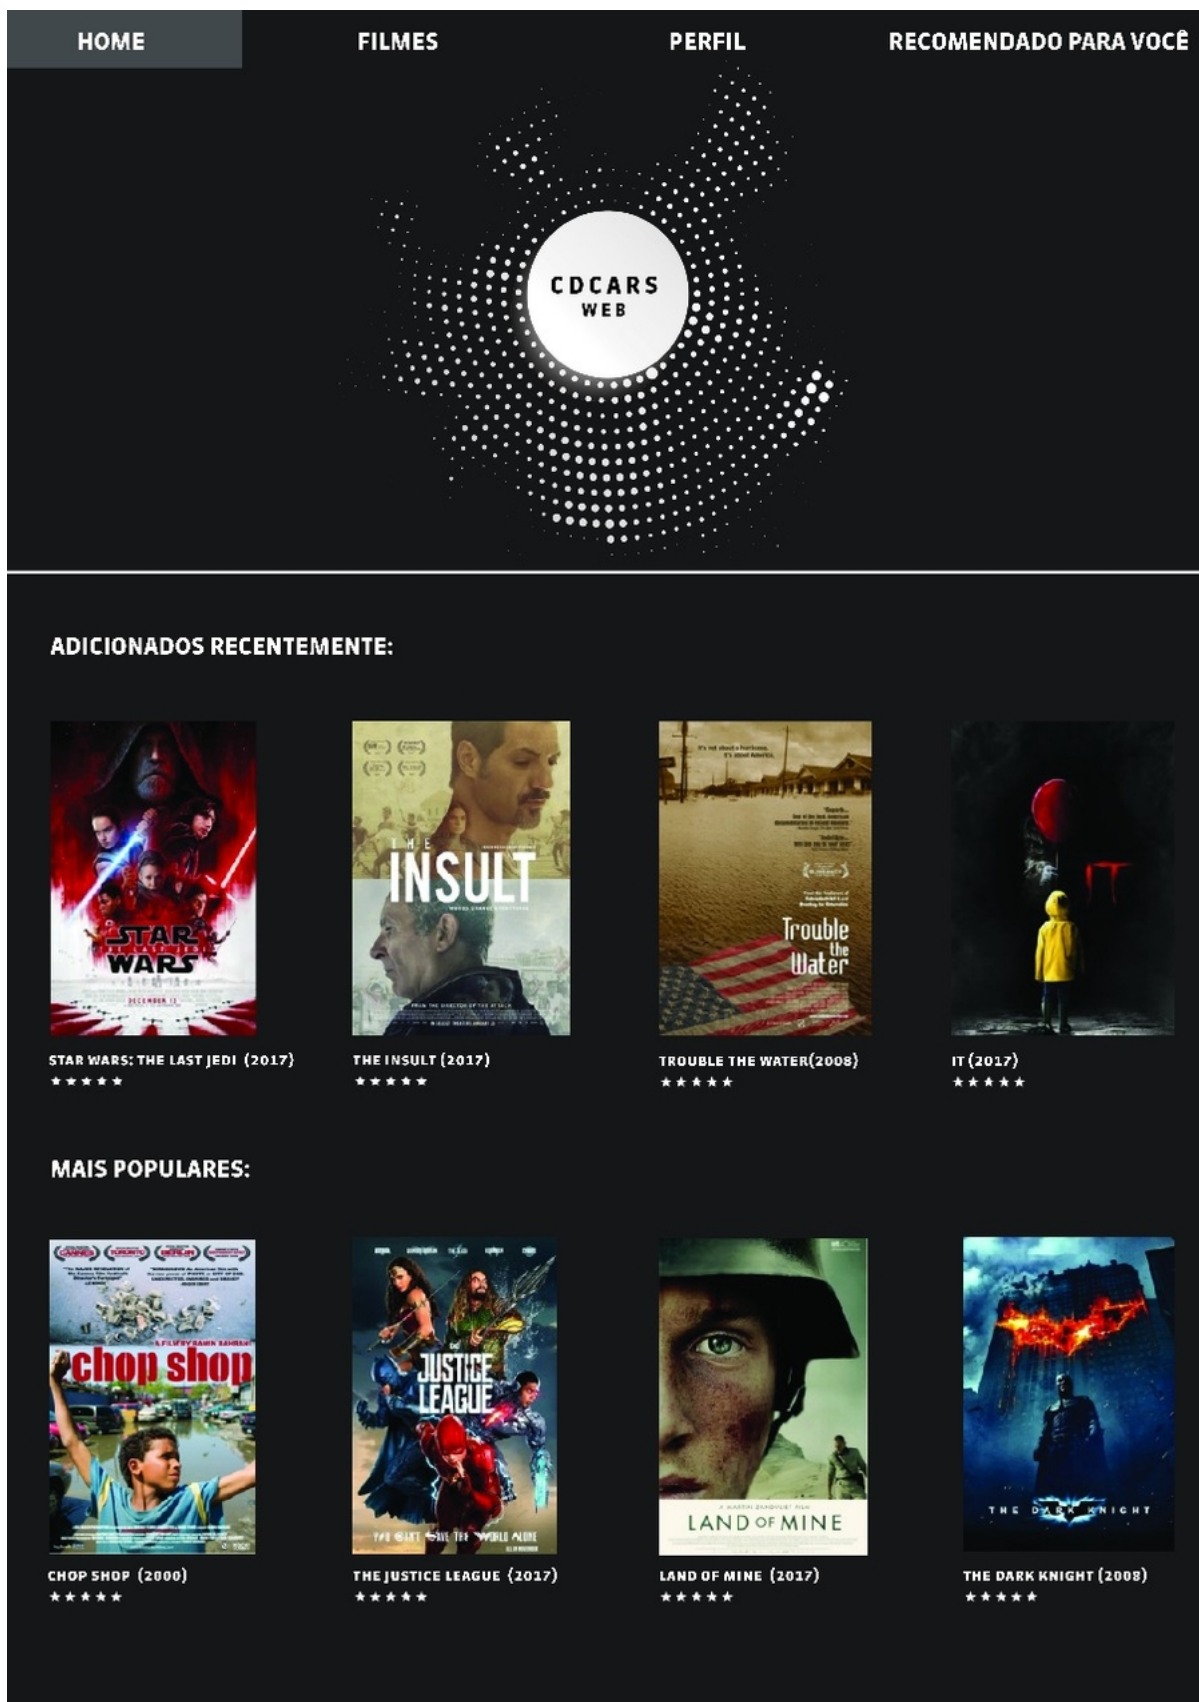
A Figura 38 representa a tela de login do CD-CARS Web, onde o usuário acessa o sistema. A Figura 39 mostra a tela inicial do sistema onde o usuário pode conferir os itens adicionados recentemente e mais populares do site, ao clicar em cada filme ou na aba perfil o usuário pode fazer avaliações dos filmes. A Figura 40 representa a tela de filmes recomendados, onde o usuário pode ver quais são as recomendações do sistema de acordo com o contexto selecionados no perfil.

**Figura 42 – CD-CARS WEB Login.**




Fonte: O autor.

Figura 43 – CD-CARS WEB página inicial.



Fonte: O autor.

Figura 44 – CD-CARS Web filmes recomendados.



Fonte: O autor.