



Carlos Olimpio Rodrigues de Melo Filho

**Análise de um sistema de recomendação de
restaurantes sensível ao contexto sobre o grau
de satisfação dos usuários**

Recife

2023

Carlos Olimpio Rodrigues de Melo Filho

**Análise de um sistema de recomendação de restaurantes
sensível ao contexto sobre o grau de satisfação dos
usuários**

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

Universidade Federal Rural de Pernambuco – UFRPE

Departamento de Computação

Curso de Bacharelado em Ciências da Computação

Orientador: Douglas Vêras e Silva

Recife

2023

Dados Internacionais de Catalogação na Publicação
Universidade Federal Rural de Pernambuco
Sistema Integrado de Bibliotecas
Gerada automaticamente, mediante os dados fornecidos pelo(a) autor(a)

- F481a Filho, Carlos Olimpio Rodrigues de Melo
Análise de um sistema de recomendação de restaurantes sensível ao contexto sobre o grau de satisfação dos usuários / Carlos Olimpio Rodrigues de Melo Filho. - 2023.
70 f. : il.
- Orientador: Douglas Veras e Silva.
Inclui referências e apêndice(s).
- Trabalho de Conclusão de Curso (Graduação) - Universidade Federal Rural de Pernambuco,
Bacharelado em Ciência da Computação, Recife, 2023.
1. Sistema de recomendação. 2. Pós-filtragem baseada em contexto. 3. Sistema de recomendação sensível ao contexto. 4. Abordagem online de avaliação. I. Silva, Douglas Veras e, orient. II. Título



**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 Carlos Olimpio Rodrigues de Melo Filho às 10h do dia 01 de setembro de 2023, no link <https://meet.google.com/wvz-thjw-iwm>, como requisito para conclusão do curso de Bacharelado em Ciência da Computação da Universidade Federal Rural de Pernambuco, intitulado “Análise de um sistema de recomendação de restaurantes sensível ao contexto sobre o grau de satisfação dos usuários”, orientado por Douglas Vêras e aprovado pela seguinte banca examinadora:

Douglas Vêras
DC/UFRPE

Luciano Pacífico
DC/UFRPE

Aos meus pais, avós e irmãos, por serem a base de tudo.

Agradecimentos

Agradeço a todo corpo de professores do Departamento de Computação da Universidade Federal Rural de Pernambuco, pelos ensinamentos e contribuição para minha formação.

Agradeço ao meu orientador Douglas Vêras, pela paciência, ensinamentos e motivação para realizar este trabalho.

Agradeço à secretária do curso de Bacharelado em Ciência da Computação, Sandra Xavier, por todo suporte, boa vontade e simpatia durante os anos da graduação.

Agradeço à minha futura esposa Célia Carvalho, pela paciência, insistência e nunca duvidar de mim.

Agradeço a todos funcionários que compõem o Restaurante Universitário da UFRPE, pelas ótimas refeições.

Agradeço a todos os amigos e colegas que fiz no decorrer da graduação da UFRPE. Em especial, agradecimentos a André Lucas, César Muniz e Cícero Pereira pelas disciplinas cursadas juntos, trabalhos em grupo e horas de estudo juntos.

*“Then as it was, then again it will be
And though the course may change sometimes
Rivers always reach the sea”
(Ten Years Gone - Led Zeppelin)*

Resumo

Aplicações populares de sistemas de recomendação podem ser encontradas em diversas áreas. No ramo de alimentação, plataformas como o TripAdvisor se destacam por sugerir recomendações de restaurantes especializadas baseadas em vários tipos de informações relevantes como avaliações de outros usuários para o cardápio, ambiente e recomendações de restaurantes mais próximos são algumas das especialidades dessas plataformas. Com a possibilidade de utilização de novos dados sensíveis ao contexto do usuário, este trabalho tem como principal objetivo avaliar o uso do motivo de ida ao restaurante para reorganizar a recomendação final de restaurantes através de uma pós-filtragem baseada em contexto. Para concretizar o objetivo foi desenvolvida uma aplicação móvel, o *SR Recife Restaurants*, onde para avaliar o grau de satisfação de usuários reais em relação aos restaurantes recomendados, uma abordagem de avaliação *online*, utilizando questionários, foi utilizada. Ao realizar o experimento com 15 usuários foi possível notar um aumento de 26,67% no grau de satisfação das top-5 primeiras recomendações ao utilizar o tipo de ida ao restaurante como dado de contexto para a fase de pós-filtragem.

Palavras-chave: Sistema de recomendação, Pós-filtragem baseada em contexto, Sistema de recomendação sensível ao contexto, Abordagem online de avaliação.

Abstract

Popular applications of recommender systems can be found in many areas. In the food business, platforms such as TripAdvisor stand out for suggesting specialized restaurant recommendations based on various types of relevant information, such as reviews from other users for the menu, atmosphere and recommendations for the closest restaurants are some of the specialties of these platforms. With the possibility of using new data sensitive to the user's context, the main objective of this work is to evaluate the usage of the reason of going to the restaurant to reorganize the final restaurants recommendation through a context-based post-filtering. To achieve the goal, a mobile application was developed, the *SR Recife Restaurants*, to assess the degree of satisfaction of real users to the recommended restaurants, an *online* evaluation approach, using questionnaires, was used. When carrying out the experiment with 15 users, it was possible to notice an increase of 26.67% in the degree of satisfaction of the top-5 first recommendations when using the trip type to the restaurant as context data for the post-filtering phase.

Keywords: Recommender system, Contextual post-filtering, context aware recommender system, online evaluation.

Lista de ilustrações

Figura 1 – Paradigmas para Incorporação de Contexto Adaptado de (NAWARA et al., 2021)	20
Figura 2 – Avaliação de Sistemas de Recomendação com Usuários Adaptado de (MONTEIRO, 2017)	22
Figura 3 – Fluxo principal do novo funcionamento do algoritmo de recomendação	39
Figura 4 – Telas da aplicação <i>SR Recife Restaurants</i>	41
Figura 5 – Fluxo principal de execução do aplicativo <i>SR Recife Restaurants</i> . .	42
Figura 6 – Gênero dos participantes do experimento	45
Figura 7 – Grau de satisfação dos usuários	46
Figura 8 – Opinião sobre a quantidade total de recomendações	47
Figura 9 – Grau de satisfação sobre a qualidade das recomendações	47
Figura 10 – Aspectos para escolha do restaurante recomendado	48
Figura 11 – Grau de dificuldade ao interagir com o sistema	48
Figura 12 – Grau de confiança em relação às recomendações feitas pelo sistema	49
Figura 13 – Contagem dos motivos da ida selecionados durante o experimento .	50
Figura 14 – Telas da aplicação <i>SR Recife Restaurants</i> (parte 1)	62
Figura 15 – Telas da aplicação <i>SR Recife Restaurants</i> (parte 2)	63
Figura 16 – Cabeçalho do questionário de avaliação	64
Figura 17 – Perguntas para avaliar o grau de satisfação do usuário (parte 1) . .	65
Figura 18 – Perguntas para avaliar o grau de satisfação do usuário (parte 2) . .	65
Figura 19 – Perguntas para avaliar o grau de satisfação do usuário (parte 3) . .	66
Figura 20 – Perguntas para avaliar o grau de satisfação do usuário (parte 4) . .	67
Figura 21 – Perguntas para avaliar o grau de satisfação do usuário (parte 5) . .	68
Figura 22 – Perguntas para avaliar o grau de satisfação do usuário (parte 6) . .	69

Lista de tabelas

Tabela 1 – Tabela de resumo dos trabalhos relacionados (parte 1)	30
Tabela 2 – Tabela de resumo dos trabalhos relacionados (parte 2)	31
Tabela 3 – Tipos de cozinha presentes no dados extraídos da plataforma TripAdvisor	33
Tabela 4 – Tipos de cozinha por quantidade de restaurantes	34
Tabela 5 – Exemplo do total de avaliações para cada motivo da ida a um restaurante	36
Tabela 6 – Porcentagem dos usuários que clicaram nas top-5 recomendações	49

Lista de abreviaturas e siglas

CARS	Context-Aware Recommender System
N/A	Not available (Não disponível)
API	Application Programming Interface (Interface de Programação de Aplicação)
CA	Context Aware
CB	Content Based
CF	Collaborative Filtering
ML	Machine Learning (Aprendizagem de Máquina)
RMSE	Root Mean Squared Error
MAE	Mean Absolute Error
nDCG	normalized Discounted Cumulative Gain
RNN	Recurrent Neural Network (Redes Neurais Recorrentes)
AUC	Area Under the ROC Curve
HUIMCCF	Hybrid User-Item based Multi-Criteria Collaborative Filtering (Filtragem de conteúdo que utiliza multi-critérios baseada em itens de usuário)
GA-ANN	Genetic Algorithm Artificial Neural Network (Rede Neural Artificial com Algoritmo Genético)
OSA	Objective System Aspects
SSA	Subjetive system aspects
EXP	User experience
INT	Interaction
PC	Personal Characteristics
SC	Situational Characteristics
GPS	Global Positioning System

Sumário

	Lista de ilustrações	7
1	INTRODUÇÃO	12
1.1	Justificativa	13
1.2	Problema	14
1.3	Objetivos	14
1.3.1	Geral	14
1.3.2	Específicos	14
1.4	Contribuições	15
1.5	Estrutura do trabalho	15
2	FUNDAMENTAÇÃO TEÓRICA	16
2.1	Sistemas de Recomendação	16
2.1.1	Paradigmas de Recomendação	17
2.1.2	Sistemas de Recomendação Sensível ao Contexto	18
2.1.2.1	Métodos para obtenção de Contexto	18
2.1.2.2	Paradigmas para Incorporação de Contexto	19
2.2	Técnicas de Avaliação em Sistemas de Recomendação	19
2.2.1	Avaliação <i>offline</i>	19
2.2.2	Avaliação <i>online</i>	21
2.2.2.1	Fatores para Avaliação de Satisfação de Usuários	21
3	TRABALHOS RELACIONADOS	24
3.1	Método de Avaliação <i>offline</i>	24
3.2	Método de Avaliação <i>online</i>	28
3.3	Tabela de Resumos dos Trabalhos	29
4	METODOLOGIA	32
4.1	Conjunto de Dados	32
4.2	Modelo de Preferências do Usuário	33
4.2.1	Características dos Restaurantes	33
4.2.2	Características dos Usuários	34
4.2.3	Contexto dos usuários	35
4.3	Algoritmo de Recomendação de Restaurantes	35
4.3.1	Similaridade Entre Usuário e Restaurantes	36
4.3.2	Distância Entre Usuário e Restaurantes	36

4.3.3	Algoritmo de Recomendação de Restaurantes	37
4.3.4	Reorganização da Recomendação Baseada no <i>motivo da ida</i>	38
4.4	Experimento	38
4.4.1	Descrição do Aplicativo <i>SR Recife Restaurants</i>	40
4.4.2	Descrição da Execução dos Testes	41
4.4.3	Coleta e Análise das Avaliações dos Questionários	43
5	RESULTADOS	45
5.1	Avaliação dos Dados do Questionário	45
5.2	Discussão	51
5.3	Considerações Finais	52
6	CONCLUSÃO	53
6.1	Limitações	53
6.2	Trabalhos Futuros	53
	REFERÊNCIAS	55
	 APÊNDICES	 59
	APÊNDICE A – EXEMPLO DOS DADOS COLETADOS DA PLATAFORMA TRIPADVISOR	60
	APÊNDICE B – TELAS DA APLICAÇÃO MÓVEL <i>SR RECIFE RESTAURANTS</i>	62
	APÊNDICE C – QUESTIONÁRIO UTILIZADO PARA COLETAR AVALIAÇÕES DOS USUÁRIOS	64

1 Introdução

A utilização de sistemas de recomendação vem se tornando cada vez mais presente e corriqueira no dia-a-dia das pessoas. Com a grande quantidade de informação disponível na internet, tomar decisões mais precisas torna-se cada vez mais difícil (AF-SAR et al., 2022). Diante disso, um fator importante a ser levado em consideração é a qualidade da recomendação que está sendo feita, ou seja, o quão satisfeito o usuário estará ao usar o sistema (KNIJNENBURG et al., 2015). Muitas pessoas gostam de receber sugestões baseadas em experiências anteriores e que possuam um certo grau de confiança nelas, geralmente no “boca a boca” as pessoas tendem a confiar mais no que o outro indivíduo está sugerindo (BLACK et al., 2023).

Aplicações populares de sistemas de recomendação podem ser encontradas em diversas áreas. Serviços de *streaming* de vídeo como Amazon Prime Video¹, Netflix² e GloboPlay³ são bons exemplos que oferecem aos seus assinantes um conteúdo exclusivo de filmes e seriados baseados no conteúdo que está sendo consumido pelo usuário durante sua jornada no aplicativo. A Netflix, por exemplo, cria competições com premiações milionárias para desenvolvimento de sistemas de recomendação com melhor performance (PENG, 2022). Outros tipos de serviço que utilizam esses tipos de aplicação que podem ser citados são plataformas de *e-commerce*, *sites* que permitem procura de emprego, locação de carros e apartamentos, *streaming* de música, lojas de jogos *online* e recomendação de ativos no mercado financeiro (LU et al., 2015).

No ramo de restaurantes também há uma procura por recomendações especializadas (ZENG et al., 2016). Dado que as pessoas procuram restaurantes com boas avaliações, *sites* como o Google Maps⁴ e TripAdvisor⁵ se destacam por oferecer vários tipos de informações relevantes como avaliações de outros usuários tanto para o cardápio, quanto para o ambiente e recomendações de restaurantes mais próximos, com acesso ao mapa, são algumas das especialidades dessas plataformas. Há também a procura por avaliações especializadas em blogs culinários que acabam por entrar em detalhes mais específicos em relação ao menu servido, atendimento e detalhes sobre a refeição (SALEHAN et al., 2017).

Quando um cliente decide escolher um restaurante para realizar uma refeição, muitas vezes, ele está usando um *smartphone* ou algum dispositivo móvel (ANDER-

1 <<https://www.primevideo.com/>>

2 <<https://www.netflix.com/br/>>

3 <<https://globoplay.globo.com/>>

4 <<https://www.google.com.br/maps/preview>>

5 <<https://www.tripadvisor.com/>>

SON, 2018). Aplicações móveis famosas como iFood⁶ e Rappi⁷ oferecem sugestões de *delivery* baseadas nas últimas compras do usuário, bem como no horário e categorias de comida. Assim como mencionado anteriormente, plataformas como TripAdvisor e Google Maps oferecem aplicações móveis que podem ser utilizadas para consulta de avaliações, localização e menu de restaurantes físicos na palma da mão do cliente.

Dados mencionados anteriormente como localização e categorias de comida preferidos, por exemplo, constituem os chamados dados sensíveis ao contexto do usuário (VERAS et al., 2019), pois estão relacionados ao contexto em que o usuário está ao receber a recomendação. Sendo assim, levando em consideração os sistemas de recomendação de restaurantes, surge a possibilidade de melhorar as opções de recomendação para os usuários utilizando seus dados sensíveis ao contexto em que está inserido (VILLEGAS et al., 2018). Tal dado pode ser aplicado em algum momento no algoritmo de recomendação para que a experiência de receber novas recomendações seja aprimorada, e com isso o grau de satisfação do usuário também seja aumentado, baseado nesse novo tipo de dado informado.

1.1 Justificativa

Dentre os sistemas de recomendação sensíveis ao contexto do usuário voltados para recomendação de restaurantes, o trabalho proposto em (ZENG et al., 2016) foi realizado com propósito de averiguar e melhorar a experiência do indivíduo no ambiente móvel. A aplicação aborda técnicas de identificação de características de usuários acerca das preferências em relação ao tipo de cozinha e características de restaurantes para sugerir as recomendações.

Uma característica importante utilizada em (ZENG et al., 2016) são os tipos de dados de contexto. A localização do indivíduo, bem como o tipo de cozinha são dados específicos que variam a cada interação dele com o sistema tendo grande impacto na recomendação. Outra característica é que o sistema apresentado no trabalho foi construído para ser utilizado por usuários reais, ou seja, considerando o método de avaliação *online* de avaliação de sistemas de recomendação.

Diante disso, diversos fatores podem ser considerados para a medição do grau de avaliação do sistema de acordo com os usuários (KNIJNENBURG et al., 2015). Além do mais, outros dados, como o motivo da ida ao restaurante, clima, horário, entre outros, também são importantes na avaliação e cálculo da recomendação (VERAS et al., 2019) (VILLEGAS et al., 2018).

Sendo assim, será realizado um estudo que visa investigar e aprimorar as re-

⁶ <<https://www.ifood.com.br/inicio>>

⁷ <<https://www.rappi.com.br/>>

comendações de restaurantes no ambiente móvel, levando em consideração um novo dado sensível ao contexto do usuário (motivo da ida) no momento da recomendação e adicionando um novo paradigma de incorporação de contexto (pós-filtragem baseada no contexto) na solução apresentada em (ZENG et al., 2016).

1.2 Problema

Acerca da satisfação dos usuários de sistemas de recomendação, existe uma discussão se sistemas focados em garantir uma maior acurácia são melhores em relação aos que focam na experiência do usuário mesmo não tendo a melhor acurácia de predição (DACREMA et al., 2019).

Outro fator a ser levado em consideração é o contexto em que o usuário do sistema está inserido no momento em que é realizada a recomendação (ZHENG, 2018). Dados coletados de sensores em dispositivos móveis ajudam o sistema a gerar sugestões personalizadas, em diferentes situações, para o usuário (NAWARA et al., 2021).

Considerando os fatos mencionados, o objetivo de sistemas de recomendação que utilizam o método de avaliação *online* levam em consideração informações como o ciclo de vida do usuário na aplicação, por exemplo, para mapear o grau de satisfação ao interagir com o sistema se tornam um desafio para o campo de pesquisa em sistemas de recomendação (KONSTAN et al., 2012).

1.3 Objetivos

Nesta seção serão descritos os objetivos, geral e específicos, que esta pesquisa se propõe a atingir.

1.3.1 Geral

Avaliar o sistema proposto em (ZENG et al., 2016) utilizando a localização e tipos de cozinha favoritos do usuário com a adição de um novo dado sensível ao contexto (motivo da ida), aplicado em uma pós-filtragem baseada em contexto, em um ambiente móvel para recomendar restaurantes, medindo o grau de satisfação dos usuários.

1.3.2 Específicos

- Elaborar uma aplicação móvel, utilizando o sistema operacional *Android*, para viabilizar a execução de testes comparativos com usuários reais.

- Realizar um estudo comparativo a partir dos resultados coletados entre os sistemas com e sem a utilização de uma etapa de pós-filtragem baseada em contexto.
- Utilizar dados de restaurantes da cidade de Recife, extraídos da plataforma TripAdvisor para realizar as recomendações.

1.4 Contribuições

As principais contribuições deste trabalho podem ser resumidas em utilizar questionários para coletar opiniões dos usuários e apresentar um caso de uso prático para avaliar o grau de satisfação dos usuários em relação ao sistema de recomendação de restaurantes, nesse caso, a aplicação móvel *SR Recife Restaurants*.

1.5 Estrutura do trabalho

Este trabalho está organizado da seguinte maneira: o Capítulo 2 define e aborda os principais conceitos de um sistema de recomendação e fatores para avaliar o grau de satisfação de usuários; o Capítulo 3 apresenta e resume os trabalhos relacionados que contribuíram para o desenvolvimento dessa pesquisa; no Capítulo 4 serão descritos todos os detalhes de implementação da aplicação *SR Recife Restaurants*, como os dados utilizados, o algoritmo de recomendação usado e os detalhes sobre o experimento conduzido; os resultados obtidos após o experimento serão apresentados no Capítulo 5; e, por fim, o Capítulo 6 apresenta as conclusões deste trabalho, assim como suas limitações e trabalhos futuros.

2 Fundamentação Teórica

Neste capítulo serão apresentados e detalhados os conceitos principais para a compreensão e desenvolvimento deste trabalho acerca de sistemas de recomendação.

O capítulo está definido da seguinte maneira: a Seção 2.1 embasa o que é um sistema de recomendação, bem como seus principais paradigmas e técnicas de avaliação. E, a Seção 2.2 descreve as principais técnicas de avaliação para sistemas de recomendação.

2.1 Sistemas de Recomendação

Sistemas de recomendação são ferramentas e técnicas de programas de computador que fornecem sugestões de itens que serão utilizados por um determinado usuário. Um sistema de recomendação é personalizável, ou seja, as recomendações produzidas têm como principal objetivo melhorar a experiência de um usuário em específico e não representa uma recomendação que satisfaça um grupo maior (BURKE et al., 2011).

O foco de um sistema de recomendação é reduzir a carga de informação, identificar e selecionar as informações mais relevantes a partir de uma grande base de dados, oferecendo assim, serviços personalizados (LU et al., 2015). A característica mais importante de um sistema de recomendação é a habilidade de “adivinhar” as preferências e interesses do usuário analisando o comportamento deste usuário e de outros para gerar recomendações personalizadas. As recomendações, apesar de personalizadas para o usuário em questão, já são conhecidas em detalhes pelo sistema.

O estudo de sistemas de recomendação desempenham um papel importante nos dias atuais, pois empresas globais como Netflix desenvolvem competições premiando um milhão de dólares aos competidores que desenvolvem e submetem algoritmos e soluções que melhorem suas recomendações, bem como o desempenho do sistema em geral (KOREN et al., 2009). Além disso, segundo explicado em (RICCI et al., 2011), essas grandes corporações visam atacar outros fatores voltados ao mercado e aos usuários: fatores como aumento do número de vendas e aumento da satisfação do usuário estão entre os principais focos para o estudo e avanço nesse âmbito de pesquisa.

Em (RICCI et al., 2011) também foram classificados três tipos de objetos que são usados por sistemas de recomendação: itens, usuários e transações, que são as relações entre usuários e itens. A classificação dos objetos são resumidas a seguir.

- Itens - um item é o termo geral que descreve o resultado de uma recomendação para um usuário. Geralmente um sistema de recomendação foca em um tipo específico de item, como filmes e restaurantes, por exemplo. Tendo sua construção, elementos de interface gráfica e técnica de recomendação principal, feitos especificamente para realizar recomendações personalizadas e úteis relacionadas a este tipo de item. Recomendações de itens personalizados geralmente são representadas através de listas, onde o sistema de recomendação tenta prever os produtos ou serviços que mais se encaixam de acordo com as preferências coletadas dos usuários.
- Usuários - como dito anteriormente, o foco de um sistema de recomendação é fornecer itens e interação homem-máquina personalizados para seus usuários, estes usuários têm preferências e características diversificados. O sistema explora uma variedade de informações relacionadas aos usuários, podendo estruturar essa informação de várias maneiras dependendo da técnica de recomendação utilizada.
- Transações - genericamente falando, uma transação é o registro da interação entre o usuário e o sistema de recomendação. As transações são dados que guardam informações importantes geradas durante a interação humano-máquina e são úteis para o algoritmo utilizado durante a geração de recomendações pelo sistema.

2.1.1 Paradigmas de Recomendação

Cada sistema de recomendação pode trabalhar de maneira diferente, para isso acontecer, paradigmas de recomendação são definidos. Onde esses paradigmas utilizam critérios variados para realizar os cálculos das recomendações. A seguir serão resumidos os principais paradigmas de recomendação utilizados.

- *Content-based* (CB) - ou filtragem baseada em conteúdo, o sistema aprende a recomendar os itens que são similares aos que o usuário avaliou bem em algum momento do passado. Ou seja, realiza as recomendações exclusivamente baseado no que o usuário escolheu como uma boa recomendação ou não anteriormente.
- *Collaborative-Filtering* (CF) - na filtragem colaborativa o sistema de recomendação gera as seus itens de acordo com informações armazenadas a partir de “perfis de avaliação” de usuários diferentes. Com isso, ele consegue realizar recomendações para usuários que possuem interesses similares entre si. Abordagens de filtragem colaborativa centradas no usuário são definidas em (LU et

al., 2015), onde o sistema recomenda itens para os usuários que possuem perfil similares. Por outro lado, sistemas que são baseados no conteúdos dos itens realizam recomendações onde os itens que possuem similaridades são recomendados para os usuários.

- *Context-aware* (CA) - sistemas de recomendação sensível ao contexto do usuário fornecem recomendações baseadas em itens que são classificados como relacionados ao contexto em que o usuário se encontra no momento da recomendação. Por exemplo, informações que são relacionadas ao clima, temperatura e localização (VERAS et al., 2019) são consideradas pertencentes ao contexto do usuário. Os ditos CARS (*Context-Aware Recommender Systems*), serão apresentados e discutidos mais a fundo na Subseção 2.1.2 seguinte.

Outros paradigmas de recomendação também são citados na literatura: técnicas de recomendação híbridas, recomendações baseadas em conhecimento, sistemas de recomendação baseados em inteligência computacional e baseados em redes sociais, sistemas baseados em informação demográfica e sistemas que utilizam técnicas para realizar recomendações para grupos e comunidades (BURKE, 2007) (LU et al., 2015) (RICCI et al., 2011) são alguns exemplos de paradigmas de recomendação.

2.1.2 Sistemas de Recomendação Sensível ao Contexto

Nesta subseção serão apresentados conceitos que estão diretamente relacionados com sistemas de recomendação sensível ao contexto, dado que este trabalho se baseia em um dado de contexto do usuário para melhorar as recomendações feitas pelo sistema.

2.1.2.1 Métodos para obtenção de Contexto

Como mencionado anteriormente, sistemas de recomendação que utilizam informações consideradas de contexto do usuário, por exemplo, localização, clima e humor, podem ser considerados como sistemas sensíveis ao contexto (VERAS et al., 2019). Segundo elicitado em (ADOMAVICIUS et al., 2011) existem três tipos principais de forma de obtenção de contexto de um usuário:

- Explicitamente - a informação de contexto é obtida diretamente dos usuários. Por exemplo, um *website* pode obter esse dado através de perguntas ao usuário ou em forma questionário antes da recomendação.
- Implicitamente - o dado de contexto é adquirido sem que o usuário, necessariamente, note que está fornecendo. Por exemplo, os dados de informação obtidos de um sensor de GPS de um *smartphone*.

- Inferindo - quando a informação é obtida implicitamente, porém métodos estatísticos ou de mineração de dados são necessários para obtenção do dado final (VERAS et al., 2019).

2.1.2.2 Paradigmas para Incorporação de Contexto

Com as informações de contexto em mãos, três paradigmas foram apresentados em (ADOMAVICIUS et al., 2011) para incorporação dos dados de contexto em um sistema de recomendação (Figura 1). São eles:

- Pré-filtragem baseada em contexto - os dados relevantes para a recomendação são selecionados a partir de uma filtragem inicial que é baseada no contexto atual do usuário (VERAS et al., 2019).
- Pós-filtragem baseada em contexto - inicialmente a informação do contexto é ignorada, fazendo-se o processo de recomendação utilizando um paradigma de recomendação não sensível ao contexto. Posteriormente os resultados da recomendação são expostos aos dados do contexto, podendo-se dizer que são contextualizados após essa fase (ADOMAVICIUS et al., 2011).
- Modelagem baseada em contexto - a modelagem do sistema de recomendação usará o contexto como uma dimensão, além dos usuários e os itens que geralmente são utilizados em sistemas de recomendação.

2.2 Técnicas de Avaliação em Sistemas de Recomendação

Sistemas de recomendação basicamente possuem dois tipos de cenários para avaliação: ora eles são projetados para serem executados em ambientes simulados, sem a interação de usuários reais com o sistema, ora são criados com a intenção de serem avaliados por usuários reais durante a interação.

A seguir serão detalhados os métodos de avaliação de sistemas de recomendação *offline* e *online*.

2.2.1 Avaliação *offline*

Como já mencionado anteriormente, no método de avaliação *offline*, o experimento é executado utilizando uma base de dados com os itens de usuário já classificados com a finalidade de simular o comportamento dos usuários ao interagirem com o sistema proposto. Experimentos que utilizam de avaliação *offline* são atrativos, pois, justamente, não requerem interação com usuários reais, tornando o processo mais rápido no teste e seleção dos algoritmos que serão usados. Em contrapartida, questões

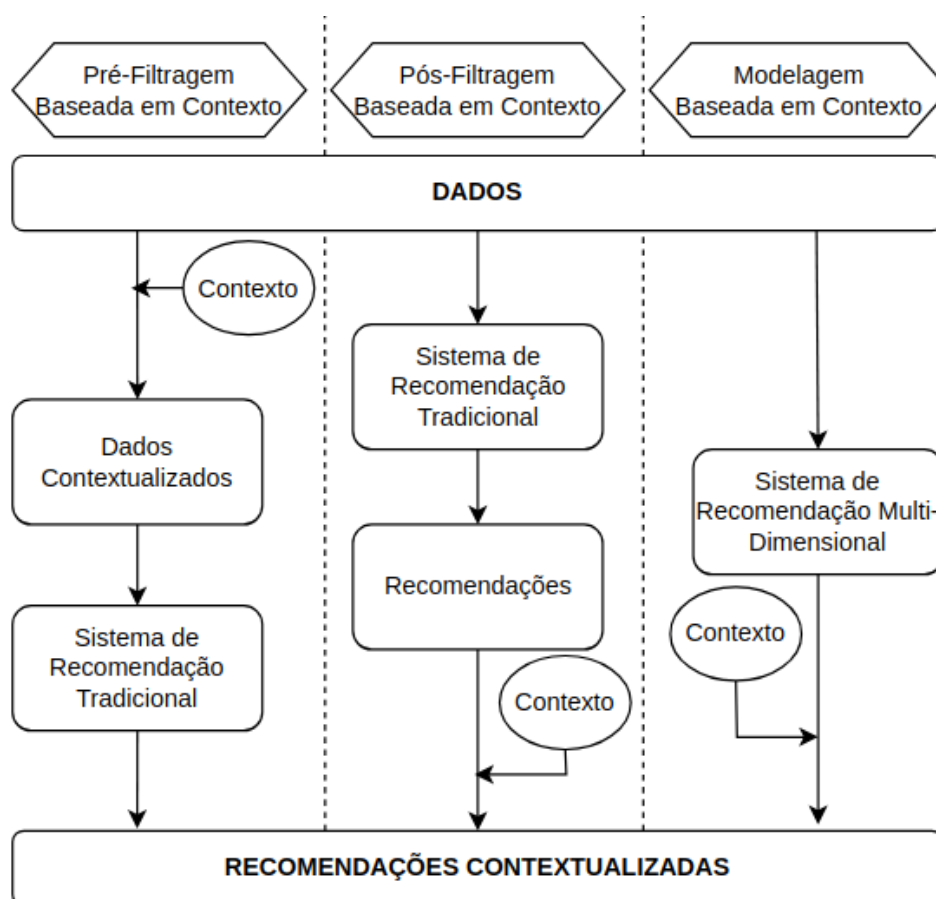


Figura 1 – Paradigmas para Incorporação de Contexto
Adaptado de (NAWARA et al., 2021)

mais complexas em relação à interação e usabilidade do sistema não são respondidas, geralmente limitando a apenas identificar o poder de predição do algoritmo utilizado (SHANI et al., 2011).

Na avaliação *offline* a base de dados, geralmente, é dividida em uma base de treino e outra de testes, onde os dados relacionados ao treino são utilizados como entrada do algoritmo do sistema de recomendação, criando assim um modelo para a recomendação. Então, os dados de teste são utilizados para validar o modelo criado anteriormente (CAÑAMARES et al., 2020).

Algumas métricas para avaliação *offline* de sistemas de recomendação tem como principal objetivo medir o erro no processo de avaliação da predição, por exemplo, *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE). Outras métricas têm como objetivo medir a acurácia do posicionamento das n-primeiras recomendações. Alguns exemplos: *precision*, *recall* e *f-measure* (NAWARA et al., 2021).

2.2.2 Avaliação *online*

Os sistemas de recomendação são desenvolvidos para usuários reais. Levando isso em consideração, medir as capacidades de interação do usuário com o sistema requer métodos diferentes em relação ao descrito anteriormente. Em sistemas de recomendação que utilizam o método de avaliação *online*, tarefas reais são executadas pelos usuários, onde fatores como a intenção, o contexto e a interface podem ser observados e levados em consideração em relação aos que utilizam o método de avaliação *offline* (SHANI et al., 2011).

Fatores, técnicas e arcabouços para realizar avaliações focadas no usuário de sistemas de recomendação são apresentados na Seção 2.2.2.1 a seguir.

2.2.2.1 Fatores para Avaliação de Satisfação de Usuários

O arcabouço *FEVR*, desenvolvido em (ZANGERLE et al., 2022), tem como objetivo de fornecer uma base estruturada para adotar as configurações mais adequadas para a avaliação do sistema. Para isso considera quatro componentes principais: objetivos da avaliação, princípios da avaliação, tipo do experimento e aspectos da avaliação. Cada um dos componentes possui subcomponentes para refinamento da avaliação do sistema, por exemplo, no componente princípio da avaliação, variáveis de controle e confiabilidade, são alguns dos itens levados em consideração.

Outro arcabouço para avaliação de sistemas de recomendação desenvolvido em (PU et al., 2011), *ResQue*, foi elaborado para identificar, a partir da ótica do usuário, o quão bem sucedido é um sistema de recomendação. Para desenvolver o *ResQue* quatro pilares essenciais foram considerados: qualidades percebidas pelo usuário do sistema; crenças do usuário como resultado dessas qualidades em termos de facilidade de uso, utilidade e controle; atitudes subjetivas do usuário; e, as intenções comportamentais do usuário. Onde cada pilar é detalhado em itens de avaliação menores como, a facilidade de uso percebida nas crenças do usuário e a confiança nas atitudes do usuário, por exemplo.

Na pesquisa elaborada em (HERLOCKER et al., 2004), várias tarefas voltadas para a execução do sistema de recomendação pelo usuário foram elaboradas e discutidas com finalidade de avaliar o sistema. Atividades como encontrar itens bons, encontrar todos os itens, recomendar uma sequência e descoberta de novos itens, por exemplo, descrevem como os objetivos do usuário final do sistema devem ser avaliados. Além disso, o trabalho também fala que um sistema de recomendação deve ser avaliado pela sua habilidade de encontrar bons itens, recomendar uma sequência, entre outros.

Alguns fatores úteis no processo de avaliação de sistemas de recomendação

também foram elencados em (KNIJNENBURG et al., 2015). Basicamente os fatores descrevem como a interpretação subjetiva dos usuários (SSA) relacionada à funcionalidades críticas de um sistema (OSA) influencia em suas experiências (EXP) e interação (INT) com o sistema (Figura 2).

Os componentes centrados nos usuários mencionados acima são descritos da seguinte maneira:

1. OSA - *Objective System Aspects* ou aspectos objetivos do sistema - sistemas de recomendação podem ter vários tipos de funcionalidades, diante disso uma forma de avaliá-lo é realizar avaliações em porções ou funcionalidades menores como, por exemplo, o algoritmo que está sendo utilizado nas recomendações, bem como a forma que as recomendações estão sendo apresentadas para o usuário (o layout utilizado, o número de recomendações feito, entre outros).

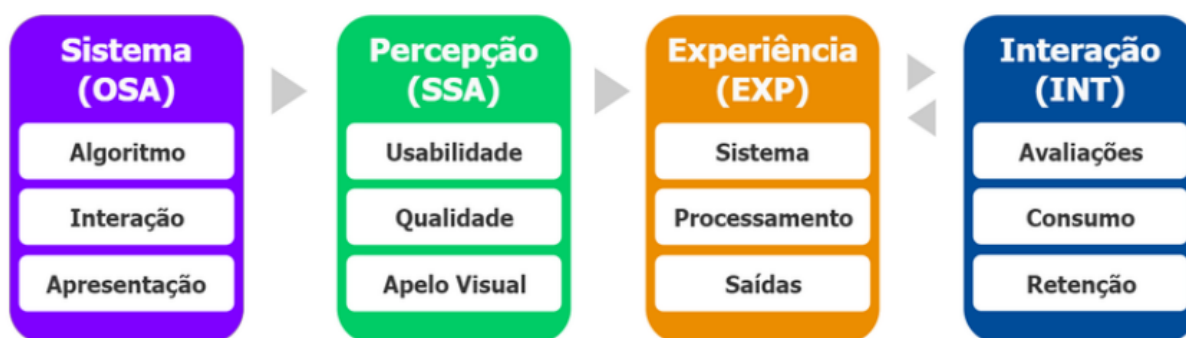


Figura 2 – Avaliação de Sistemas de Recomendação com Usuários
Adaptado de (MONTEIRO, 2017)

2. SSA - *Subjective system aspects* ou aspectos subjetivos do sistema - essa técnica visa medir a percepção subjetiva do usuário em relação aos OSAs. Por exemplo, o usuário pode não gostar de uma recomendação feita mesmo que essa recomendação seja a que possui maior pontuação na avaliação feita pelo algoritmo. Isso será medido através de questionários com o usuário durante ou após o uso do sistema.
3. EXP - *User experience* ou experiência do usuário - esse fator tem como objetivo avaliar a experiência do usuário ao utilizar o sistema de recomendação. Fatores pessoais podem ser levados em consideração como a avaliação dos itens escolhidos, a experiência que o usuário teve ao navegar pelo sistema, entre outras. Também utiliza de questionários para coletar essas informações.
4. INT - *Interaction* ou interação - considerado como o último estágio na avaliação de um sistema de recomendação, a interação do usuário com o sistema é um fator relevante para notar se o usuário está interagindo com o sistema da mesma forma

para que o mesmo foi projetado. Interações com a interface, o tempo gasto e a interação do usuário com as recomendações feitas são as informações coletadas por essa técnica.

Outros fatores que podem ser levados em consideração na avaliação de um sistema de recomendação são as características pessoais e situacionais do sistema (PCs - *Personal Characteristics* e SCs - *Situational Characteristics*). Também coletados a partir de questionários, esses fatores visam identificar se características como gênero, expertise, confiança no sistema e objetivo da escolha, por exemplo, influenciam nos fatores definidos anteriormente.

3 Trabalhos Relacionados

Para realização e implementação da aplicação *SR Recife Restaurants*, foram reunidas pesquisas que abordam o tema de recomendação de restaurantes, tendo como principal finalidade o estudo e contextualização dos trabalhos que abordam as técnicas de avaliação *offline* e *online*, utilizadas para realizar suas recomendações.

Nesta seção serão detalhados os trabalhos que estão relacionados com o objetivo desta pesquisa: recomendações de restaurantes. Para melhor entendimento, a seção está dividida em duas subseções: a primeira, Seção 3.1, onde serão apresentados os trabalhos que utilizam do método de avaliação *offline* para realizar as recomendações de restaurantes, a Seção 3.2, que, por sua vez, descreve os trabalhos que usam do método de avaliação *online* para avaliar seus resultados e, por fim, a Seção 3.3 apresenta as tabelas resumindo os trabalhos relacionados.

3.1 Método de Avaliação *offline*

Na pesquisa desenvolvida em (ASANI et al., 2021) foram coletados dados de um grupo de 100 usuários diferentes, que utilizam a plataforma TripAdvisor¹, durante 9 meses. Foi proposto um sistema de recomendação sensível ao contexto que extrai as preferências de comidas encontradas nos comentários de cada usuário na plataforma, bem como informações de localização e tempo fora utilizadas para realizar sugestões de acordo com essas preferências. Para isso, um sistema híbrido foi sugerido, que combina extração de informação e recomendação, onde, uma abordagem semântica é usada para agrupar o nome de ingredientes extraídos dos comentários e analisar os sentimentos sobre eles. Em seguida o sistema de recomendação faz a recomendação baseado no conteúdo extraído do comentário de cada usuário, recomendando um novo restaurante de acordo com os itens extraídos de comentários anteriores. Os autores foram capazes de fazer uma recomendação de restaurantes próximos ao usuário com uma precisão de 92.8%.

Em (GOMATHI et al., 2019) um sistema de recomendação que utiliza análise de sentimentos usando *NLP - Natural Language Processing* foi construído. Para fazer recomendações de restaurantes que mais se encaixam com o perfil do usuário, o sistema agrupa informações de hotéis (encontradas em comentários), amenidades, avaliações e notas de usuários da plataforma TripAdvisor. O estudo concluiu que ao utilizar NLP como técnica principal de recomendação, o sistema obteve uma acurácia

¹ <<https://www.tripadvisor.com/>>

de 92.45% em comparação com outras técnicas de aprendizagem de máquina, como SVM, por exemplo.

No trabalho proposto em (SUN et al., 2019) um sistema de recomendação de restaurantes baseado em análise de sentimentos de opiniões de usuários acerca de restaurantes chineses foi elaborado. Tendo como principal técnica a força do sentimento e a polaridade do sentimento expresso nas avaliações de usuários. O estudo utilizou seis algoritmos, sendo três derivados do *k-NN* e três derivados do *k-Means* para se basear na teoria da incerteza e, com isso, utilizar *precision* e *F-score* como métricas de avaliação de dois sistemas de recomendação baseados em opiniões de usuários. O estudo conclui que os algoritmos derivados do *k-Means* obtiveram melhor *F-score* em relação ao outro grupo de algoritmos: entre 0,008 e 0,016 para lista resultante de tamanho entre 5 e 10. Em relação à métrica *precision* os dois grupos de algoritmos mantiveram os mesmos valores (0,012 e 0,016) quando a lista possui entre 1 e 10 itens.

Em (ZHANG et al., 2018) é sugerido um sistema de recomendação baseado em filtragem de conteúdo e focado em restaurantes que se enquadram em categorias culturais. A recomendação é baseada em fatores de avaliação dos usuários e o sentimento das avaliações contidos na base de dados do Yelp². Os fatores avaliados variam entre qualidade de serviço, diversidade de menu, atmosfera do local, comida saudável, entre outros. Para a extração de sentimento das avaliações, algumas técnicas foram utilizadas como filtragem e remoção de *stop-words*, seleção de características, entre outras. Foram utilizados diversos algoritmos de aprendizagem de máquina como SVM, *Naive-Bayes* e *Random Forest*, por exemplo. O algoritmo que atingiu melhor resultado foi o *Naive-Bayes* com *F-score* de 92.44%.

O estudo apresentado em (CHU et al., 2017) averiguou a influência da informação visual presente em blogs em combinação com técnicas comuns na literatura (filtragem baseada em conteúdo e filtragem colaborativa) para realizar recomendação de restaurantes. O modelo coleta os dados de cada usuário de acordo com suas preferências, onde se o usuário adiciona restaurantes em seus favoritos, o sistema coleta dados de avaliação desses restaurantes bem como imagens relacionadas a esses estabelecimentos, salvando-os como as preferências de um usuário. Para extrair informação dos textos foi criado um vetor binário que mostra a presença de cada palavra chave nos artigos relacionados àquele restaurante. Para as imagens, foram utilizadas a abordagem de extração de nome das cores em conjunto com a classificação das imagens através do de uma rede neural convolucional onde quatro classes foram usadas: bebida, comida, *indoor* e *outdoor*. O autor conclui que utilizando a abordagem de adição de informação obtida de imagens obteve melhor desempenho na predição do

² <<https://www.yelp.com.br/>>

restaurante a ser recomendado. Para isso foram utilizados os métodos *Matrix Factorization* e *Bayesian Personalized Ranking Matrix Factorization* aprimorados, onde em todos eles a métrica AUC (*Area Under the ROC Curve*) foi superior, 0.6384 para MF e 0,7078 para BPRMF, utilizando o modelo híbrido adicionando a informação obtida de imagens.

No trabalho proposto em (SHAMBOUR et al., 2023) um algoritmo híbrido de recomendação de restaurantes baseado em itens de usuário e baseado em filtragem de conteúdo que utiliza multi-critérios (*Hybrid User-Item based Multi-Criteria Collaborative Filtering*). Segundo o autor, o algoritmo explora as similaridades implícitas entre usuários e itens para eliminar a escassez de informação sobre avaliações. Para validar o trabalho em relação à literatura, foram utilizados três base de dados distintas: Restaurants/Hotels-TripAdvisor³ e Yahoo! Movies⁴. Já para comparar o algoritmo em relação à literatura, seis algoritmos baseados em filtragem de conteúdo foram utilizados, onde todas as três bases de dados foram examinadas. Os resultados experimentais mostraram que o algoritmo proposto é efetivo para escassez de informação nas bases de dados, utilizando as métricas de avaliação obtendo 66% para MAE, 54% para RMSE, 92% para nDCG e cobertura de 89%.

Em (KUMAR et al., 2018) uma abordagem híbrida para recomendação de restaurantes é fornecida: um algoritmo genético em conjunto com redes neurais artificiais (GA-ANN) para realizar recomendações de restaurantes para os usuários. Com finalidade de obter maior precisão e acurácia, o estudo propõe a implementação de um sistema de recomendação consciente do contexto para recomendar várias informações úteis para os usuários. Os dados utilizados no trabalho são provenientes da base de dados *Entree Chicago Recommendation Data*, que contém informações relacionadas ao contexto, coletadas por dispositivos de IoT que possuem informações sobre as sessões dos clientes com esses restaurantes, entre outras. Como resultado, a abordagem híbrida obteve uma acurácia 98% e *precision error* de 2%.

Em (KOETPHROM et al., 2018) um comparativo de várias técnicas de filtragem em sistemas de recomendação de restaurantes é apresentado, com o objetivo de prever o grau de satisfação na predição de restaurantes, baseado em três metodologias: filtragem baseada em conteúdo - usada para realizar a predição da satisfação do cliente, usando como dados de entrada informações do usuário e do restaurante; filtragem colaborativa - combina análise de agrupamentos, teste de similaridades e soma ponderada para realizar a predição. Esse método leva em consideração as preferências de usuário e as avaliações do restaurante; e, filtragem híbrida, que utiliza as duas anteriores combinadas para inferir a predição através da similaridade por cosseno e

³ <<https://tripadvisor-content-api.readme.io/reference/searchforlocations>>

⁴ <<https://www.yahoo.com/entertainment/movies/>>

do método soma ponderada. Como conclusão, o estudo destacou que a abordagem híbrida superou as duas anteriores tendo melhor com MAE de 1,032, sendo sua distribuição residual mais concentrada do que as outras abordagens.

Na abordagem descrita em (MUSTAFA et al., 2018), a junção de similaridade entre itens e similaridade entre usuários como características principais para criar um sistema que gera recomendações de restaurantes. O estudo foi dividido em duas fases: a primeira, modelagem dos dados, dois modelos foram criados para serem usados no sistema de recomendação, sendo empregadas as técnicas de filtragem colaborativa e filtragem baseada em conteúdo para obter as similaridades entre os itens e os usuários. Esses modelos foram criados usando o algoritmo *k-NN*; na segunda fase, o modelo criado na fase anterior é submetido aos sistemas de recomendação. O trabalho utilizou dados de restaurantes indonésios, consistidos de informações dos restaurantes e de avaliações sobre esses restaurantes. Concluiu-se que melhores *F-score* são produzidas quando os modelos são construídos considerando um maior período de tempo dos dados. Obtendo *F-score* de 0.441277 para similaridade entre restaurantes e 0.323167 para similaridade entre usuários.

Em (FAKHRI et al., 2019) foi construído um sistema de recomendação de restaurantes baseado em avaliações de usuários. O sistema utiliza de filtragem de conteúdo para fazer a recomendação e usa as avaliações para indicar o restaurante similar às preferências do usuário e que possui maior avaliação dentre outros usuários. Para encontrar as similaridades entre os usuários, o sistema utiliza duas técnicas: similaridade entre avaliações de usuários e similaridade entre atributos de usuários. O estudo concluiu que utilizando um número maior de vizinhos no algoritmo *k-NN*, bem como não utilizando a similaridade de atributos dos usuários, melhor a performance do sistema de recomendação. Obtendo assim a média MAE de 1.492 usando similaridade de avaliação de usuário em comparação com 2.166 com a similaridade de atributos de usuário.

Em (LI et al., 2017) é proposto estudar e prever os hábitos de usuários do sistema para, depois, prever os valores que serão usados para fazer a recomendação de restaurantes. Para isso, o estudo utiliza filtragem colaborativa baseada em atributos de usuários e avaliações de restaurantes gerando valores de entrada para calcular a similaridade entre avaliações dos usuários, similaridades entre os atributos de usuários e, na etapa final do algoritmo, o algoritmo *k-NN* é utilizado para seleção dos top-*n* itens. O estudo proposto obteve melhor desempenho, tendo uma MAE de 0.687 para $k = 25$, comparado com o algoritmo baseado apenas em atributos de usuários, com 0.8326. O estudo conclui informando que quando melhor a MAE mais precisa e efetiva é a recomendação.

3.2 Método de Avaliação *online*

Em (HERSE et al., 2018) um estudo é conduzido para saber se a combinação entre o sistema de recomendação com elicitación de preferências e personificação de um robô humanóide aumenta a confiança que o usuário tem na recomendação de refeições em um restaurante. Um *script* com instruções descrevendo cenários foram passados para os usuários, assim como a opção de escolha entre um *tablet* ou um robô para escolha de atendimento no restaurante. O procedimento do estudo se deu seguindo a seguinte sequência: pequena interação com o usuário, interação com o sistema de recomendação, captação de respostas de um questionário e uma entrevista. O questionário é constituído de três dimensões: competência, boa vontade e confiabilidade; com pontuação que varia de -3 a +3 para avaliar o grau de percepção. O estudo conclui que o uso ou não de robô não influenciou na confiança que o usuário teve, por outro lado, a elicitación de preferências ajudou na preferência do usuário pelo robô em relação ao *tablet*. As médias de resposta para cada dimensão em relação ao uso do robô ficaram: competência - 0.833, boa vontade - 1.053 e confiabilidade - 0.903.

Em (WANG et al., 2020) um modelo de recomendação para RNNs *Transformer cross Transformer - TxT* é proposto, onde explora o comportamento da sequência de pedidos de um cliente de acordo com características contextuais como localização, tempo e clima para realizar recomendações em um sistema de *drive-thru*. Um transformador de sequência (*Sequence Transformer*) e um transformador de contexto (*Context Transformer*) foram utilizados para codificar a ordem de pedido de cada item e características relacionadas ao contexto em que o pedido foi realizado. Para finalizar, o treinamento TxT foi utilizado para treinar o algoritmo com as duas técnicas anteriores. Com os dados preparados, a função de ativação LeakyRelu e em seguida a camada softmax foram usadas para prever as probabilidades de cada item. Na metodologia *offline*, as acurácias Top1 e Top3 foram escolhidas para medir a performance da recomendação. Para medir a metodologia *online*, um teste A/B foi realizado e outras características como aumento de conversão de clientes e aumento de vendas foram levadas em consideração. Os resultados apresentados foram que na avaliação *offline* o modelo TxT melhorou a recomendação do *drive-thru* em 79% e na avaliação *online* o modelo garantiu um adicional de 4.7% nas vendas em relação ao grupo de controle.

Em (ZENG et al., 2016) um sistema de recomendação de restaurantes para o ambiente móvel é apresentado, usando as preferências do usuário e informações de localização do usuário para gerar as recomendações. Para criar o vetor de preferências, o usuário responde um questionário com as características que ele procura em restaurantes, como, por exemplo, o tipo de cozinha. Após o usuário visitar tal restaurante, as novas características que não constavam presentes antes são adicionadas ao vetor de preferências do usuário, fazendo com que novas informações sejam adici-

onadas e preferências anteriores reforçadas. Para realizar a recomendação, primeiro é calculada a similaridade de cosseno para determinar a similaridade entre os vetores de preferência do usuário e o de características do restaurante. O trabalho leva em consideração que a menor distância entre o usuário e o restaurante é a ideal para recomendação, então o sistema utiliza o GPS do *smartphone* e realiza o cálculo com as coordenadas do restaurante. Finalmente, para realizar a recomendação, o cálculo do score é feito baseado na similaridade entre a distância entre o usuário e o restaurante. Assim, o restaurante com melhor score ficará no topo da recomendação. O estudo mostrou, em um caso de estudo, que 89.5% dos restaurantes recomendados no top-5 estavam de acordo com as preferências dos usuários

3.3 Tabela de Resumos dos Trabalhos

Os trabalhos exemplificados nas seções anteriores abordam vários tipos de métodos e técnicas para construção e avaliação de sistemas de recomendação de restaurantes, porém o modelo descrito em (ZENG et al., 2016) se assemelha com este trabalho em termos de técnicas, plataforma, paradigma de recomendação e tipo de avaliação. Sendo assim, o presente trabalho visa utilizar o estudo desenvolvido em (ZENG et al., 2016) como base para aprimoramento da recomendação através da adição de um novo dado sensível ao contexto do usuário.

A seguir estão desenhadas as Tabela 1 e Tabela 2 contendo um resumo dos trabalhos relacionados, exaltando os paradigmas de recomendação utilizados, técnicas, tipo de avaliação e as plataformas usadas em cada pesquisa.

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

Trabalho	Paradigma de Recomendação	Tipo de avaliação
(ASANI et al., 2021)	CA, CB	Precision, Recall e F-score
(WANG et al., 2020)	CA	Acurácia top-1 e top-3 e Testes A/B
(FAKHRI et al., 2019)	CF	MAE
(GOMATHI et al., 2019)	CB	RMSE, MAE e acurácia
(SUN et al., 2019)	CB	Precision, Recall e F-score
(HERSE et al., 2018)	N/A	Questionário de Avaliação
(ZHANG et al., 2018)	CB	F-score
(CHU et al., 2017)	CB, CF	AUC
(ZENG et al., 2016)	CA	Cliques de usuários
(SHAMBOUR et al., 2023)	CB	MAE, RMSE, nDCG e Cobertura de precisão
(KUMAR et al., 2018)	CA	Acurácia e Precision
(KOETPHROM et al., 2018)	CB, CF	MAE
(MUSTAFA et al., 2018)	CB, CF	Precision, Recall e F-score
(LI et al., 2017)	CF	MAE e RMSE
Trabalho Proposto	CA	Questionário de satisfação

Fonte: O autor

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

Trabalho	Técnica	Plataforma
(ASANI et al., 2021)	Análise de sentimentos e Similaridade por cosseno	N/A
(WANG et al., 2020)	RNN	Drive-thru e Móvel
(FAKHRI et al., 2019)	k-NN	Web
(GOMATHI et al., 2019)	Sentimental Score	N/A
(SUN et al., 2019)	k-NN e k-MEANS	Web
(HERSE et al., 2018)	N/A	Móvel
(ZHANG et al., 2018)	Vários algoritmos de ML	N/A
(CHU et al., 2017)	Vários algoritmos de ML	N/A
(ZENG et al., 2016)	Similaridade por cosseno e score	Móvel
(SHAMBOUR et al., 2023)	HUIMCCF	N/A
(KUMAR et al., 2018)	GA-ANN	N/A
(KOETPHROM et al., 2018)	Similaridade por cosseno e soma ponderada	N/A
(MUSTAFA et al., 2018)	k-NN	N/A
(LI et al., 2017)	k-NN	N/A
Trabalho Proposto	Similaridade por cosseno, score e motivo da ida ao restaurante	Móvel

Fonte: O autor

4 Metodologia

Nesta seção serão apresentados os conceitos e técnicas necessários para executar o experimento proposto neste trabalho, a aplicação móvel *SR Recife Restaurants*, bem como as técnicas para avaliação do sistema de recomendação de restaurantes. Como mencionado anteriormente, este trabalho tem como trabalho-base o executado em (ZENG et al., 2016).

O capítulo está dividido em quatro seções, na Seção 4.1 o conjunto de dados obtido e utilizado é descrito, na Seção 4.2 o modelo de preferências do usuário é detalhado, sendo essa seção dividida em duas subseções: a Subseção 4.2.1 descreve as características dos restaurantes que serão utilizadas como entrada para o sistema de recomendação, na Subseção 4.2.2, assim como na anterior, as características dos usuários serão apresentadas e na Subseção 4.2.3, o novo dado sensível ao contexto dos usuários é apresentado. Seguindo, na Seção 4.3, o algoritmo de recomendação é abordado, essa seção é subdividida em três subseções: Subseção 4.3.1 descreve o cálculo da similaridade entre o usuário e o restaurante, na Subseção 4.3.2 o cálculo da distância entre o usuário e os restaurantes é detalhada, o algoritmo de recomendação de restaurantes é apresentado e detalhado na Subseção 4.3.3, e, por fim, na Subseção 4.3.4 é dedicada a mostrar como o motivo da ida ao restaurante reorganizará a recomendação final. Concluindo o capítulo de metodologia de pesquisa, a última seção, Seção 4.4 é dedicada a abordar o experimento proposto no trabalho, tendo como subseções Subseção 4.4.1 onde é detalhado a aplicação *SR Recife Restaurants*, a Subseção 4.4.2, onde os testes com usuários reais são descritos e, concluindo, a Subseção 4.4.3 descreve os questionários de avaliação do sistema.

4.1 Conjunto de Dados

Os dados utilizados no trabalho foram adquiridos através da API pública da plataforma TripAdvisor¹, a qual fornece acesso a vários tipos de dados que são coletados pela própria plataforma. Esses dados variam entre informações detalhadas, fotos, avaliações de clientes, entre outras, sobre hotéis, restaurantes e atrações turísticas. Para este trabalho foram extraídos e utilizados os seguintes dados de restaurantes: latitude, longitude, tipo de cozinha, avaliação do motivo da ida ao restaurante e informações do restaurante como nome e endereço.

Como já mencionado, os dados foram coletados e armazenados apenas para

¹ <<https://tripadvisor-content-api.readme.io/reference/overview>>

Tabela 3 – Tipos de cozinha presentes no dados extraídos da plataforma TripAdvisor

Peruana	Chinesa	Frutos do mar
Americana	Mediterrânea	Coreana
Grelhados	Lanchonete	Europeia
Brasileira	Italiana	Steakhouse
Israelense	Indígena	Norte da Itália
Contemporânea	Pizza	Churrasco
Restaurantes que servem cerveja	Sul-americana	Bar
Pub com restaurante	Fusion	Asiática
Asiática central	Africana	Portuguesa
Árabe	Latina	Saudável
Japonesa	Australiana	Francesa
Mexicana	Oriente Médio	Pub
Europeia central	Restaurante com bar	Libanesa
Sul da Itália	Sushi	Internacional
Wine Bar	Comida de rua	

Fonte: O autor

as cidades de Recife e Jaboatão, ambas pertencentes à região metropolitana de Recife, Pernambuco. O trabalho se restringiu apenas a essas cidades, pois para fins de testes com usuários reais e coleta de questionários, seria o ideal. No total foram coletados dados de 145 restaurantes para implementação e avaliação do modelo de recomendação.

4.2 Modelo de Preferências do Usuário

Nesta seção, os detalhes de como as características dos restaurantes e dos usuários são detalhadas, com finalidade identificar e criar a matriz de características dos restaurantes e os vetores de preferência de usuários, além de, principalmente, servir como entrada para o sistema de recomendação final.

4.2.1 Características dos Restaurantes

Uma das características que descreve o cardápio de um restaurante é o tipo de cozinha que ele serve aos seus clientes. Um bom exemplo são restaurantes ditos “italianos” por ter como pratos principais de sua cozinha espaguete, lasanhas e outros tipos de massas. Dados a este fato, a cozinha do restaurante pode ser classificada como “italiana”. A Tabela 3 mostra os tipos de cozinha presentes na base de dados coletada. A Tabela 4 mostra os doze tipos de cozinha mais presentes nos restaurantes coletados. Os outros tipos de cozinha foram omitidos pois estavam presentes em menos de dez restaurantes da base de dados.

Sendo assim, cada restaurante pode oferecer aos seus clientes diferentes tipos de pratos, de várias localidades e especialidades, fazendo com que eles possuam um ou mais tipos de cozinha. Para representar esse tipo de característica, considera-se o vetor de características dos restaurantes $C = (c_1, c_2, \dots, c_n)$, onde c_i representa a i -ésima característica de um restaurante. Assim, para um restaurante r , caso ele possua a característica c_i , então à c_i será atribuído o valor 1, caso contrário será atribuído o valor 0. Levando essas informações em consideração, uma matriz de *restaurantes x características* é formada, onde as colunas representam as características do restaurante (tipo de cozinha) e as linhas representam os restaurantes (ZENG et al., 2016).

Tabela 4 – Tipos de cozinha por quantidade de restaurantes

Tipo de cozinha	Quantidade de restaurantes
Brasileira	88
Sul-americana	59
Frutos do mar	28
Sushi	24
Japonesa	20
Bar	14
Contemporânea	14
Asiática	13
Pizza	13
Churrasco	13
Europeia	11
Chinesa	10

Fonte: O autor

4.2.2 Características dos Usuários

As características, relacionadas ao tipo de cozinha dos restaurantes, descritas anteriormente também refletem as preferências dos clientes quando procuram um restaurante para realizar uma refeição. Então, o vetor de usuário pode ser representado como $U = (c_1, c_2, \dots, c_n)$, sendo c_i a i -ésima característica que descreve a cozinha de um restaurante (ZENG et al., 2016).

Ao iniciar a aplicação de recomendação de restaurantes, o usuário informará ao sistema suas preferências relacionadas ao tipo de cozinha, ou seja, os tipos de cozinha favoritos que espera que sejam recomendados. Com essa informação, dado o vetor de característica de um restaurante R , o sistema atribuirá o valor 1 para a(s) característica(s) escolhida(s) pelo usuário que são iguais àquelas possuídas pelo res-

taurante R , e o valor 0 para as demais não selecionadas no vetor de características de usuário.

Como o objetivo principal da aplicação é sugerir recomendações de restaurantes de acordo com as preferências do usuário, seu uso será feito de maneira rotineira, fazendo assim, com que o sistema ofereça melhores recomendações com o tempo de uso. Assim, com o uso recorrente da aplicação, caso o usuário escolha um restaurante que possua o mesmo tipo de cozinha que já foi atribuído o valor 1, então o valor atual é incrementado em 1. Isso significa que com o tempo as preferências do usuário serão cada vez mais explícitas para o sistema de recomendação. Com isso, os valores do vetor de características dos usuários precisa ser normalizado a cada iteração seguindo a fórmula definida em (ZENG et al., 2016):

$$Norm(c_i) = \frac{c_i}{\sum_{j=0}^n c_j}$$

Desta forma, os valores presentes no vetor estão limitados no intervalo $[0, 1]$. Assim, dado o vetor de características de um usuário, por exemplo, $U = (0, 2, 1, 1)$, após normalização, ficará $U = (0, 0.5, 0.25, 0.25)$ (ZENG et al., 2016).

4.2.3 Contexto dos usuários

Cada usuário da plataforma TripAdvisor, após frequentar um restaurante, pode decidir avaliá-lo no sistema, podendo deixar uma avaliação da companhia com quem foi ao restaurante. Levando isso em consideração, cada motivo da ida ao restaurante possui um valor atribuído a si, que na realidade é um somatório das avaliações de outros usuários. Para cada restaurante presente na base de dados, encontram-se cinco motivos da ida ao restaurante² avaliados pelos usuários: negócios, romântica, viagem a sós, família e viagem com amigos.

4.3 Algoritmo de Recomendação de Restaurantes

Nas subseções que se seguem serão descritos em detalhes os cálculos de similaridade entre os vetores de usuários e os vetores de restaurantes, a distância entre o usuário e os restaurantes na hora da recomendação, o algoritmo que calcula as recomendações de restaurantes e, por fim, será adicionado ao modelo existente, proposto em (ZENG et al., 2016), uma nova característica sensível ao contexto do usuário – motivo da ida ao restaurante – que irá reorganizar a posição das recomendações providas pelo algoritmo.

² <<https://tripadvisor-content-api.readme.io/reference/getlocationreviews>>

Tabela 5 – Exemplo do total de avaliações para cada motivo da ida a um restaurante

Motivo da ida ao restaurante	Total de avaliações
Negócios	16
Romântica	35
Viagem a sós	5
Família	81
Viagem com amigos	98

Fonte: O autor

4.3.1 Similaridade Entre Usuário e Restaurantes

Para determinar se um usuário u tem preferência por um restaurante r , o algoritmo proposto em (ZENG et al., 2016) utiliza do cálculo da similaridade por cosseno, para determinar o quão similares u e r são.

$$S(u, r) = \cos(u, r) = \frac{\sum_{i=1}^n p_i f_i}{\sqrt{\sum_{i=1}^n p_i^2} \times \sqrt{\sum_{i=1}^n f_i^2}}$$

O valor da similaridade por cosseno entre u e r , $S(u, r)$, mede o cosseno do ângulo formado por u e r , onde quanto menor o ângulo mais similares são os valores (SINGH et al., 2020), além de estar sempre no intervalo $[0, 1]$, pois os valores foram normalizados anteriormente.

Então, pode-se considerar que dado um usuário u , que possui um vetor de características de tipo de cozinha $U_u = (u_1, u_2, \dots, u_n)$, e dado um restaurante r , que possui um vetor de características $R_r = (r_1, r_2, \dots, r_n)$ serão similares se o valor da similaridade entre u e r , $S(u, r)$, for próximo de 1 (ZENG et al., 2016).

4.3.2 Distância Entre Usuário e Restaurantes

O cálculo da distância entre o usuário e os restaurantes em tempo real é de grande importância, pois como o sistema é uma aplicação para dispositivos móveis, geralmente, o restaurante mais próximo pode ser uma boa escolha para o usuário.

Para coletar os dados de localização em tempo real, o sistema utiliza o GPS do dispositivo, coletando informações de latitude e longitude do usuário no momento anterior à recomendação. Esses dados em conjunto com as latitudes e longitudes previamente, coletadas a partir da API do TripAdvisor, dos restaurantes poderão ser utilizados para o cálculo da distância entre usuário e restaurante.

Para realizar o cálculo da distância entre o usuário e os restaurantes a fórmula de haversine é escolhida. A fórmula de haversine é utilizada para determinar a distância entre dois pontos em uma esfera a partir de suas latitudes e longitudes, sendo amplamente aplicada em navegações. Dado dois pontos $(A(x_1, y_1), B(x_2, y_2))$, onde x é a latitude e y a longitude, dado que $a = \cos(x_1 - x_2)$, $b = \cos(y_1 - y_2)$ e $c = \cos(x_1) \times \cos(x_2)$ e dado que R é o raio da terra (ZENG et al., 2016) (MARIA et al., 2020):

$$Dist(A, B) = 2 \times R \times \arcsin\left(\frac{\sqrt{2 \times (1 - a + c - cb)}}{2}\right)$$

4.3.3 Algoritmo de Recomendação de Restaurantes

Quando um usuário solicita a recomendação de um restaurante, o sistema obtém os restaurantes mais próximos que se encontram dentro de um raio R inicial de 100 metros, sendo R ajustável. Após o passo de descobrir os restaurantes que estão incluídos na área de R , o sistema calcula a distância utilizando a fórmula descrita na seção anterior. Caso a quantidade de restaurantes incluídos na área de R seja inferior a 10, o algoritmo incrementa R em 250 metros até que a condição se satisfaça.

O próximo passo é determinar o score de cada restaurante que se encontra dentro de R . Para o cálculo do score de um restaurante r_i para um usuário u - $Score(u, r_i)$ - a seguinte fórmula é utilizada (ZENG et al., 2016):

$$Score(u, r_i) = \alpha \times S(u, r_i) + \beta \times \frac{(1 - Dist(u, r_i))}{R}$$

Na equação do score, α e β são pesos que têm valores iniciais de 0.5. De acordo com a fórmula, se dois restaurantes possuírem a mesma similaridade, o restaurante mais próximo do usuário será indicado com uma posição melhor nas recomendações. Pelo lado contrário, se dois restaurantes têm as mesmas distâncias a partir do ponto que o usuário se encontra, o restaurante com maior similaridade com o usuário será mostrado como melhor opção, ou seja, receberá um score maior. Os pesos α e β não são constantes, ou seja, eles são atualizados a cada interação do usuário com o sistema, onde o mesmo indicará qual foi a melhor recomendação ao final. Para realizar esse ajuste a cada interação, as seguintes equações são definidas em (ZENG et al., 2016) e utilizadas:

$$\alpha' = \alpha + 0.1 \times \left[S(u, r) - \left(1 - \frac{Dist(u, r)}{R}\right) \right]$$

$$\beta' = \beta + 0.1 \times \left[\left(1 - \frac{Dist(u, r)}{R}\right) - S(u, r) \right]$$

Sendo assim, α' e β' serão os novos valores a serem utilizados como pesos na próxima interação com o sistema.

4.3.4 Reorganização da Recomendação Baseada no *motivo da ida*

Como mencionado anteriormente, o presente trabalho propõe explorar o desempenho e qualidade das recomendações do sistema de recomendação de restaurantes utilizando um novo dado de contexto do usuário. Para isso, será introduzida uma nova etapa de pós-filtragem contextual no algoritmo de recomendação apresentado em (ZENG et al., 2016). Nesta nova etapa uma das informações coletada da base de dados do TripAdvisor será utilizada, o *motivo da ida*, tendo como objetivos principais a contextualização da recomendação final (KANNOUT, 2020) e reorganização da lista de restaurantes sugerida.

Um ranque, exemplificado no Algoritmo 1, pode ser definido para cada restaurante com os *motivo da ida* mais votados pelos usuários. O trabalho tem como proposta justamente utilizar este dado, selecionado pelo usuário um passo antes da recomendação, para ser utilizado como fator decisivo na ordenação das recomendações. Ao ter o *motivo da ida* selecionado, o sistema reordenará as recomendações existentes de acordo com o valor das avaliações para o dado informado, colocando os restaurantes recomendados no topo que obtiverem melhores avaliações para este tipo de dado.

A Figura 3 mostra o fluxo principal do algoritmo utilizado neste trabalho e descrito nas subseções anteriores. Mostrando desde o início, onde as características de usuários e restaurantes são modeladas, passando pelas etapas de cálculo de similaridade, distância entre usuários e restaurantes e cálculo do *score* (que determina a recomendação) e, por fim, sendo realizada a pós-filtragem baseada no novo tipo de dado sensível ao contexto do usuário para realizar a recomendação final.

Algorithm 1 Reorganize a lista de acordo com o motivo da ida ao restaurante

```
1: function reorganizaLista(lista, motivoDaIda)
2:   Crie uma nova lista vazia listaFinal
3:   for all elementos item em lista do
4:     Extraia a posição pos na lista usando item(motivoDaIda)
5:     Insira item em listaFinal de mantendo a ordem de acordo com pos
6:   end for
7:   Retorne listaFinal
8: end function
```

4.4 Experimento

O experimento tem como principal função explorar o desempenho e qualidade das recomendações do sistema de recomendação utilizando mais uma informação sensível ao contexto do usuário para recomendar os primeiros n restaurantes. Para isso, o dado *motivo da ida* que cada restaurante da base de dados possui é utilizado como parâmetro para uma pós-filtragem.

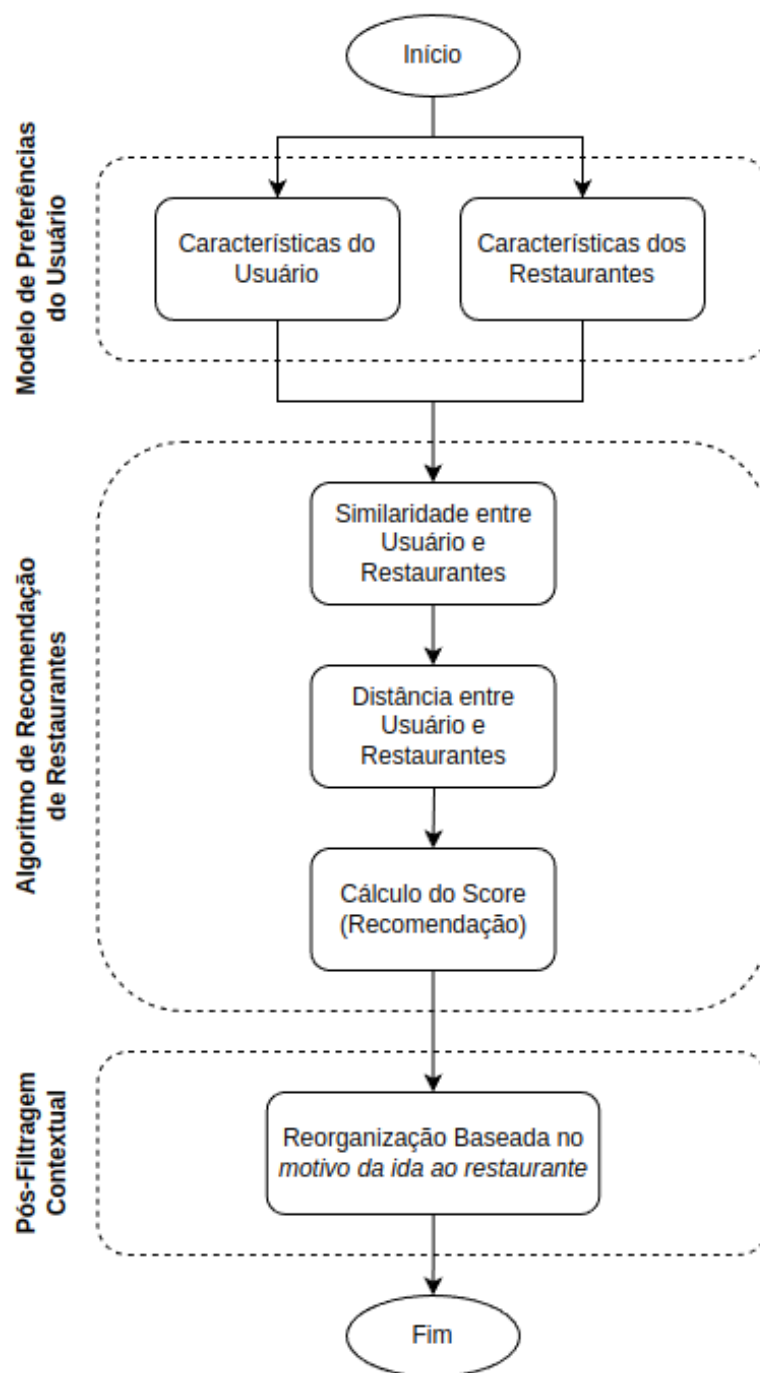


Figura 3 – Fluxo principal do novo funcionamento do algoritmo de recomendação

A Subseção 4.4.1 a seguir descreve como o experimento foi criado e seu funcionamento, na Subseção 4.4.2, os testes serão apresentados e na subsequente, Subseção 4.4.3, a coleta e análise dos questionários será descrita.

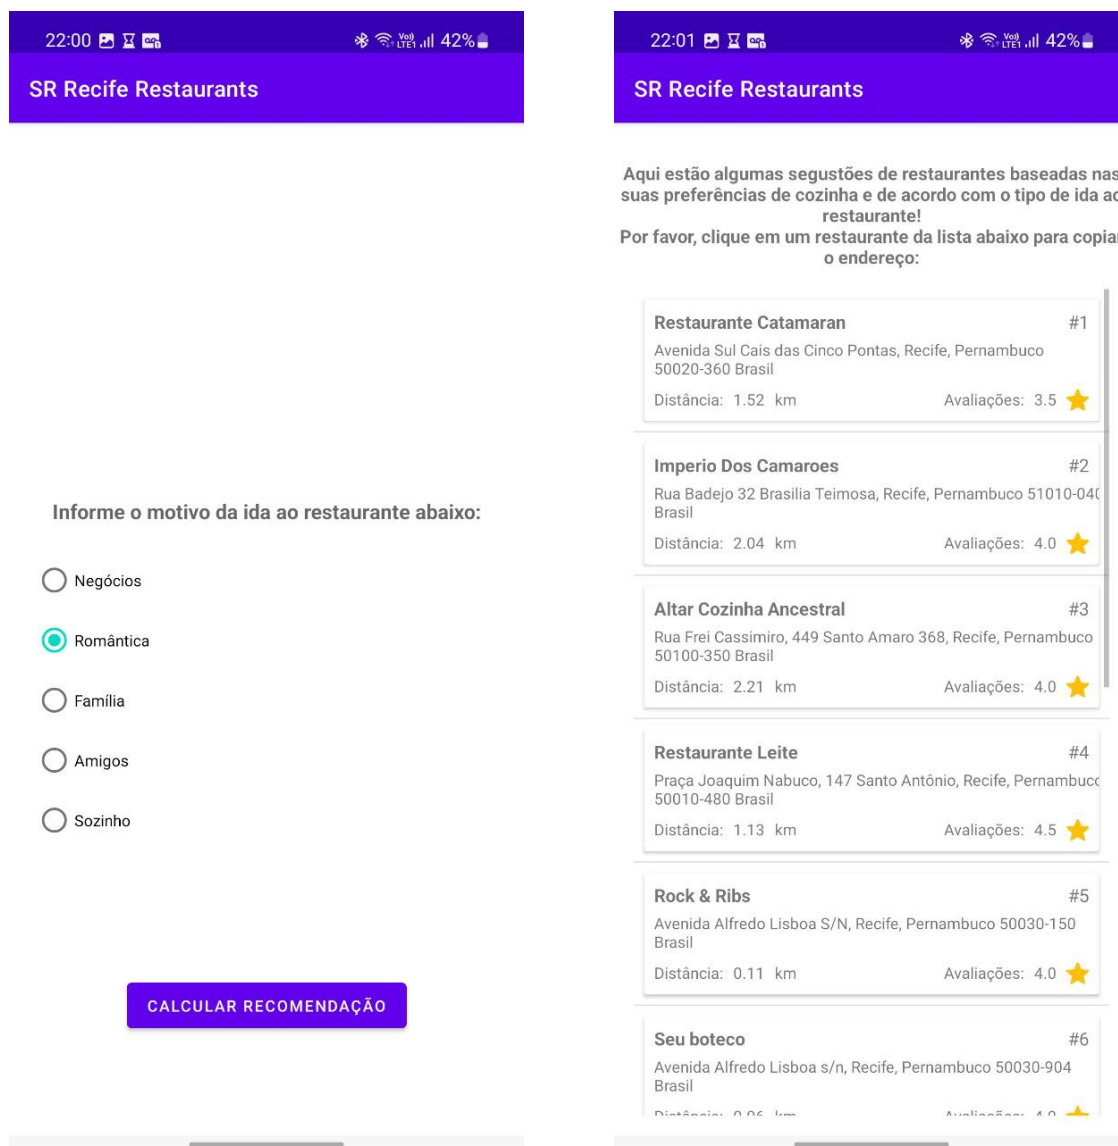
4.4.1 Descrição do Aplicativo *SR Recife Restaurants*

Com o objetivo de avaliar o proposto neste trabalho, um experimento foi elaborado onde o principal objetivo é averiguar o grau de satisfação dos usuários ao utilizar o sistema e, principalmente, as recomendações de restaurantes. Para isso foi desenvolvida uma aplicação móvel onde o algoritmo proposto em (ZENG et al., 2016) e apresentado na Seção 4.3 é utilizado e, posteriormente, uma pós-filtragem baseada no contexto *motivo da ida* é usada para realizar a recomendação final.

O sistema utilizado para as recomendações foi desenvolvido para *smartphones* que possuem o sistema operacional *Android*³ pois este é de fácil implementação e era o disponível para o autor durante o desenvolvimento da pesquisa (Figura 4).

O aplicativo, inicialmente, pede ao usuário para que permita o uso da localização do dispositivo (Figura 5, passo 1.) e, na mesma tela, selecione a quantidade desejada de tipos de cozinha - explanados na Tabela 3 - que o mesmo gosta ou tem interesse quando está procurando algum restaurante para realizar suas refeições (Figura 5, passo 2.). A partir da primeira tela, após selecionar pelo menos um item da lista, ao clicar em *PROSSEGUIR* (Figura 5, passo 2.1.) o usuário será redirecionado à tela que deverá selecionar o novo dado de contexto: motivo da ida ao restaurante (Figura 5, passo 3.). Vale salientar que nesta mesma tela, a localização, contendo latitude e longitude do GPS do usuário, estará sendo coletada enquanto ele seleciona o novo dado. Na tela de seleção do motivo da ida ao restaurante, o usuário deverá clicar no botão *CALCULAR RECOMENDAÇÃO* (Figura 5, passo 3.1.) para que o cálculo das recomendações sejam feitos pelo algoritmo (Figura 4a). Ao pressionar o botão, o usuário será redirecionado para uma terceira tela que expõe as recomendações de restaurantes, estas baseadas na seleção dos tipos de cozinha preferidos, na localização do GPS e no motivo da ida ao restaurante previamente coletados (Figura 5, passo 4.). A disposição das recomendações é em forma de lista, onde estarão presentes o nome, endereço, avaliação e posição do restaurante na lista de recomendações. Outro dado também presente para cada restaurante é a distância que o usuário está para o restaurante em quilômetros (Figura 4b). Para finalizar, o usuário deverá clicar no item escolhido, ou seja, ao clicar em uma recomendação de restaurante o sistema assumirá que o usuário frequentou aquele restaurante (Figura 5, passo 4.1.).

³ <https://www.android.com/intl/pt-BR_br/>



(a) Tela dos motivos da ida ao restaurante

(b) Tela da lista de recomendações

Figura 4 – Telas da aplicação SR Recife Restaurants

4.4.2 Descrição da Execução dos Testes

Para fins de avaliação e comparação dos algoritmos, foram realizadas duas rodadas de testes para cada usuário. Em cada rodada o usuário foi requisitado a executar as mesmas tarefas no fluxo do aplicativo, onde no final, na lista de recomendações, o resultado muda na segunda rodada de testes. A variação do resultado se deve ao fato do dado sensível ao contexto, *motivo da ida*, ser de fato inserido no cálculo da recomendação.

Ambas rodadas pedem para que o usuário percorra o fluxo descrito na subseção anterior, porém na primeira rodada, mesmo não sendo utilizado, o *motivo da ida* é coletado por parte do usuário para evitar enviesamento e diferenças na execução da segunda rodada, esta que utiliza o dado na pós filtragem.

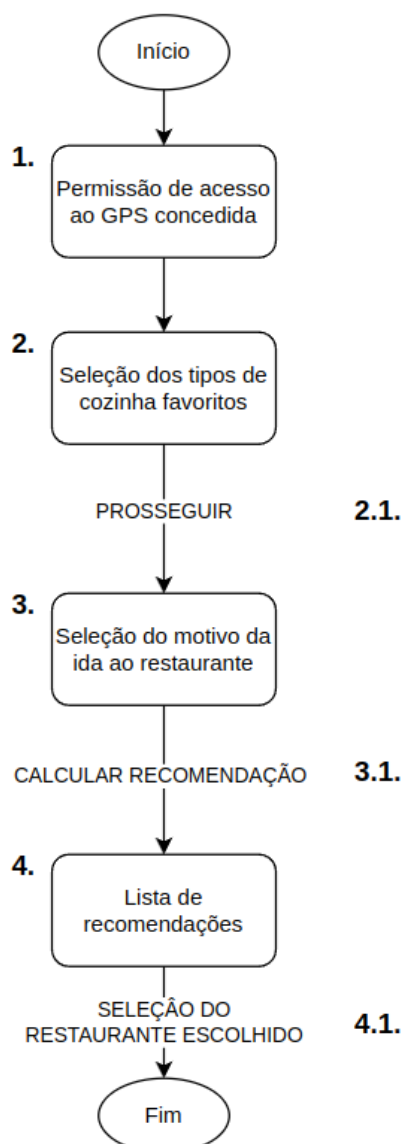


Figura 5 – Fluxo principal de execução do aplicativo *SR Recife Restaurants*

Para maior variedade de opções de recomendações de restaurantes, em cada rodada do experimento foram criados três cenários, utilizando localizações diferentes onde o usuário deverá se imaginar em uma situação elaborada e apresentada pelo autor, onde necessita utilizar a aplicação seguindo instruções. Os três cenários mencionados são apresentados a seguir:

- Cenário 1: *em um domingo, você está a passeio com a sua família no Marco Zero, quando decide que quer almoçar e gostaria de sugestões para escolher o restaurante.*
- Cenário 2: *é uma sexta-feira à noite, você mora próximo a pracinha de Boa Viagem e está marcando de encontrar alguns amigos que moram perto em algum barzinho. Você precisa de sugestões para decidir o bar.*

- Cenário 3: *cenário livre. Você pode escolher o motivo da ida ao restaurante/bar.*

Para os cenários 1 e 2 as localizações dos lugares foram fixadas no aplicativo para não haver divergência de valores e não necessitar que os usuários precisassem se deslocar para os locais indicados. Sendo o último cenário o que, de fato, utiliza o GPS do usuário. Além do mais, em todos cenários foi pedido ao usuário para que memorizasse suas escolhas desde a seleção dos tipos de cozinha preferidos, até o motivo da ida ao restaurante para uma comparação mais robusta e explícita entre as recomendações dos restaurantes.

Para finalizar os testes com o experimento, foi criado um formulário contendo questões pertinentes à usabilidade e grau de satisfação dos usuários em relação ao aplicativo *SR Recife Restaurants*. Sendo este questionário respondido apenas uma vez, ao término de ambas rodadas. O questionário será apresentado na subseção seguinte.

4.4.3 Coleta e Análise das Avaliações dos Questionários

O primeiro passo para avaliar o sistema de recomendação de restaurantes proposto neste trabalho foi definir que fatores serão avaliados pelos usuários. Como o trabalho propõe um sistema sensível ao contexto do usuário, as técnicas de avaliação online definidas em (KNIJNENBURG et al., 2015) foram escolhidas. Previamente definidas na Seção 2.2.2.1, essas técnicas são voltadas para investigar a satisfação dos usuários em relação ao sistema proposto, neste caso o aplicativo *SR Recife Restaurants*.

Para a avaliação do sistema deste trabalho foram escolhidos seis aspectos que serão analisados seguindo as técnicas de avaliação online mencionadas anteriormente:

1. OSA - avaliar o quão satisfeitos estão os usuários ao receber as recomendações dos restaurantes feitas pelos algoritmos.
2. SSA - avaliar se a quantidade total de recomendações estava satisfatória. E, se a qualidade de recomendações de restaurantes foram satisfatórias.
3. EXP - mensurar o que levou o usuário a tomar a decisão de escolha do restaurante. Tendo como opções o nome do restaurante, endereço, distância, avaliação do restaurante, posição na lista de recomendação e se o usuário já conhecia o restaurante selecionado.
4. INT - avaliar o grau de dificuldade que o usuário experienciou ao interagir com as recomendações feitas pelo sistema.

5. SC - averiguar o grau de confiança que o usuário tem nas recomendações de restaurantes feitas pelo sistema.
6. PC - Em qual posição, dos itens da lista de recomendação, o usuário clicou mais. Significando que selecionou o restaurante para visitar.

Para coletar as respostas dos usuários, foi elaborado um questionário (Apêndice C) contendo no total doze perguntas. Sendo duas perguntas para cada aspecto descrito anteriormente, ou seja, seis para cada rodada executada pelo usuário. Ao final das 12 perguntas, uma seção de comentário não obrigatório foi deixado como opção para os usuários anotarem qualquer sugestão ou reclamação acerca da sua experiência.

Um teste estatístico sobre as respostas coletadas do questionário foi utilizado para estabelecer um nível de confiança sobre alguns dos aspectos definidos anteriormente. O teste tem como principal objetivo responder se há diferença significativa entre o grau de satisfação e se há diferença significativa entre o grau de confiança para os usuários durante a Rodada 1 e Rodada 2. Para realizar a validação das hipóteses o Teste T de Student foi utilizado (MAZHOU et al., 2021).

Na Rodada 1, o trabalho utilizado como base (ZENG et al., 2016) foi executado e na Rodada 2, a proposta deste trabalho, com a adição de um novo dado sensível ao contexto do usuário na pós-filtragem foi executado.

Para coletar as avaliações relacionada ao aspecto PC, o autor deste trabalho ficou como observador enquanto os usuários interagiram com o sistema, tomando notas de interações, quantidades de cliques e rolagem de itens da lista.

5 Resultados

Neste capítulo serão apresentados os resultados dos questionários que foram utilizados para coletar as avaliações dos usuários em relação à sua experiência ao interagir com sistema *SR Recife Restaurants*. Como explicado na Subseção 4.4.3, do capítulo anterior, os questionários foram elaborados seguindo as técnicas de avaliação propostas em (KNIJNENBURG et al., 2015) para examinar o grau de satisfação dos usuários em relação às recomendações de restaurantes feitas pelo sistema.

Lembrando que as rodadas apresentadas a seguir foram desenvolvidas da seguinte maneira: na Rodada 1, o trabalho proposto em (ZENG et al., 2016) utilizado como base foi implementado; e, na Rodada 2, este trabalho foi implementado.

Este capítulo está dividido da seguinte maneira: a Seção 5.1 expõe os resultados dos questionários obtidos após a interação com o sistema, enquanto a Seção 5.2 discute esses resultados coletados e, por fim, a Seção 5.3 as considerações finais são apresentadas.

5.1 Avaliação dos Dados do Questionário

Os dados foram coletados de 15 participantes do experimento do sistema, sendo suas idades variando entre 25 e 62 anos, onde 9 participantes tinham idade entre 25 e 30 anos. Em relação ao gêneros dos participantes o gráfico de pizza ilustrado na Figura 6 apresenta a proporção.



Figura 6 – Gênero dos participantes do experimento

Como os dados relacionados às respostas coletadas se referem aos fatores subjetivos elencados na Subseção 4.4.3, para realizar a medição desses fatores a escala de cinco pontos de Likert foi utilizada (BRAUNHOFER et al., 2014). A escala contém cinco opções de escolha e varia entre o menor grau de satisfação, passando

pela opção neutra e atingindo o maior grau de satisfação, oferecendo ao usuário apenas uma única opção de escolha para cada pergunta. A seguir serão apresentados os dados obtidos.

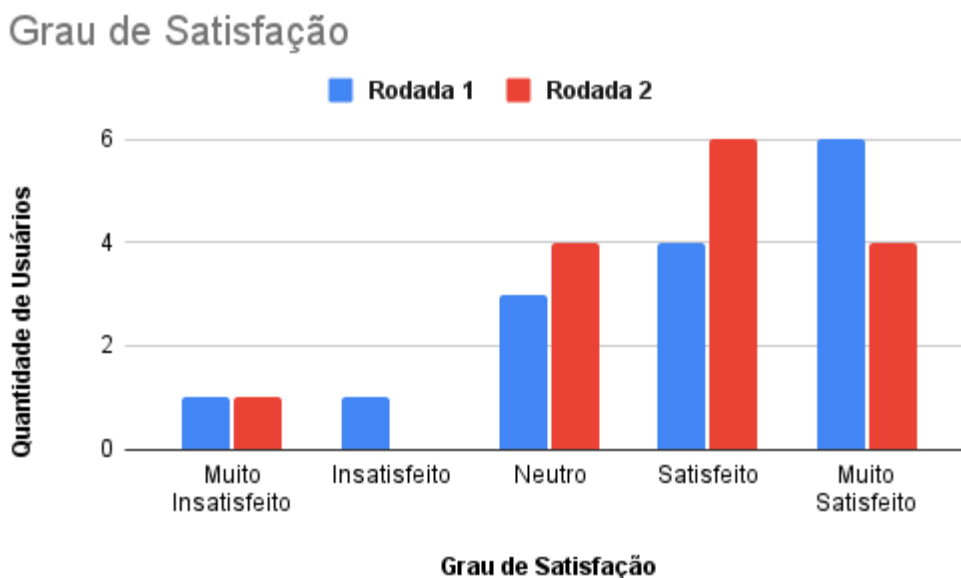


Figura 7 – Grau de satisfação dos usuários

Para o componente de avaliação OSA (Aspectos Objetivos do Sistema), que visa avaliar o grau de satisfação dos usuários ao receber as recomendações dos restaurantes pelo algoritmo, os graus de satisfação para Rodadas 1 e 2 são mostrados na Figura 7. Como pode-se observar, o grau de satisfação dos usuários foi praticamente o mesmo durante as duas rodadas do experimento para a maioria dos usuários, variando entre satisfeito e muito satisfeito.

Seguindo para o próximo fator de avaliação, SSA (Aspectos Subjetivos do Sistema), que tem como objetivo avaliar se a quantidade total de recomendações de restaurantes foi satisfatória. O gráfico que ilustra esse aspecto se encontra na Figura 8. A quantidade de itens recomendados varia entre dez e treze recomendações, diante disso nota-se que a quantidade total de recomendações feita pelo sistema, foi satisfatória para a grande maioria dos usuários durante ambas rodadas.

Opinião Sobre a Quantidade Total de Recomendações

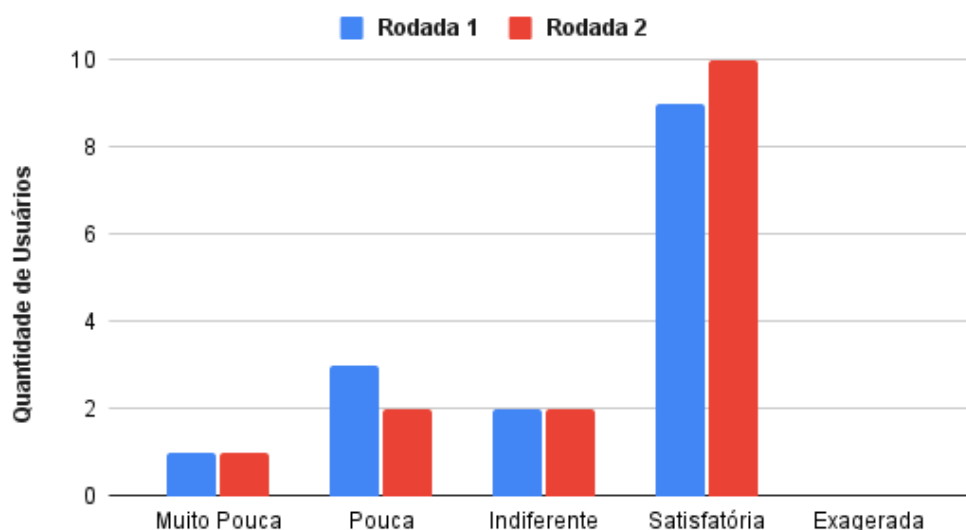


Figura 8 – Opinião sobre a quantidade total de recomendações

Ainda se referindo ao fator SSA, o grau de satisfação sobre a qualidade das recomendações dos algoritmos também foi averiguado e está desenhado na Figura 9.

Grau de Satisfação sobre a Qualidade das Recomendações




Figura 9 – Grau de satisfação sobre a qualidade das recomendações

O componente de avaliação EXP (Experiencia do Usuário) mensura a tomada de decisão do usuário ao escolher um restaurante recomendado pelo sistema. As opções elencadas para seleção do item foram: nome do restaurante, endereço, distância, avaliação do restaurante, posição na lista de recomendação e se o usuário já conhecia o restaurante selecionado. A Figura 10 apresenta os dados coletados. Para esse

aspecto pode-se verificar que fatores como nome, quantidade de avaliações e restaurante já conhecido pelo usuário foram fatores decisivos na escolha da recomendação. Em contraste, tem-se o endereço onde apresentou menor quantidade de votos para a escolha final.

Quantitativo de Aspectos para Escolha do Restaurante

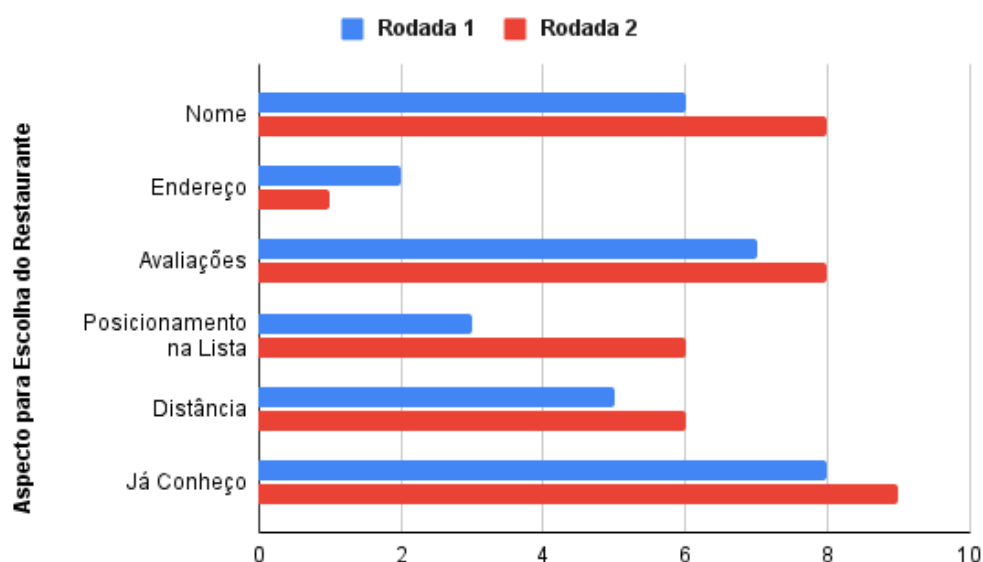



Figura 10 – Aspectos para escolha do restaurante recomendado


O fator INT (Interação) avalia o grau de dificuldade do usuário ao interagir com as recomendações de restaurantes feitas pelo sistema. As imagens Figura 11a e Figura 11b mostram a opinião dos usuários sobre o grau de dificuldade ao interagir com o sistema em relação às Rodadas 1 e 2, respectivamente.

Rodada 1



(a) Durante a Rodada 1

Rodada 2



(b) Durante a Rodada 2

Figura 11 – Grau de dificuldade ao interagir com o sistema

Para averiguar o grau de confiança que o usuário tem em relação às recomendações feitas pelo sistema, o fator SC (Características Situacionais) foi utilizado. Os

gráficos que ilustram esse fator foram desenhados nas Figura 12a e Figura 12b para cada rodada do experimento.




Figura 12 – Grau de confiança em relação às recomendações feitas pelo sistema

Para medir o fator PC, foi necessária observação da interação do usuário com o sistema por parte do autor. Para isso, a posição dos itens da lista de recomendação que o usuário clicou mais vezes, significando que selecionou o restaurante para visitaç o, foi observada. Para a Rodada 1 e Rodada 2 (trabalho base e o proposto neste trabalho respectivamente), os cen rios descritos na Subseç o 4.4.2 foram utilizados nos experimento. Sendo assim, a Tabela 6 mostra a porcentagem de seleç o dos itens que estavam sendo sugeridos entre as cinco primeiras recomendações para cada cen rio.

Tabela 6 – Porcentagem dos usu rios que clicaram nas top-5 recomendações

Cen�rios	Rodada 1	Rodada 2
Cen�rio 1	80%	73,33%
Cen�rio 2	40%	66,67%
Cen�rio 3	66,67%	73,33%

Fonte: O autor

Tamb m foi poss vel coletar e realizar a contagem do dado motivo da ida ao restaurante que foi selecionado pelos usu rios durante o Cen rio 3 em ambas rodadas. Pelo apresentado na Figura 13, pode-se observar que os tipos de ida mais selecionados foram “Rom ntica”, “Sozinho” e “Fam lia”.



Figura 13 – Contagem dos motivos da ida seleccionados durante o experimento

A partir da seção de comentários não opcional foi possível notar alguns comentários que relatam queixas dos usuários em relação ao sistema como um todo:

- Três comentários informaram que os restaurantes indicados na recomendação não estão mais operando ou existem restaurantes na região que não estão sendo sugeridos. Outro comentário informou que os restaurantes recomendados foram, considerados pelo usuário, mais conceituados e caros, onde o mesmo relatou que existiam mais opções em conta e menos conhecidos naquela região.
- Em relação a restaurantes de culinária vegetariana, houve um comentário que informou não encontrar esse tipo de cozinha na primeira tela de seleção de tipos de cozinha preferidos. Fazendo com que o usuário selecionasse o tipo “saudável” pois era algo mais parecido com o que ele esperava.
- Dois comentários exaltaram a quantidade excessiva de tipos de cozinha relacionados à culinária oriental/asiática. Os usuários relataram que existem muitas opções e que todas elas poderiam ser reduzidas à apenas oriental/asiática.
- Também houveram queixas em relação à quantidade de tipos de culinária na primeira interação com o aplicativo. Alguns usuários acharam que foram muitos itens para ser selecionados.
- Por fim, um comentário enalteceu a falta de informações sobre os restaurantes recomendados devido ao fato do usuário ser um turista de outro estado e não conhecer a região e/ou restaurantes.

5.2 Discussão

Neste trabalho foi realizada a implementação de uma aplicação móvel – *RS Recife Restaurants* – que recomenda restaurantes, com o intuito de analisar o algoritmo proposto em (ZENG et al., 2016), adicionando um novo tipo de dado de contexto sensível ao usuário, o motivo da ida ao restaurante, utilizando em uma pós-filtragem baseada em contexto como paradigma de incorporação de contexto.

Para analisar os graus de satisfação em relação aos aspectos OSA e SSA entre as duas rodadas do experimento, sendo a Rodada 1 o sistema sugerido no trabalho base e a Rodada 2 o proposto neste trabalho, foi necessário calcular o Teste t de Student. Tendo $p = 0,1654$ como resultado do cálculo conclui-se que, devido a p ser menor que 0.05 (nível de significância), não há diferença significativa entre o grau de satisfação para as duas rodadas do experimento. Então, como as médias dos graus de satisfação foram ≈ 4 para ambas Rodada 1 e Rodada 2, pode-se inferir que o grau de satisfação para os aspectos OSA e SSA foi satisfatório para os usuários.

Esses aspectos mediram grau de satisfação ao receber recomendações, quantidade e qualidade das recomendações de restaurantes feitas pelo sistema. Por outro lado, ainda analisando os aspectos OSA e SSA, apesar de satisfatório no geral, alguns fatores como o fato do restaurante não estar mais em funcionamento, tipos de cozinha não presentes na lista de preferências inicial e quantidade excessiva de tipos de cozinha geraram certa insatisfação para os usuários.

Levando em consideração o fator INT, do ponto de vista de 66,7% dos usuários, o sistema proposto foi de fácil utilização em ambas rodadas propostas no experimento. Esse valor tem relação direta em como a aplicação *SR Recife Restaurants* e o experimento deste trabalho foram desenvolvidos. Como o sistema se propõe a apenas coletar as preferências do usuário e realizar as recomendações de restaurantes, não apresentando outros tipos de interações e tomadas de decisão para o usuário, o sistema acaba sendo simples e com apenas um objetivo. Talvez esses fatores levaram os usuários a considerar o sistema amigável e de fácil interação.

Analisando o fator SC, assim como feito para os aspectos OSA e SSA anteriormente, foi realizado o teste estatístico Teste t de Student. Obteve-se $p = 0,449$, sendo assim, também não houve uma diferença significativa entre o grau de confiança das recomendações entre as duas rodadas. Sendo as médias das avaliações obtidas dos questionários ≈ 4 para ambas Rodada 1 e Rodada 2, conclui-se que os usuários confiam de modo geral nas recomendações de restaurantes.

Outro ponto ao analisar o fator SC é que, para a Rodada 1, 86,7% dos usuários classificaram que as recomendações de restaurantes feitas pelo sistema são confiáveis. Já na Rodada 2, o sistema proposto por este trabalho obteve uma parcela maior

de confiança, com 97% dos votos classificando o sistema como confiável. Um aumento de 10,3% em relação ao trabalho base.

Para o aspecto PC observou-se que houve um aumento na escolha de restaurantes, presentes nas top-5 (cinco primeiras) recomendações da lista, por parte dos usuários durante a Rodada 2, com o uso do dado *motivo da ida*. Por exemplo, no Cenário 2 da Tabela 6 é possível notar que o aumento foi de 26,67% para a Rodada 2 em relação à Rodada 1. Esse aumento na escolha talvez ocorra pelo fato desse cenário simular horário e local com estabelecimentos mais conhecidos por parte dos usuários, visto que o cenário sugere bares noturnos na região do bairro de Boa viagem.

Considerando o conteúdo da base de dados utilizada para compor o conjunto de dados deste trabalho, composta por dados extraídos da API do TripAdvisor, é importante destacar que alguns dados de restaurantes desatualizados, dados descalibrados e não compatíveis com o dia-a-dia dos usuários tenha contribuído para as avaliações negativas em relação ao sistema para ambas rodadas do experimento.

Outro fator de grande importância para os resultados deste trabalho foi a quantidade de usuários participantes no experimento. Por se tratar de um sistema de recomendação que utiliza o método de avaliação online, segundo esclarecido em (ZANGERLE et al., 2022), o custo de fazer testes com usuários reais é alto dado que precisa-se alocar tempo para motivar, apresentar e realizar o experimento com os usuários.

Ainda se tratando dos usuários, um ponto de discussão é o perfil do usuário que está interagindo com o sistema. Com o experimento foi possível notar que usuários menos experientes, com idade superior a 35 anos, demoravam mais tempo analisando a lista de restaurantes recomendados, bem como não se sentiam confortáveis ao informar certos tipos de dados (idade no questionário, motivo da ida e localização). Também foi possível notar que esses usuários não conheciam muito bem os restaurantes recomendados, escolhendo-os de acordo com a distância e com a quantidade de avaliações.

5.3 Considerações Finais

Neste capítulo foram discutidos e analisados os resultados obtidos pelos experimentos que foram realizados com usuários reais. Os experimentos visaram comparar a adição de um novo tipo de dado sensível ao contexto do usuário, o motivo da ida ao restaurante, para melhorar a lista de recomendação de restaurantes final. No próximo capítulo este trabalho será concluído e também serão apresentadas as principais limitações e os possíveis trabalhos futuros a partir deste trabalho.

6 Conclusão

O objetivo geral deste trabalho foi avaliar o sistema proposto em (ZENG et al., 2016) com a adição de um novo dado sensível ao contexto do usuário para realizar recomendações de restaurantes.

O novo dado adicionado ao sistema foi o *motivo da ida*, presente na API do TripAdvisor para restaurantes. Esse dado foi incorporado ao sistema de recomendação utilizando a pós-filtragem baseada em contexto como paradigma de incorporação de contexto. Criando, assim, o *SR Recife Restaurants*, uma aplicação móvel para *smartphones* cujo sistema operacional é o *Android*.

O experimento foi executado com a participação de 15 usuários onde os resultados foram coletados a partir de questionários e observação da interação do usuário com a aplicação móvel por parte do autor. Foram realizadas duas rodadas com finalidade de comparação entre o trabalho base e o proposto neste trabalho, onde o grau de satisfação dos usuários foi medido e avaliado.

A partir dos resultados coletados foi possível observar que o grau de satisfação ao utilizar o *SR Recife Restaurants* foi considerado satisfatório e de fácil utilização por parte dos usuários. Também foi analisado que os usuários classificaram o trabalho proposto como confiável, tendo um aumento de 10,3% no grau de confiança em relação ao trabalho base. Em relação à escolha das recomendações, houve um aumento de 26,67% ao utilizar o trabalho proposto. Esse aumento se refere aos cinco primeiros restaurantes recomendados na lista da aplicação.

6.1 Limitações

As limitações deste trabalho estão listadas a seguir:

- Poucos usuários participantes do experimento, resultando em pouca variedade de dados para análise do grau de satisfação.
- Conjunto de dados limitado com pouca variedade de restaurantes.
- Base de dados desatualizada com restaurantes fechados em relação ao momento atual deste trabalho.

6.2 Trabalhos Futuros

Dentre as sugestões de trabalhos futuros, pode-se elencar:

- Construir e utilizar uma nova base de dados mais completa, abrangendo a variedade de restaurantes e restaurantes com dados atualizados.
- Utilizar e agregar mais dados de contexto como, por exemplo, clima e horário na hora da recomendação.
- Testar outros dados de contexto com novos paradigmas de para incorporação de contexto.
- Executar o experimento com outra técnica de cálculo de similaridade de preferências.
- Traçar perfis de usuários a partir de seus dados de uso do sistema.
- Inferir motivo da ida ao restaurante de acordo com perfis de usuários.
- Aprimorar a aplicação móvel fornecendo mais detalhes em relação ao restaurantes para os usuários.
- Adicionar à aplicação móvel um mapa para melhor visualização dos restaurantes recomendados.

Referências

- ADOMAVICIUS, G. et al. Context-aware recommender systems. *AI Magazine*, v. 32, n. 3, p. 67–80, Oct. 2011. Disponível em: <<https://ojs.aaai.org/aimagazine/index.php/aimagazine/article/view/2364>>. Citado 2 vezes nas páginas 18 e 19.
- AFSAR, M. et al. Reinforcement learning based recommender systems: A survey. *ACM Computing Surveys*, v. 55, 06 2022. Citado na página 12.
- ANDERSON, C. A survey of food recommenders. *arXiv preprint arXiv:1809.02862*, 2018. Citado na página 13.
- ASANI, E. et al. Restaurant recommender system based on sentiment analysis. *Machine Learning with Applications*, v. 6, p. 100114, 2021. ISSN 2666-8270. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2666827021000578>>. Citado 3 vezes nas páginas 24, 30 e 31.
- BLACK, J. et al. Retiree volunteerism: Automating “word of mouth” communication. *SOCIALIZE 2023*, 2023. Citado na página 12.
- BRAUNHOFER, M. et al. Usability assessment of a context-aware and personality-based mobile recommender system. In: . [S.l.: s.n.], 2014. v. 188, p. 77–88. ISBN 978-3-319-10490-4. Citado na página 45.
- BURKE, R. Hybrid web recommender systems. In: _____. *The Adaptive Web: Methods and Strategies of Web Personalization*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. p. 377–408. ISBN 978-3-540-72079-9. Disponível em: <https://doi.org/10.1007/978-3-540-72079-9_12>. Citado na página 18.
- BURKE, R. et al. Recommender systems: An overview. *AI Magazine*, v. 32, n. 3, p. 13–18, Jun. 2011. Disponível em: <<https://ojs.aaai.org/aimagazine/index.php/aimagazine/article/view/2361>>. Citado na página 16.
- CAÑAMARES, R. et al. Offline evaluation options for recommender systems. *Information Retrieval Journal*, Springer, v. 23, n. 4, p. 387–410, 2020. Citado na página 20.
- CHU, T.-W. et al. A hybrid recommendation system considering visual information for predicting favorite restaurants. *World Wide Web*, v. 20, 11 2017. Citado 3 vezes nas páginas 25, 30 e 31.
- DACREMA, M. F. et al. Are we really making much progress? a worrying analysis of recent neural recommendation approaches. In: *Proceedings of the 13th ACM conference on recommender systems*. [S.l.: s.n.], 2019. p. 101–109. Citado na página 14.
- FAKHRI, A. et al. Restaurant recommender system using user-based collaborative filtering approach: A case study at bandung raya region. *Journal of Physics: Conference Series*, v. 1192, p. 012023, 03 2019. Citado 3 vezes nas páginas 27, 30 e 31.

- GOMATHI, R. et al. Restaurant recommendation system for user preference and services based on rating and amenities. In: *2019 International Conference on Computational Intelligence in Data Science (ICCIDIS)*. [S.l.: s.n.], 2019. p. 1–6. Citado 3 vezes nas páginas 24, 30 e 31.
- HERLOCKER, J. et al. Evaluating collaborative filtering recommender systems. *ACM Transactions on Information Systems*, v. 22, p. 5–53, 01 2004. Citado na página 21.
- HERSE, S. et al. Do you trust me, blindly? factors influencing trust towards a robot recommender system. In: *2018 27th IEEE International Symposium on Robot and Human Interactive Communication (RO-MAN)*. [S.l.: s.n.], 2018. p. 7–14. Citado 3 vezes nas páginas 28, 30 e 31.
- KANNOUT, E. Context clustering-based recommender systems. In: . [S.l.: s.n.], 2020. p. 85–91. Citado na página 38.
- KNIJNENBURG, B. P. et al. Evaluating recommender systems with user experiments. In: _____. *Recommender Systems Handbook*. Boston, MA: Springer US, 2015. p. 309–352. Disponível em: <https://doi.org/10.1007/978-1-4899-7637-6_9>. Citado 5 vezes nas páginas 12, 13, 22, 43 e 45.
- KOETPHROM, N. et al. Comparing filtering techniques in restaurant recommendation system. In: *2018 2nd International Conference on Engineering Innovation (ICEI)*. [S.l.: s.n.], 2018. p. 46–51. Citado 3 vezes nas páginas 26, 30 e 31.
- KONSTAN, J. et al. Recommender systems: From algorithms to user experience. *User Modeling and User-Adapted Interaction*, v. 22, p. 101–123, 04 2012. Citado na página 14.
- KOREN, Y. et al. Matrix factorization techniques for recommender systems. *Computer*, v. 42, n. 8, p. 30–37, 2009. Citado na página 16.
- KUMAR, A. et al. Analysis of ga optimized ann for proactive context aware recommender system. In: _____. [S.l.: s.n.], 2018. p. 92–102. ISBN 978-3-319-76350-7. Citado 3 vezes nas páginas 26, 30 e 31.
- LI, L. et al. Collaborative filtering based on user attributes and user ratings for restaurant recommendation. In: *2017 IEEE 2nd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*. [S.l.: s.n.], 2017. p. 2592–2597. Citado 3 vezes nas páginas 27, 30 e 31.
- LU, J. et al. Recommender system application developments: A survey. *Decision Support Systems*, v. 74, p. 12–32, 2015. ISSN 0167-9236. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0167923615000627>>. Citado 3 vezes nas páginas 12, 16 e 18.
- MARIA, E. et al. Measure distance locating nearest public facilities using haversine and euclidean methods. *Journal of Physics: Conference Series*, v. 1450, p. 012080, 02 2020. Citado na página 37.
- MAZHOUD, O. et al. Educational recommender system based on learner’s annotative activity. *International Journal of Emerging Technologies in Learning*, v. 16, n. 10, 2021. Citado na página 44.

MONTEIRO, X. *AVALIAÇÃO DO SISTEMA CD-CARS COM EXPERIMENTOS FOCADOS EM USUÁRIOS*. 2017. Citado 2 vezes nas páginas 7 e 22.

MUSTAFA, A. A. et al. Recommendation system based on item and user similarity on restaurants directory online. In: *2018 6th International Conference on Information and Communication Technology (ICoICT)*. [S.l.: s.n.], 2018. p. 70–74. Citado 3 vezes nas páginas 27, 30 e 31.

NAWARA, D. et al. Context-aware recommendation systems in the iot environment (iot-cars)—a comprehensive overview. *IEEE Access*, v. 9, p. 144270–144284, 01 2021. Citado 3 vezes nas páginas 7, 14 e 20.

PENG, Y. A survey on modern recommendation system based on big data. *arXiv preprint arXiv:2206.02631*, 2022. Citado na página 12.

PU, P. et al. A user-centric evaluation framework of recommender systems. *CEUR Workshop Proceedings*, v. 612, 01 2011. Citado na página 21.

RICCI, F. et al. Introduction to recommender systems handbook. In: _____. *Recommender Systems Handbook*. Boston, MA: Springer US, 2011. p. 1–35. ISBN 978-0-387-85820-3. Disponível em: <https://doi.org/10.1007/978-0-387-85820-3_1>. Citado 2 vezes nas páginas 16 e 18.

SALEHAN, M. et al. A recommender system for restaurant reviews based on consumer segment. 2017. Citado na página 12.

SHAMBOUR, Q. Y. et al. Restaurant recommendations based on multi-criteria recommendation algorithm. *Journal of Universal Computer Science*, v. 29, n. 2, 2023. Citado 3 vezes nas páginas 26, 30 e 31.

SHANI, G. et al. Evaluating recommendation systems. In: _____. *Recommender Systems Handbook*. Boston, MA: Springer US, 2011. p. 257–297. Disponível em: <https://doi.org/10.1007/978-0-387-85820-3_8>. Citado 2 vezes nas páginas 20 e 21.

SINGH, R. et al. Movie recommendation system using cosine similarity and knn. *International Journal of Engineering and Advanced Technology*, v. 9, p. 2249–8958, 06 2020. Citado na página 36.

SUN, L. et al. Applying uncertainty theory into the restaurant recommender system based on sentiment analysis of online chinese reviews. *World Wide Web*, v. 22, 01 2019. Citado 3 vezes nas páginas 25, 30 e 31.

VERAS, D. et al. Cd-cars: Cross-domain context-aware recommender systems. *Expert Systems with Applications*, v. 135, 06 2019. Citado 3 vezes nas páginas 13, 18 e 19.

VILLEGAS, N. M. et al. Characterizing context-aware recommender systems: A systematic literature review. *Knowledge-Based Systems*, v. 140, p. 173–200, 2018. ISSN 0950-7051. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0950705117305075>>. Citado na página 13.

WANG, L. et al. Context-aware drive-thru recommendation service at fast food restaurants. 10 2020. Citado 3 vezes nas páginas 28, 30 e 31.

ZANGERLE, E. et al. Evaluating recommender systems: Survey and framework. Association for Computing Machinery, New York, NY, USA, v. 55, n. 8, dec 2022. ISSN 0360-0300. Disponível em: <<https://doi.org/10.1145/3556536>>. Citado 2 vezes nas páginas 21 e 52.

ZENG, J. et al. A restaurant recommender system based on user preference and location in mobile environment. In: *2016 5th IIAI International Congress on Advanced Applied Informatics (IIAI-AAI)*. [S.l.: s.n.], 2016. p. 55–60. Citado 18 vezes nas páginas 12, 13, 14, 28, 29, 30, 31, 32, 34, 35, 36, 37, 38, 40, 44, 45, 51 e 53.

ZHANG, S. et al. A recommender system for cultural restaurants based on review factors and review sentiment. 2018. Citado 3 vezes nas páginas 25, 30 e 31.

ZHENG, Y. Context-aware mobile recommendation by a novel post-filtering approach. In: . [S.l.: s.n.], 2018. Citado na página 14.

Apêndices

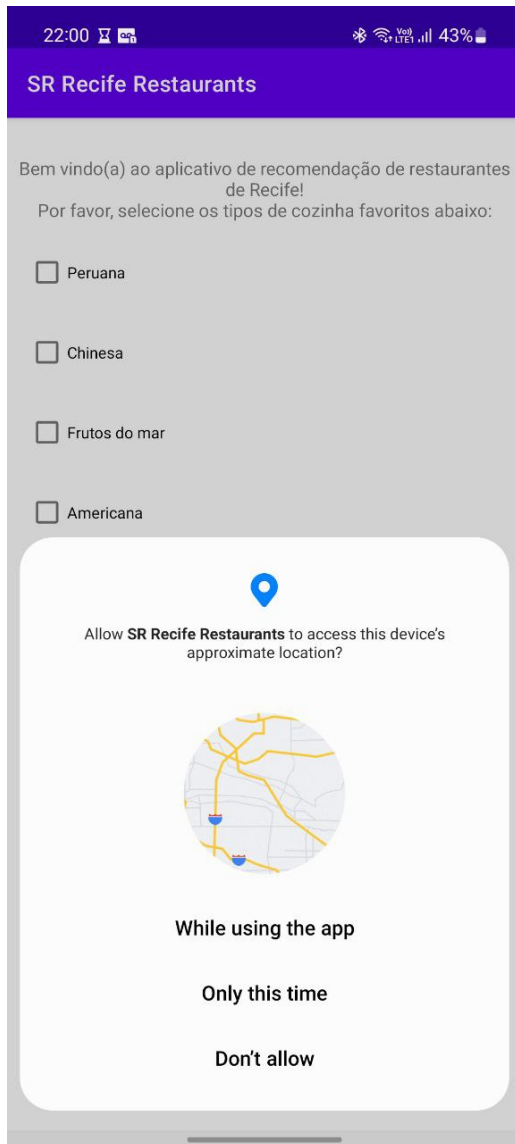
APÊNDICE A – Exemplo dos dados coletados da plataforma TripAdvisor

```
{
  "name": "Guaiamum Gigante",
  "address_string": "Rua Doutor Jose de Goes 299, Recife, Pernambuco 52060-380
    Brasil",
  "latitude": "-8.036143",
  "longitude": "-34.910084",
  "cuisine": [
    {
      "name": "brazilian",
      "localized_name": "Brasileira"
    },
    {
      "name": "bar",
      "localized_name": "Bar"
    },
    {
      "name": "seafood",
      "localized_name": "Frutos do mar"
    }
  ],
  "trip_types": [
    {
      "name": "business",
      "localized_name": "Negócios",
      "value": "16"
    },
    {
      "name": "couples",
      "localized_name": "Romântica",
      "value": "35"
    },
    {
      "name": "solo",
      "localized_name": "Viagem a sós",
```

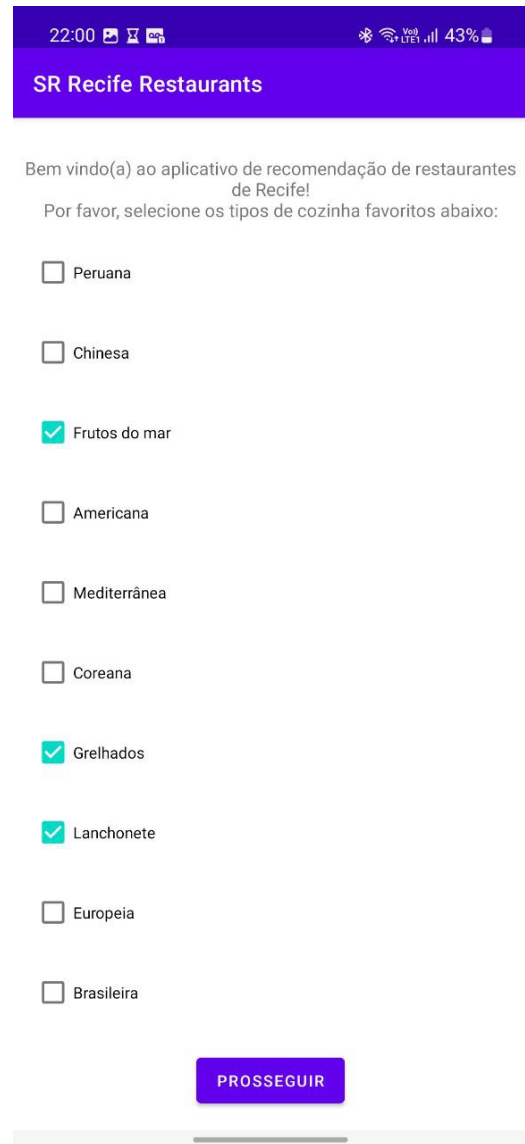
```
    "value": "5"
  },
  {
    "name": "family",
    "localized_name": "Família",
    "value": "81"
  },
  {
    "name": "friends",
    "localized_name": "Viagem com amigos",
    "value": "98"
  }
]
}
```

APÊNDICE B – Telas da aplicação móvel

SR Recife Restaurants

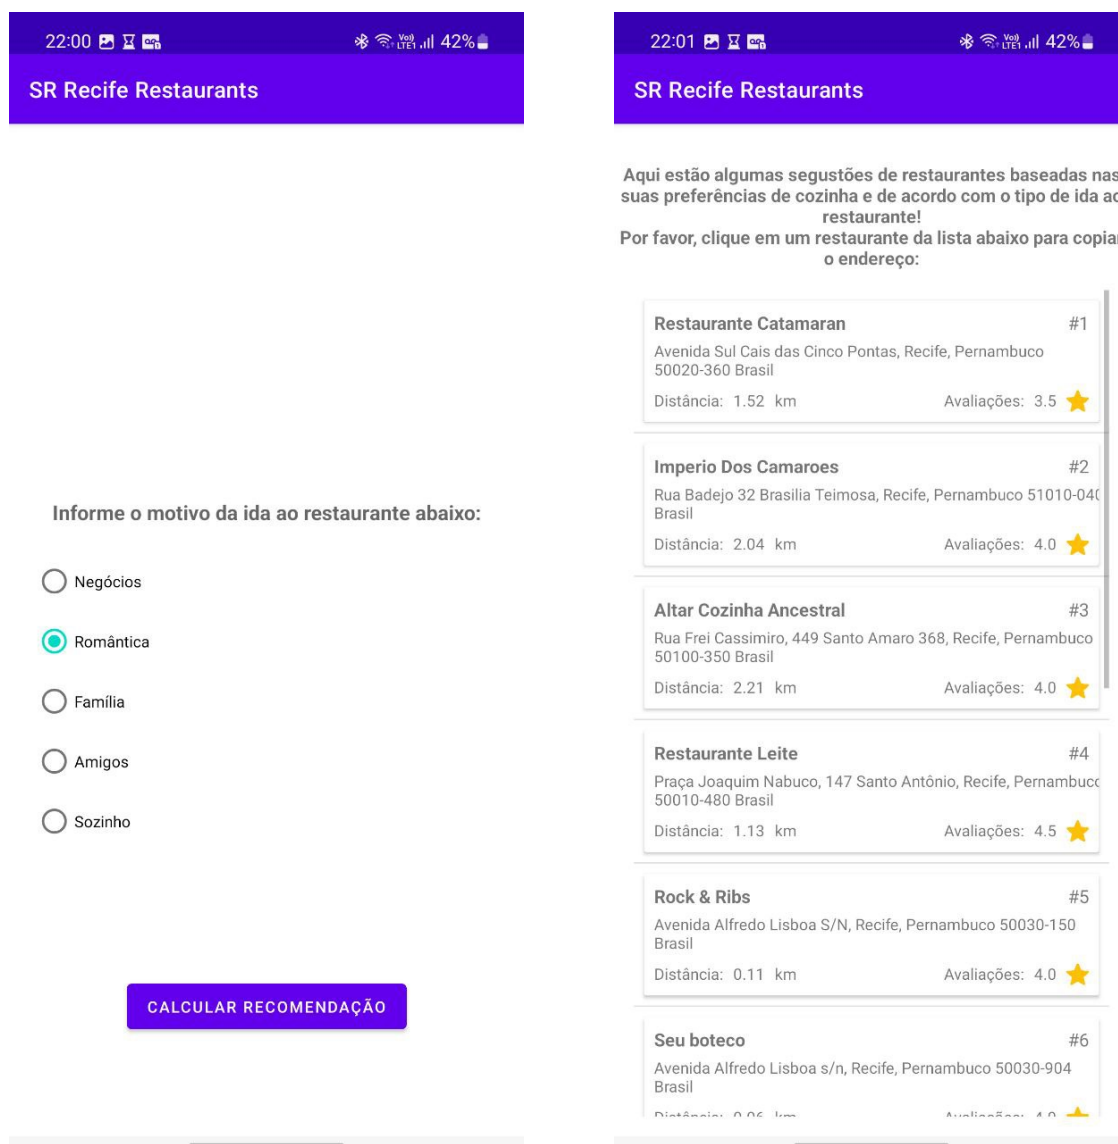


(a) Tela de permissão para usar GPS



(b) Tela com lista de tipos de cozinha

Figura 14 – Telas da aplicação *SR Recife Restaurants* (parte 1)



(a) Tela do motivo da ida ao restaurante

(b) Tela da lista de recomendações

Figura 15 – Telas da aplicação SR Recife Restaurants (parte 2)

APÊNDICE C – Questionário utilizado para coletar avaliações dos usuários

Questionário de avaliação do aplicativo SR Recife Restaurants

Bem vindo(a) ao formulário de avaliação do aplicativo SR Recife Restaurants. O questionário abaixo tem como principal objetivo coletar e analisar o grau de satisfação de uma pessoa ao utilizar o aplicativo para pedir sugestões de restaurantes em Recife.

O questionário será utilizado para compor o Trabalho de Conclusão de Curso de Carlos Olimpio, para o curso de Bacharelado em Ciência da Computação. Além disso, o questionário não coletará **NENHUM** dado pessoal, apenas o apresentado abaixo.

Por favor, durante o preenchimento do questionário seja o mais sincero possível.

[Faça login no Google](#) para salvar o que você já preencheu. [Saiba mais](#)

* Indica uma pergunta obrigatória

Figura 16 – Cabeçalho do questionário de avaliação

Qual o seu grau de satisfação em relação às recomendações de restaurantes feitas na **Rodada 1**? *

	1	2	3	4	5	
Muito Insatisfeito	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Muito Satisfeito

Qual o seu grau de satisfação em relação às recomendações de restaurantes feitas na **Rodada 2**? *

	1	2	3	4	5	
Muito Insatisfeito	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Muito Satisfeito

Figura 17 – Perguntas para avaliar o grau de satisfação do usuário (parte 1)

Em relação a qualidade das recomendações de restaurantes feitas na **Rodada 1**, você se considera: *

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

Em relação a qualidade das recomendações de restaurantes feitas na **Rodada 2**, você se considera: *

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

Figura 18 – Perguntas para avaliar o grau de satisfação do usuário (parte 2)

Na sua opinião, a quantidade total de recomendações de restaurantes feitas na **Rodada 1** estava: *

- Muito Pouca
- Pouca
- Indiferente
- Satisfatória
- Exagerada

Na sua opinião, a quantidade total de recomendações de restaurantes feitas na **Rodada 2** estava: *

- Muito Pouca
- Pouca
- Indiferente
- Satisfatória
- Exagerada

Figura 19 – Perguntas para avaliar o grau de satisfação do usuário (parte 3)

Quais os principais aspectos que te levaram a escolher uma recomendação de restaurante durante a **Rodada 1**: (Você pode selecionar uma ou mais opções) *

- Nome do restaurante
- Endereço do restaurante
- Avaliações do restaurante
- Posicionamento do restaurante na lista
- Distância para o restaurante
- Já conheço o restaurante

Quais os principais aspectos que te levaram a escolher uma recomendação de restaurante durante a **Rodada 2**: (Você pode selecionar uma ou mais opções) *

- Nome do restaurante
- Endereço do restaurante
- Avaliações do restaurante
- Posicionamento do restaurante na lista
- Distância para o restaurante
- Já conheço o restaurante

Figura 20 – Perguntas para avaliar o grau de satisfação do usuário (parte 4)

Informe o grau de dificuldade ao utilizar o sistema durante a **Rodada 1:** *

	1	2	3	4	5	
Muito Complicado	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Muito Fácil

Informe o grau de dificuldade ao utilizar o sistema durante a **Rodada 2:** *

	1	2	3	4	5	
Muito Complicado	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Muito Fácil

Figura 21 – Perguntas para avaliar o grau de satisfação do usuário (parte 5)

Qual seu grau de confiança em relação as recomendações de restaurantes durante a **Rodada 1**: *

	1	2	3	4	5	
Desconfio muito	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Confio muito

Qual seu grau de confiança em relação as recomendações de restaurantes durante a **Rodada 2**: *

	1	2	3	4	5	
Desconfio muito	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Confio muito

Se tiver alguma observação sobre o aplicativo de recomendação de restaurantes, deixe abaixo seu comentário.

Sua resposta

Figura 22 – Perguntas para avaliar o grau de satisfação do usuário (parte 6)