

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
DEPARTAMENTO DE COMPUTAÇÃO**

Thiago Raulino Dal Pont

**UM MODELO DE GELADEIRA INTELIGENTE QUE
LEVA EM CONTA AS PREFERÊNCIAS E HÁBITOS DE
SEUS USUÁRIOS**

Araranguá

2017

Thiago Raulino Dal Pont

**UM MODELO DE GELADEIRA INTELIGENTE QUE
LEVA EM CONTA AS PREFERÊNCIAS E HÁBITOS DE
SEUS USUÁRIOS**

Trabalho de Conclusão de Curso
submetido à Universidade Federal
de Santa Catarina, como parte dos
requisitos necessários para a obten-
ção do Grau de Bacharel em Enge-
nharia de Computação.

Orientador: Prof. Dr. Alexandre
Leopoldo Gonçalves

Araranguá

2017

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Dal Pont, Thiago Raulino

Um modelo de geladeira inteligente que leva em
conta as preferências e hábitos de seus usuários /
Thiago Raulino Dal Pont ; orientador, Alexandre
Leopoldo Gonçalves, 2017.

135 p.

Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Santa Catarina, Campus
Araranguá, Graduação em Engenharia de Computação,
Araranguá, 2017.

Inclui referências.

1. Engenharia de Computação. 2. Internet das
Coisas. 3. Sistemas de Recomendação. 4. Geladeira
Inteligente. 5. Preferências de Usuário. I.
Leopoldo Gonçalves, Alexandre. II. Universidade
Federal de Santa Catarina. Graduação em Engenharia
de Computação. III. Título.

Thiago Raulino Dal Pont

**UM MODELO DE GELADEIRA INTELIGENTE QUE
LEVA EM CONTA AS PREFERÊNCIAS E HÁBITOS DE
SEUS USUÁRIOS**

Este Trabalho de Conclusão de Curso foi julgado aprovado para a obtenção do Título de “Bacharel em Engenharia de Computação” e aprovado em sua forma final pela Universidade Federal de Santa Catarina.

Araranguá, 05 de dezembro 2017.

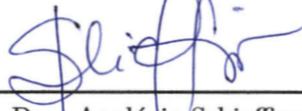


Prof. Dra. Eliane Pozzebon
Coordenadora

Banca Examinadora:



Prof. Dr. Alexandre Leopoldo Gonçalves
Universidade Federal de Santa Catarina



Prof. Dra. Analúcia Schiaffino Morales
Universidade Federal de Santa Catarina



Prof. Dr. Anderson Luiz Fernandez Perez
Universidade Federal de Santa Catarina

Dedico este trabalho aos meus pais e meu irmão, sem os quais jamais chegaria até aqui, e a todos os colegas e professores que me guiaram ao longo do curso.

AGRADECIMENTOS

Agradeço, primeiramente, a Deus pelo dom da vida e pela oportunidade de ter conhecido pessoas tão importantes ao longo dos últimos anos. Além disso, tenho de manifestar a minha profunda gratidão aos meus pais e meu irmão, que ao longo destes anos, foram muito compreensivos e pacientes comigo e, constantemente, me incentivaram a estudar.

Gostaria também de agradecer ao meu conterrâneo, Alan Kunz Cechinel, que, desde o começo do curso, se mostrou um grande amigo, um companheiro de noites de estudo e uma grande inspiração.

Devo também mostrar minha gratidão a três professores em especial na Universidade aos quais me proporcionaram aprendizado profissional e pessoal muito importante. O primeiro deles, o Prof. Dr. Alexandre Leopoldo Gonçalves, que ao longo dos últimos dois anos, me orientou com muita dedicação, paciência e profissionalismo e me deu lições sobre a vida acadêmica, profissional e pessoal que levarei por toda a minha vida. Além disso, a Prof. Dra. Analúcia Schiaffino que me concedeu o meu primeiro projeto na universidade, em que pude aprender muito e que mudou a minha visão de Universidade. Por fim, o Prof. Dr. Anderson Luiz Fernando Perez, que me permitiu quase morar no Laboratório de Automação de Robótica Móvel (LARM) e que passou, a cada conversa no laboratório, uma nova lição sobre a vida.

Não poderia esquecer da Empresa Júnior de Engenharia de Computação (EJEC) e a todos os seus membros que, ao longo dos últimos dois anos, me ensinaram o que é ser um empreendedor e colocar o empreendedorismo em prática. Poderia dizer com convicção que foi a experiência mais impactante dentro da universidade. Nada disso teria acontecido sem o convite do atual presidente e fundador, Kaio Anselmo.

Agradeço a todos os colegas e professores que conheci e que fiz grandes amizades.

Por fim, gostaria de agradecer à Universidade Federal de Santa Catarina pela oportunidade de ter vivenciado tudo isso.

“Eu acredito que é uma coisa importante a fazer, e então, prestar muita atenção aos feedbacks negativos, e solicitá-los, especialmente de amigos”

(Elon Musk)

RESUMO

Nas últimas duas décadas o conceito de Internet das Coisas vem se popularizando, propondo a introdução da tecnologia e da interconexão de objetos distintos, como lâmpadas, geladeiras, carros, etc., através de uma rede, frequentemente, a Internet. Assim, o número de aparelhos interligados tende a crescer produzindo uma grande quantidade de dados. Torna-se, então, necessário o uso de ferramentas capazes de processar e extrair informações relevantes desses dados. Entre os métodos existentes estão os sistemas de recomendação, aos quais, a partir de análises das interações de usuários, são capazes de traçar perfis de usuários e fornecer sugestões. Nos últimos anos, esses sistemas vêm sendo incorporados em diversos contextos como plataformas de *streaming* e, gradativamente, outras aplicações introduzirão tais ideias no âmbito da Internet das Coisas. Entre os ambientes, nos quais é possível integrar ambos os conceitos, estão as casas inteligentes ou *smart homes*, onde o uso da tecnologia abre caminho para novas formas de interação com o lar. Dispositivos comuns presentes em casas, como geladeiras, agregam, assim, novas tecnologias e funcionalidades, no entanto, os modelos existentes apenas proporcionam interações digitais, contudo não atentam aos gostos e hábitos dos usuários. Levando isso em conta, o presente trabalho propõe um modelo de geladeira capaz de monitorar as interações e traçar perfil de preferências por produtos. Isso é possível devido ao uso de etiquetas RFID, que terão o papel de identificar os diversos produtos contidos na geladeira e da aplicação de algoritmos de recomendação. Ao final, fez-se uma avaliação, a partir de um cenário criado, onde o equipamento foi capaz de realizar o monitoramento dos produtos disponíveis e de oferecer recomendações aos usuários a partir de seus perfis, além da reposição de produtos considerados essenciais. Além disso, foi possível recomendar receitas tanto a partir do conteúdo da geladeira, bem como, do perfil do usuário. A partir do exposto, conclui-se que a integração dos conceitos de Internet das Coisas e Sistemas de Recomendação pode contribuir para auxiliar usuários em suas tarefas diárias facilitando, de algum modo, o processo de tomada de decisão.

Palavras-chave: Internet das Coisas. Sistemas de Recomendação. Geladeira Inteligente. Preferências do usuário.

ABSTRACT

In the last two decades the concept of the Internet of Things has become popular, proposing the introduction of technology and the interconnection of different objects such as lamps, refrigerators, cars, etc. through a network, often the Internet. Thus, the number of interconnected devices tends to grow producing a large amount of data. It is then necessary to use tools capable of processing and extracting relevant information from such data. Among the existing areas are the Recommender Systems based on analyzes of user interactions being able to trace user profiles and provide suggestions. In recent years, these systems have been incorporated into a variety of contexts such as streaming platforms and, gradually, other applications will introduce such ideas into the Internet of Things context. Among the environments in which both concepts can be integrated are smart houses, in which the use of technology creates new forms of interaction with the home. Common devices present in the houses such as refrigerators add, thus, technologies and new features, however, existing models only provide digital interactions, however do not address the tastes and habits of users. Taking this into account the present work proposes a model of refrigerator capable of monitoring interactions and tracing preferences profile by products. This is possible by using RFID tags which have the role of identifying the various products contained in the refrigerator and the application of recommendation algorithms. In the end, an evaluation was made, based on a created scenario, where the equipment was able to monitor the available products and offer recommendations to users from their profiles as well as the replacement of products considered essential. In addition, it was possible to recommend recipes both from the contents of the refrigerator as well as from the user profile. From the above, it is concluded that the integration of the Internet of Things and Recommendation Systems concepts can contribute to help users in their daily tasks facilitating, in some way, decision making process.

Keywords: Internet of Things. Recommender systems. Smart fridge. User preferences.

LISTA DE FIGURAS

Figura 1	Fluxo das etapas do trabalho.....	32
Figura 2	Arquiteturas para IoT.....	34
Figura 3	Arquitetura básica para o IEEE802.11.....	42
Figura 4	Modelo para casas inteligentes.....	46
Figura 5	Exemplo de grupos para classificação com o kNN....	56
Figura 6	Exemplo de classificação com o kNN.....	57
Figura 7	Rede MLP.....	60
Figura 8	Modelo lógico.....	73
Figura 9	Modelo físico.....	77
Figura 10	Estrutura interna da geladeira.....	78
Figura 11	Estrutura externa da geladeira.....	80
Figura 12	Página principal da interface.....	81
Figura 13	Listagem de produtos.....	81
Figura 14	Exibição de detalhes de uma receita.....	82
Figura 15	Fluxo de leitura do conteúdo da geladeira.....	97
Figura 16	Fluxo para listagem de conteúdo da geladeira.....	98
Figura 17	Fluxo para recomendação de produtos novos.....	100
Figura 18	Fluxo para recomendação de produtos faltantes.....	102
Figura 19	Fluxo para recomendação de receitas por conteúdo..	103
Figura 20	Fluxo para recomendação de receitas por perfil.....	104
Figura 21	Deteção de porta aberta.....	105
Figura 22	Fluxo para listagem de recomendações.....	106
Figura 23	Ambiente do cenário.....	107
Figura 24	Listagem de produtos na Interface.....	109
Figura 25	Listagem de Recomendações por falta.....	112
Figura 26	Resultado da recomendação de receitas.....	113
Figura 27	Lista de Receitas Sugeridas por Perfil.....	114
Figura 28	Alerta de porta aberta.....	115

LISTA DE TABELAS

Tabela 1	Resumo dos protocolos 802.11.....	41
Tabela 2	Matriz de avaliações de itens por usuários.....	52
Tabela 3	Matriz de frequências de interações.....	110

LISTA DE ABREVIATURAS E SIGLAS

6LoWPAN	<i>IPv6 Over Wireless Personal Area Network</i>
AES128	<i>Advanced Encryption Standard de 128 bits</i>
AP	<i>Access Point</i>
BLE	<i>Bluetooth Low Energy</i>
BR/EDR	<i>Basic Rate/Enhanced Data Rate</i>
BSS	<i>Basic Service Set</i>
EPC	<i>Electronic Product Code</i>
FC	<i>Filtragem Colaborativa</i>
HTTP	<i>Hypertext Transfer Protocol</i>
IDE	<i>Integrated Development Environment</i>
IDF	<i>Inverse Document Frequency</i>
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
IETF	<i>Internet Engineering Task Force</i>
IPv6	<i>Internet Protocol Version 6</i>
ISM	<i>Industrial, Scientific and Medical</i>
JAX-WS	<i>Java API for XML Web Services</i>
JEE	<i>Java Enterprise Edition</i>
JSON	<i>JavaScript Object Notation</i>
kNN	<i>k Nearest Neighbors</i>
MLP	<i>Multilayer Perceptron</i>
NDEF	<i>NFC Data Exchange Format</i>
NFC	<i>Near Field Communication</i>
OSI	<i>Open System Interconnection</i>
PDF	<i>Portable Document Format</i>
REST	<i>Representational State Transfer</i>
RFID	<i>Radio-Frequency Identification</i>
RMSE	<i>Root Mean Square Error</i>
RNA	<i>Rede Neural Artificial</i>
SPI	<i>Serial Peripheral Interface</i>
SQL	<i>Search Query Language</i>
SR	<i>Sistema de Recomendação</i>
SVD	<i>Singular Value Decomposition</i>

TDM	<i>Time-Division Multiplexing</i>
TF-IDF	<i>Term Frequency - Inverse Document Frequency</i>
TF	<i>Term Frequency</i>
URI	<i>Uniform Resource Identifier</i>
URL	<i>Uniform Resource Locator</i>
WPAN	<i>Wireless Personal Area Network</i>

LISTA DE QUADROS

1	Serviço de registro de interação	82
2	Serviço de consulta de estado de porta	83
3	Registro na base de interações	84
4	Estrutura de um código EPC	85
5	Estrutura de um registro de estado da porta	85
6	Estrutura de um registro de configurações	86
7	Estrutura de um registro de metainformação de produto	87
8	Registro de receita	89
9	Registro de recomendação de produtos	90
10	Registro de recomendação de receitas	91
11	Registro de interação dos produtos	108
12	Registro de porta aberta	114

SUMÁRIO

1	INTRODUÇÃO	25
1.1	PROBLEMÁTICA	28
1.2	OBJETIVOS	29
1.2.1	Geral	29
1.2.2	Específicos	29
1.3	JUSTIFICATIVA E MOTIVAÇÃO	29
1.4	PROCEDIMENTOS METODOLÓGICOS	31
1.5	ORGANIZAÇÃO DO TRABALHO	32
2	INTERNET DAS COISAS	33
2.1	INTRODUÇÃO	33
2.2	ARQUITETURA	34
2.3	TECNOLOGIAS	35
2.3.1	Bluetooth	35
2.3.2	RFID	37
2.3.3	NFC	38
2.3.4	Zigbee	39
2.3.5	Wi-Fi	41
2.3.6	Outros	43
2.4	AMBIENTES INTELIGENTES	44
2.4.1	Smart Grid	44
2.4.2	Smart Home	44
2.4.3	Outros	47
2.5	DESAFIOS	47
3	SISTEMAS DE RECOMENDAÇÃO	49
3.1	INTRODUÇÃO	49
3.2	HISTÓRICO	50
3.3	FILTRAGEM COLABORATIVA (FC)	51
3.3.1	Método de FC Baseado em Memória	52
3.3.2	Método de FC Baseado em Modelo	57
3.4	ABORDAGEM BASEADA EM CONTEÚDO	61
3.4.1	Descrição do Item	61
3.4.2	Perfil de Usuário	62
3.4.3	Recomendação	63
3.5	BASEADA EM CONHECIMENTO	63
3.5.1	Baseado em Restrições	64
3.5.2	Baseado em Caso	64
3.6	ABORDAGEM HÍBRIDA	65

3.7	OUTRAS ABORDAGENS	66
3.7.1	Baseada em Contexto	66
3.7.2	Baseada em Utilidade	66
3.7.3	SRs Sociais	67
3.7.4	SRs Demográficos	67
3.8	DESAFIOS	67
3.9	APLICAÇÕES	68
4	MODELO PROPOSTO	71
4.1	INTRODUÇÃO	71
4.2	MODELO LÓGICO	72
4.2.1	Camada de Aplicação	72
4.2.2	Camada de Serviços	74
4.2.3	Camada de Repositórios	75
4.2.4	Camada de Processamento	75
4.2.5	Camada de Agente Externo	76
4.3	MODELO FÍSICO	77
4.3.1	Camada de Aplicação	77
4.3.2	Camada de Serviços	81
4.3.3	Camada de Repositórios	83
4.3.4	Camada de Processamento	90
4.3.5	Camada de Agente Externo	94
5	APLICAÇÃO DO MODELO E ANÁLISE DOS	
	RESULTADOS	95
5.1	INTRODUÇÃO	95
5.2	FLUXOS DE EXECUÇÃO DO SISTEMA	95
5.2.1	Leitura de Conteúdo	95
5.2.2	Listagem do Conteúdo da Geladeira	97
5.2.3	Recomendação de Produtos Novos	98
5.2.4	Recomendação de Produtos Faltantes	101
5.2.5	Recomendação de Receitas por Conteúdo	102
5.2.6	Recomendação de Receitas por Perfil	103
5.2.7	Fluxo para Detecção e Registro de Porta Aberta ..	104
5.2.8	Listagem de Recomendações	105
5.3	CENÁRIO DE APLICAÇÃO	106
5.4	AVALIAÇÃO DO PROTÓTIPO	108
5.4.1	Leitura do Conteúdo	108
5.4.2	Listagem de Conteúdo da Geladeira	108
5.4.3	Recomendações de Produtos Novos	109
5.4.4	Recomendação de Produtos Faltantes	111
5.4.5	Recomendação de Receitas a partir de Conteúdo ..	112
5.4.6	Recomendação de Receitas por Perfil	113

5.4.7	Alerta de Porta Aberta	114
6	CONSIDERAÇÕES FINAIS	117
6.1	TRABALHOS FUTUROS	118
	REFERÊNCIAS	121

1 INTRODUÇÃO

Nas últimas décadas, presencia-se os acelerados avanços na ciência e tecnologia impulsionados por empresas dos mais diversos ramos e pelas constantes pesquisas nas universidades.

Um dos avanços tecnológicos mais significativos é a Internet, com efeito significativo no desenvolvimento da economia global e na sociedade atual. Em duas décadas tem decorrido um grande crescimento na disponibilidade do acesso a rede. Em setembro de 2016, o número de usuários da rede mundial de computadores era de aproximadamente 3,75 bilhões, quase metade da população mundial e cerca de 92 vezes maior em relação ao ano 2000 (MINIWATTS MARKETING GROUP, 2016). Outro grande avanço tem ocorrido nos celulares, aos quais evoluíram tanto nos últimos anos que passaram de simples e grandes telefones sem fio à dispositivos menores, no entanto, com acesso à Internet, recursos avançados de áudio e vídeo e capacidade de processamento equiparável à computadores de mesa (*desktops*) e/ou notebooks (MEYERS, 2011; WOYKE, 2014).

Em meio ao contexto da Internet, um novo paradigma surgiu no meio acadêmico e aos poucos ganha terreno nas grandes empresas. A sua proposta é levar a tecnologia a objetos do dia a dia, como condicionadores de ar, lâmpadas, fogões etc., e, assim, criar novas formas de interação além de funcionalidades inéditas, seguindo o exemplo dos *smartphones*.

Mencionada pela primeira vez, por Kevin Ashton, em 1999 (FINEP, 2015), a Internet das Coisas (IoT, do inglês, *Internet of Things*) vem se consolidando cada vez mais. Abrigará um variado ecossistema de dispositivos com capacidade de processamento, sensoriamento, conexão com demais dispositivos, em muito casos, com a Internet, entre outros avanços. Estima-se que, em 2020, cerca de 24 bilhões de dispositivos IoT estejam conectados, implicando em torno de quatro dispositivos por pessoa (MEOLA, 2016).

Contudo, com o crescimento do número de itens computacionais, a quantidade de dados gerada por eles também cresce de maneira acelerada (CHIANG; ZHANG, 2016). A partir disso, o fluxo de dados na rede de internet se intensifica a ponto de comprometer o seu desempenho. Isso decorre em função modelo de rede utilizado, também chamado *cloud computing*, ao qual mantêm recursos e funcionalidades distantes dos dispositivos que os utilizam, ou seja, em servidores e *data centers*. Assim, para obtenção de tais recursos há a necessidade dos

dispositivos em acessar a nuvem através da internet sempre que necessário, gerando, desse modo, um alto tráfego de dados (VAQUERO; RODERO-MERINO, 2014).

Além disso, o acesso a nuvem dificulta aplicações em IoT em tempo real devido ao atraso entre envio e recebimento de dados pela rede de internet (SYED; FERNANDEZ; ILYAS, 2016). Portanto, uma nova arquitetura se faz necessária para incorporar os dispositivos IoT à Internet tradicional. Nesse contexto, a *fog computing* ou computação de neblina, surge como potencial solução, com base na proposta de uma forma de organização de rede que complementa a atual. Isso é possível com base na aproximação, aos dispositivos IoT que as utilizam, de algumas funcionalidades e recursos que atualmente são acessados através da nuvem, ou seja, centralizadas em servidores e *data centers*. (CHIANG; ZHANG, 2016). Para tanto, um dispositivo de rede seria responsável por uma “nuvem local” ou *fog*. Desse modo, os dispositivos IoT se comunicariam com esse equipamento e obteriam funcionalidades necessárias de maneira mais eficiente. Ademais, a nuvem local se comunicaria diretamente com a nuvem convencional, transferindo apenas informações mais relevantes e necessárias (SYED; FERNANDEZ; ILYAS, 2016).

Os dispositivos que compõem a IoT podem ser denominados objetos inteligentes, ou *smart objects*, aos quais detêm funcionalidades expandidas como comunicação, sensoriamento, processamento e atuação sobre o ambiente. Além disso, promovem a interação entre o mundo físico (analógico) e o mundo digital. Isso ocorre graças a sensores capazes de capturar grandezas como temperatura e luminosidade e, a partir disso, torna-se possível que aplicações tenham conhecimento do contexto do ambiente (STOJKOSKA et al., 2017).

Baseando-se nesses conceitos, algumas companhias vêm inserindo no mercado novos produtos com as características citadas. Como exemplo, o Amazon Echo¹, um dispositivo que opera com o serviço de assistente pessoal Alexa, e interage com pessoas em uma casa a partir de comando de voz. Outro produto é a *smart lock* da empresa Nuki², pelo qual é possível abrir e fechar a porta apenas com um toque no aplicativo móvel pelo *smartphone* ou através de um *smart watch*. Ademais, outras áreas vem se utilizando desses conceitos, por exemplo, os esportes. O CARV³, um dispositivo vestível ou *wearable*, propõe um

¹<https://www.amazon.com/Amazon-Echo-Bluetooth-Speaker-with-WiFi-Alexa/dp/B00X4WHP5E>

²<https://nuki.io/en/shop/nuki-smart-lock/>

³<https://www.kickstarter.com/projects/333155164/carv-the-worlds-first-wearable-that-helps-you-ski>

calçado para praticantes de ski capaz de analisar, em tempo real, o modo de esquiar e fornecer informações detalhadas, visando melhorar o desempenho dos usuários.

Os *smart objects* poderão, a partir da IoT, operar em conjunto com o objetivo de compor os chamados *smart environments*, ambientes nos quais a integração dos dispositivos agrega novas funcionalidades e formas de interação para determinado ambiente (ASANO; YASHIRO; SAKAMURA, 2016). Entre os ambientes inteligentes emergentes estão as *smart grids*, que propõem a atualização do sistema elétrico atual a partir do uso da tecnologia. Uma das principais mudanças será o direcionamento do fluxo de energia e informações em dois sentidos. Como consequência, será possível consumir e fornecer energia para o sistema elétrico, bem como trocar informações sobre o estado da rede de eletricidade, o consumo, entre outros avanços. Tudo isso será viável em virtude da capacidade de sensoriamento, troca de informações, controle e da tecnologia da informação e comunicação (CECILIA; SUDARSANAN, 2016).

Além das *smart grids*, outro ambiente em expansão é a *smart home* ou casa inteligente. Através dela, os moradores de uma casa podem interagir com um recinto capaz de responder ao seus comportamentos e prover diversas funcionalidades (SILVA et al., 2012). Isso se deve à presença de dispositivos dotados com tecnologias de sensoriamento, controle e comunicação.

Os ambientes inteligentes podem abrigar outros menores. No caso das *smart homes*, é possível subdividi-las em ambientes como a cozinha inteligente ou *smart kitchen*. Nesse espaço, usuário tem à disposição novas maneiras de interagir com os utensílios e eletrodomésticos. A partir disso, surgem diversas oportunidades em termos de criação de produtos, como geladeiras, fogões, cafeteiras conectadas à Internet. Em relação às geladeiras inteligentes ou *smart fridges*, por exemplo, viu-se um avanço nos últimos anos. Desde os anos 2000 vem-se pensando em como conectar refrigeradores à Internet, sendo a LG⁴ uma das primeiras companhias a implementar o conceito de dispositivos conectados à Internet. Em pesquisas recentes, propõe-se adicionar outros recursos como monitoramento dos produtos no interior e seus respectivos prazos de validade, entre outros (HACHANI et al., 2016).

As interações das pessoas com os ambientes e dispositivos conectados, no contexto da IoT, gerará uma grande quantidade de dados (CHIANG; ZHANG, 2016). Um aproveitamento eficiente desses dados pode ampliar as aplicações da IoT. Uma das diversas formas para colo-

⁴<http://www.lg.com>

car essa ideia em prática são os Sistemas de Recomendação (SRs). Com base nas preferências indicadas pelo usuário ou no seu comportamento, esses sistemas buscam selecionar e fornecer informações relevantes (FILHO; GEUS; ALBUQUERQUE, 2008).

SRs podem ser divididos em três classes principais. A primeira refere-se a filtragem colaborativa, em que recomendações são realizadas com base na similaridade das preferências de determinado usuários em relação a outros usuários no que tange a produtos, serviços etc., que o usuário não conhece, mas tem alta probabilidade de interesse. Outra categoria é a baseada em conteúdo, na qual os conteúdos apresentados ao usuário são baseados nas suas próprias preferências, mas considerando as características de determinado item de interesse. Por fim, existe a abordagem híbrida, em que ambas as categorias citadas são mescladas, aproveitamento, desse modo, as melhores funcionalidades de cada uma (THOMAS; SUJATHA, 2016).

As aplicações de SRs são adotadas nos mais diversos campos, dentre eles, plataformas de *streaming* de filmes e séries, sites de vendas *online* entre outros. Ainda assim, os SRs vêm recebendo novas propostas de uso, como sistemas aptos a propor pontos de carga para condutores de carros elétricos (FERREIRA et al., 2011), notícias personalizadas (YEUNG; YANG, 2010) e sistemas focados em acessibilidade (CARDOSO et al., 2016).

1.1 PROBLEMÁTICA

Os ambientes inteligentes, através da IoT, tornam possível a interação entre usuários e a tecnologia. No entanto, há dispositivos que ainda não fazem uso de todo o potencial proporcionado através da IoT para fornecer experiências como os objetos presentes em casas inteligentes, como, geladeiras, fogões etc.

Em relação às geladeiras inteligentes, um dos problemas em aberto está o modo com o qual é realizado o monitoramento e registro de itens. Muitas propostas fazem uso de dispositivos que operam por ondas eletromagnéticas. No entanto, os alimentos que contém água, além de estruturas metálicas, podem interferir no desempenho das leituras dependendo da tecnologia utilizada (PERIYASAMY; DHANASEKARAN, 2015; QING; CHEN, 2007). Por outro lado, os métodos que utilizam processamento de imagem têm êxito em monitoramento de alimentos naturais como verduras e frutas (SHWETA, 2017), mas não há, na literatura, outras propostas que englobem processamento de imagem para

produtos embalados, como leite, enlatados entre outros.

Apesar do grande número de estudos a cerca da IoT, as tecnologias e aplicações propostas não têm demonstrado a devida atenção aos aspectos de usabilidade e experiência do usuário, focando mais no ponto de vista técnico (KORESHOFF; ROBERTSON; LEONG, 2013; WILSON; HARGREAVES; HAUXWELL-BALDWIN, 2015). É necessário, portanto, incluir no projeto de aplicações conceitos que visem auxiliar os usuários no seu dia a dia.

Desse modo, tem-se como pergunta de pesquisa: **“Como aprimorar o conceito atual de geladeira inteligente levando em conta a interação dos usuários de modo que o dia a dia destes seja facilitado?”**

1.2 OBJETIVOS

Esta seção apresenta o objetivo geral e os objetivos específicos do trabalho.

1.2.1 Geral

Desenvolver um modelo de geladeira inteligente que facilite o dia a dia dos usuários a partir da análise das interações destes.

1.2.2 Específicos

- Elaborar e desenvolver um projeto de leitura e monitoramento dos produtos contidos na geladeira.
- Implementar um sistema de análise das interações e recomendação de produtos e de receitas.
- Elaborar um cenário que permita a avaliação do modelo proposto.
- Avaliar e discutir os resultados obtidos a partir do modelo proposto.

1.3 JUSTIFICATIVA E MOTIVAÇÃO

A Internet tem evoluído nas últimas décadas impactando na economia mundial e no dia a dia das pessoas. Nos seus primeiros anos de existência, tinha como principal função o uso militar e acadêmico,

como foco em troca de informações (LEINER et al., 2012). Contudo, anos mais tarde foi aberta para uso da população em geral permitindo, desse modo, que pessoas comuns tivessem acesso a rede. Hoje, cerca de metade da população mundial usa a Internet frequentemente (MINIWATTS MARKETING GROUP, 2016).

No cenário atual, um novo grupo está sendo conectado na Internet: “as coisas”. Cria-se um novo paradigma, a IoT, onde a rede não será mais utilizada apenas da maneira tradicional, como em um computador de mesa ou *smartphone* entre outros, mas por dispositivos que possuem acesso a redes e capacidades como sensoriamento, atuação e comunicação com outros dispositivos. Muitos dos dispositivos serão versões conectadas dos objetos presentes no dia a dia, como televisão, fogão, geladeira, lâmpada e porta. Todos esses equipamentos, operando em conjunto com a rede, criarão um ecossistema de objetos com funcionalidades inéditas.

Com a IoT estima-se que até 2020, cerca de 24 bilhões de dispositivos estejam conectados, garantindo espaço para inovação em produtos e serviços. Além disso, espera-se que a IoT se torne um grande atrativo para o mercado. Prevê-se que, em 2025, sejam gerados em torno de 13 trilhões de dólares (MEOLA, 2016).

A sociedade se beneficia com o desenvolvimento da IoT. As soluções geradas considerando este conceito trarão novas formas de interação entre as pessoas e os objetos que as cercam no cotidiano. Ambientes como casa, indústria e sala de aula terão a disposição novas formas de interação a partir da tecnologia.

Tratando-se de uma casa inteligente, chamada também de *smart home*, os moradores tem à disposição conforto e comodidade em virtude dos objetos conectados presentes nela, entre eles a geladeira. Presente em grande parte dos lares, o refrigerador tem um papel fundamental na vida dos moradores. Os alimentos contidos nele devem ser bem conservados para o consumo. No entanto, produtos são esquecidos no seu interior e, por vezes, passam do prazo de validade. Além disso, seria cômodo aos usuários, estando em um supermercado, se soubessem quais itens estão faltando ou vencidos, evitando assim compras desnecessárias. Apesar da facilidade na visita ao supermercado com uma lista em tempo real dos produtos necessários, seria ainda mais cômodo se o refrigerador automaticamente realiza-se compras de itens essenciais como leite ou carne e o supermercado entregasse as compras em casa. Ainda que tais funcionalidades não sejam comuns, existem propostas de geladeiras inteligentes que as implementam. Contudo, não há abordagens em que se leve em conta os interesses do usuários

como preferências por certos alimentos, horários em que o consumo é mais comum, a sugestão de itens similares quando os rotineiramente comprados se encontram em falta, a recomendação de receitas com os produtos disponíveis, entre outros. Por isso, acredite-se que entender o comportamento dos usuários por meio da IoT pode facilitar o dia a dia destes.

Portanto, este trabalho trará como contribuição a melhora do modelo atual de geladeira inteligente leve em conta os interesses e padrões de consumo de seus usuários.

1.4 PROCEDIMENTOS METODOLÓGICOS

Os procedimentos metodológicos representam um conjunto de passos necessários para se atingir certo objetivo. Por meio destes procedimentos, a pesquisa caracteriza-se como uma atividade voltada para a investigação de problemas teóricos ou práticos (MATIAS-PEREIRA, 2012).

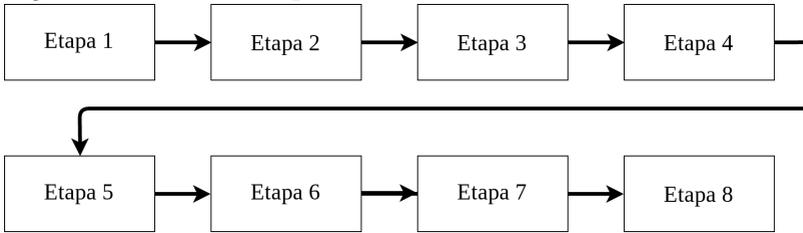
Este trabalho pode ser caracterizado, quanto à sua finalidade, como uma pesquisa aplicada, visto que, conforme Matias-Pereira (2012), “os conhecimentos adquiridos são utilizados para aplicação prática e voltados para a solução de problemas concretos da vida moderna”. Quanto ao objeto, o projeto é descrito como uma pesquisa bibliográfica, já que é necessário o levantamento do estado da arte do tema, fundamentação teórica e definição da contribuição do trabalho (MATIAS-PEREIRA, 2012). De acordo com a modalidade, a pesquisa se identifica como uma pesquisa tecnológica, onde será criado um artefato tecnológico, sendo este um protótipo de geladeira capaz de reconhecer as interações do usuário, realizar compras automáticas além de recomendações de outros produtos e receitas com base nas preferências do usuário.

A metodologia de desenvolvimento deste trabalho é dividida em 8 etapas, das quais, a ordem cronológica é apresentada na Figura 1.

A seguir, a sequência de etapas demonstradas anteriormente são especificadas em detalhes.

- Etapa 1: Análise e definição do escopo do trabalho.
- Etapa 2: Levantamento bibliográfico sobre IoT e SRs;
- Etapa 3: Elaboração e desenvolvimento de um projeto de leitura e monitoramento dos produtos contidos na geladeira.
- Etapa 4: Implementação de um sistema de análise das interações e recomendação de produtos e receitas.
- Etapa 5: Desenvolvimento de um protótipo funcional que integre

Figura 1 – Fluxo das etapas do trabalho



Fonte: Elaborado pelo Autor

as Etapas 3 e 4.

- Etapa 6: Criação de um cenário de testes para avaliar o protótipo.
- Etapa 7: Avaliação e discussão dos resultados obtidos no cenário proposto.
- Etapa 8: Escrita do Trabalho de Conclusão de Curso.

1.5 ORGANIZAÇÃO DO TRABALHO

Este trabalho é dividido em seis capítulos. O **Capítulo 1** apresenta uma introdução do estado da arte das áreas envolvidas bem como a problemática do trabalho, os objetivos gerais e específicos, justificativa e procedimentos metodológicos.

O **Capítulo 2** trata da IoT, no qual é realizada uma revisão da arquitetura para organização dos diversos componentes, das tecnologias existentes que possibilitam o desenvolvimento de novos dispositivos e, por fim, uma descrição sobre alguns dos ambientes nos quais a IoT será incorporada nos próximos anos.

O **Capítulo 3** apresenta a área de SRs considerando um histórico, as principais abordagens e aplicações em que se inserem.

O **Capítulo 4** tem por objetivo detalhar o sistema proposto apresentando uma visão lógica e uma visão física promovendo assim um entendimento do como os diversos componentes interagem e se comportam.

O **Capítulo 5** apresenta um cenário criado bem como os resultados obtidos a partir da aplicação do mesmo no sistema.

O **Capítulo 6** contém as considerações finais e os trabalhos futuros.

2 INTERNET DAS COISAS

Neste capítulo, será tratado da IoT, no qual é realizada uma revisão da arquitetura para organização dos diversos componentes, das tecnologias existentes que possibilitam o desenvolvimento de novos dispositivos e, por fim, uma descrição sobre alguns dos ambientes nos quais a IoT será incorporada nos próximos anos.

2.1 INTRODUÇÃO

A tecnologia de telecomunicação cada vez mais se faz presente em diferentes setores, por exemplo, na indústria (FERNANDES, 2013), no comércio (CARMONA; DRSKA, 2014), na agricultura (QUADROS; SILVA, 2011). No entanto, um novo paradigma vem emergindo, a IoT. A partir dela novas possibilidades de interação e aplicações serão criadas.

O conceito de IoT está relacionado à interconexão de objetos distintos através de uma rede, sendo esta, muitas vezes, a Internet. Desse modo, elementos do mundo real, que até então funcionavam de maneira independente ao meio em que estavam inseridos, são capazes de interagir com outros objetos à sua volta e, assim, trocar informações que possam ser relevantes. Desse modo, permite-se a agregação de novas funcionalidades. Além disso, a IoT abre espaço para interação entre o mundo físico e o digital a partir de dispositivos capazes de capturar dados físicos no meio em que estão, tais como, temperatura, distância, entre outros, e então representá-los digitalmente e transmiti-los para outros dispositivos (SURESH et al., 2014).

O termo IoT foi citado pela primeira vez em 1999 por Kevin Ashton, diretor executivo da AutoIDCentre do MIT, em 1999 enquanto realizava uma apresentação para promover a ideia do uso de Identificadores de Radio Frequência (RFID) na etiquetagem de produtos. O uso da tecnologia beneficiaria a logística da cadeia de produção (FINEP, 2015). Apesar de o termo IoT ter sido usado apenas em 1999, aplicações práticas da ideia já existiam anos antes. Um exemplo disso é a torradeira que podia ser ligada e desligada via internet criada em 1990 (SURESH et al., 2014).

A IoT está em grande expansão. Estima-se que, até 2020, cerca de 24 bilhões de dispositivos estejam conectados, implicando em cerca de quatro dispositivos por pessoa. Para tanto, em torno de 6 trilhões de dólares serão investidos em desenvolvimento de tecnologias de *hard-*

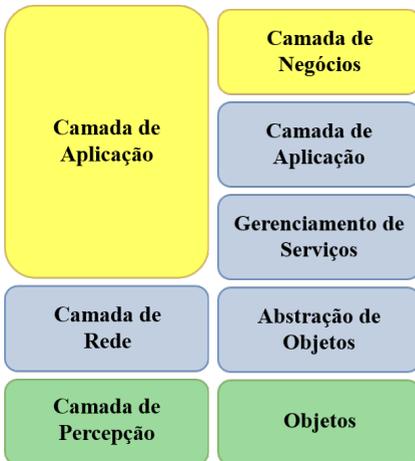
ware e *software*. Além disso, o setor é visto como promissor, pois, a partir desses investimentos, aproximadamente 13 trilhões de dólares serão gerados até 2025 (MEOLA, 2016).

2.2 ARQUITETURA

Segundo Al-Fuqaha et al. (2015), para que seja possível a IoT, em meio ao grande número de objetos, são necessários seis elementos básicos: a) identificação de cada dispositivo na rede; b) sensoriamento sobre o ambiente; c) comunicação entre os dispositivos e a Internet; d) computação; e) serviços; e f) semântica. As arquiteturas para IoT, devem levar em conta esses pontos.

Com o tempo, alguns modelos de arquiteturas em camadas foram propostos no âmbito da IoT. Al-Fuqaha et al. (2015) mostra algumas das arquiteturas mais comuns para IoT, entre elas, as que estão apresentadas na Figura 2.

Figura 2 – Arquiteturas para IoT



(a) 3 camadas

(b) 5 camadas

Fonte: Adaptado de Al-Fuqaha et al. (2015)

A arquitetura em três camadas pode ser definida como a base para dispositivos relacionados à IoT e envolve a percepção, a rede e a aplicação. A primeira camada compreende os objetos inteligentes responsáveis pelo sensoriamento e a atuação sobre o ambiente. Já a segunda se refere à infraestrutura de comunicação responsável por co-

nectar os dispositivos entre si e com a Internet. Por fim, a camada de aplicação provê serviços, processamento e tomada de decisão.

Na Figura 2.1(b) também é apresentada a arquitetura de cinco camadas, sendo que a primeira representa os objetos dotados de sensoriamento e/ou atuação, aos quais, interagem diretamente com o ambiente. Já a segunda camada, é responsável por transmitir de forma segura os dados provenientes da camada anterior. A camada de gerenciamento de serviços atua como intermediária entre requisitores de serviços e provedores, além de processar os dados da camada inferior e entregar serviços de acordo com o necessário. O quarto nível interage diretamente com os usuários a partir da disponibilização de serviços como exibição de informações de sensoriamento, além do controle sobre atuadores. Já a última camada é responsável por gerenciar todas as atividades e serviços da IoT, além de possibilitar a tomada de decisão e análise de *big data* a partir dos dados provenientes da camada de aplicação (AL-FUQAHA et al., 2015).

2.3 TECNOLOGIAS

Para compreender melhor o funcionamento e a evolução da IoT, é importante ter conhecimento e entendimento das tecnologias que promovem base à ela. As principais tecnologias necessárias estão imersas nas camadas das arquiteturas expostas na seção anterior, ou seja, sensoriamento e atuação, redes e aplicação. A seguir é exposta uma breve introdução sobre algumas das tecnologias.

2.3.1 Bluetooth

O *Bluetooth* é uma especificação de rede *Wireless Personal Area Network* (WPAN), ou seja, rede sem fio pessoal, sendo descrito e especificado pelo padrão definido pelo *Institute of Electrical and Electronics Engineers* (IEEE), o IEEE 802.15.1. O *Bluetooth* foi criado na década de 90 com o objetivo de unir tecnologias distintas, tais como computadores, celulares entre outros, a partir de uma padronização de comunicação sem fio entre os dispositivos (KARDACH, 2008).

Uma das principais características dessa tecnologia *wireless* é o curto alcance de transmissão variando de centímetros até alguns metros (HUANG; RUDOLPH, 2007).

No IEEE 802.15.1 há suporte para criação de redes *ad-hoc*, aos

quais, é desnecessário uma infraestrutura de rede para conexão dos dispositivos. A partir disso, é possível criar redes chamadas *picorredes*, nas quais podem conter até 8 dispositivos ativos. Sendo um mestre, ao qual coordena as operações, e os demais, são os escravos (BLUETOOTH SIG, 2017c; KUROSE; ROSS, 2012).

A tecnologia Bluetooth opera na faixa *Industrial, Scientific and Medical* (ISM) de 2.4 GHz de uso livre em modo *Time-Division Multiplexing* com um delta de $625\mu\text{s}$, proporcionando uma taxa de transmissão máxima em torno de 2 Mb/s, podendo variar de acordo com o dispositivo e a categoria de tecnologia de *Bluetooth* utilizada (BLUETOOTH SIG, 2017c).

2.3.1.1 Categorias

Segundo Bluetooth SIG (2017c), o *Bluetooth* pode ser categorizado em:

(A) *Basic Rate/Enhanced Data Rate* (BR/EDR) Esta é a subdivisão mais popularizada do Bluetooth presente nas versões 2.0 e 2.1, onde as principais características são alta velocidade de transmissão, baixo alcance e necessidade de conexão através da confirmação dos dispositivos. A partir disso, há uma transmissão contínua de dados. Uma desvantagem é o consumo de energia considerável para o funcionamento na categoria, já que há uma conexão contínua e uma taxa de transmissão que mantêm o dispositivo ativo por um longo período ininterrupto. A taxa de transmissão gira em torno de 2Mb/s.

(B) *Bluetooth Low Energy* (BLE)

O BLE é a mais recente categoria do *Bluetooth* incorporada na versão 4.0, em 2011, sendo esta a menos comum (LABS, 2015). BLE está centrado no baixo consumo de energia para permitir que certos dispositivos não precisem recarregar ou trocar suas fontes de energia, geralmente baterias, por longos períodos, que podem chegar a anos. Para uma conexão para transmissão de dados, ao contrário do BR/EDR, não é necessário um pareamento, além disso esta tem curta duração, na ordem de milissegundos. Ademais, a taxa de dados é baixa e o alcance alto. A baixa taxa de dados decorre do modo de funcionamento dos dispositivos BLE, aos quais, enviam dados em rajadas, ou seja, de tempos em tempos dados são transmitidos em forma de *broadcast*

para os dispositivos que estiverem próximos. Nos intervalos de tempo em que o dispositivo não transmite, ele “dorme”, isto é, entra em modo de consumo mínimo a fim de poupar energia.

A aplicação prática dessas características está na IoT através de *beacons* e *wearables*. Os beacons foram introduzidos pela *Apple*[®] em conjunto com o iOS 7, com o nome de *iBeacon*, que permitia aos aplicativos possuir senso de localização (APPLE, 2014). Com esses dispositivos é possível aprimorar a experiência do usuário em estabelecimentos como museus, supermercados, *shoppings*, estádios. Através da identificação de contexto, uma aplicação móvel, em um *smartphone* de um usuário pode exibir conteúdos, indicar promoções entre outros relacionados a determinado dispositivo BLE.

(C) Dual-mode

Esta categoria se refere a dispositivos, como *smartphones* que precisam se conectar tanto com dispositivos BR/EDR e BLE (BLUETOOTH SIG, 2017b).

2.3.1.2 Bluetooth 5.0

A versão 5.0 do *Bluetooth* foi lançada em dezembro de 2016 e traz consigo aprimoramentos em desempenho e segurança, garantindo duas vezes mais velocidade, quatro vezes mais alcance, oito vezes mais taxa de dados e, por fim, maior coexistência (BLUETOOTH SIG, 2017a).

Com a nova versão, veio a flexibilidade para construção de soluções baseadas em necessidade. Parâmetros como alcance, velocidade e segurança podem ser regulados para diversos objetivos a depender das aplicações (BLUETOOTH SIG, 2017a).

2.3.2 RFID

O protocolo de *Radio-Frequency Identification* (RFID) é uma tecnologia de identificação automática, entre diversas outras como código de barras. No entanto, se distingue pelo modo de funcionamento, ou seja, por ondas eletromagnéticas. Além disso, o RFID se destaca em relação às demais tecnologias no que se refere às influências externas no seu funcionamento, como sujeira e posição de leitura. Desse modo, não é necessário nem limpar ou reposicionar o dispositivo RFID para

efetuar a leitura (FINKENZELLER, 2010).

No RFID, os dados são transmitidos através de ondas de rádio entre dois dispositivos: *transponder* ou *tag* e leitor. O *transponder* é localizado no objeto identificado, um produto, equipamento etc., e nele são mantidos os dados de identificação. Já o leitor é responsável pela leitura e escrita destes (FINKENZELLER, 2010).

Para a transmissão dos dados entre os dois dispositivos o leitor emite ondas de rádio na *tag*. Ao receber o estímulo, a *tag* responde com seus respectivos dados. Além disso, existem *tags* que utilizam a energia do campo eletromagnético gerado pelo leitor para seu funcionamento, sendo estas chamadas de passivas. Existem, também, aquelas que possuem uma fonte própria de energia e por isso são denominadas ativas (FINKENZELLER, 2010).

Uma das características mais importantes dos dispositivos RFID é a frequência de operação. Os dispositivos são classificados, de acordo com esse parâmetro, em três grupos:

- **Low Frequency (LF):** Entre 30kHz à 300kHz
- **High Frequency (HF):** Entre 3MHz à 30MHz
- **Ultra High Frequency (UHF):** Entre 300MHz a 3GHz.

É possível distinguir pelo alcance:

- **Longo alcance:** maior que um metro
- **Ligação remota:** até um metro
- **Ligação próxima:** até um centímetro

2.3.3 NFC

O *Near Field Communication* (NFC) é um sistema de comunicação sem fio derivado do RFID. Ele permite transações simples e seguras entre dois dispositivos a partir da curta distância de operação, em torno de quatro centímetros, e do funcionamento baseado em aproximação dos objetos em questão (NFC FORUM, 2016). Assim, é possível realizar leituras de etiquetas (do inglês, *tags*) e obter conteúdos de acordo com a aplicação, transferir dados entre *smartphones* entre outras funcionalidades. Outra vantagem do NFC é a compatibilidade com a infraestrutura de cartões sem contato existentes permitindo usar um único dispositivo em tecnologias diferentes. Desse modo, é possível interagir com tags RFID, por exemplo.

Como o RFID, o NFC funciona através de ondas eletromagnéticas, mas com uma taxa de transmissão máxima de 424 kbps (NFC

FORUM, 2016). Assim como no RFID, é possível que os dispositivos NFC que contenham os dados usem a energia do leitor para transmitir seus dados, no modo passivo, ou usem uma fonte própria para tal procedimento, no modo ativo (IGOE; COLEMAN; JEPSON, 2014).

Outra característica importante no NFC são os modos de operação. De acordo com NFC Forum (2016), existem três modos:

- **Leitor/Escritor de tag:** Tem por objetivo ligar o mundo físico ao digital através de aplicações que leem e/ou escrevem em *tags* para obter dados e, assim, fornecer conteúdo ao usuário relacionado à etiqueta lida. Um exemplo é um *smartphone* ao ler uma *tag* NFC de um cartaz na rua.
- **Peer to Peer:** Visa conectar dispositivos por aproximação física e permite transferência de dados. Um exemplo é o Android^{®1} Beam que possibilita a troca de arquivos entre smartphones com o sistema operacional móvel da Google^{®2}.
- **Emulação de cartão:** Conecta o dispositivo do usuário em uma infraestrutura possibilitando a simulação de um cartão, além da realização de transações financeiras e identificação em um sistema de transporte, a partir da aproximação do dispositivo a um leitor específico.

O NFC possui um padrão com o qual dispositivos devem estar formatados, o *NFC Data Exchange Format* (NDEF). O mesmo define um formato comum de comunicação (IGOE; COLEMAN; JEPSON, 2014). Deste modo, os dados armazenados em *tags* devem estar gravados de acordo com o ele. A partir do NDEF, é possível armazenar e trocar documentos binários, como imagens e arquivos *Portable Document Format* (PDF), além de endereços *Uniform Resource Locator* (URL) e textos simples.

2.3.4 Zigbee

O Zigbee é um protocolo padrão de comunicação de baixa potência para redes sem fio *mesh*, ao qual permite a diversos dispositivo trabalharem em conjunto (FALUDI, 2011). Além disso, é descrito como um conjunto de camadas implementadas sobre o IEEE 802.15.4 (FALUDI, 2011), ao qual especifica a Camada Física (PHY) e o controle de acesso ao meio (MAC) para redes WPAN. (IEEE, 2011).

¹https://www.android.com/intl/pt-BR_br/

²<https://www.google.com>

As camadas do Zigbee, de acordo com Faludi (2011), responsabilizam-se pelo:

- **Roteamento:** Tabelas de roteamento que definem como um nó envia dados até um destino.
- **Rede Adhoc:** Criação automática de rede.
- **Malha Auto-Curativa (do inglês, *Self healing mesh*):** Descobre se nós se perderam da rede e a reconfigura para garantir uma rota para os dispositivos conectados aos nós faltantes.

O Zigbee opera na faixa não licenciada ISM, de 2,4GHz, o que permite sua expansão global e, assim, ter a capacidade de operar em qualquer local do mundo. Além disso, especifica que os nós das redes criadas possam assumir papéis específicos (FALUDI, 2011), sendo eles:

- **Coordenador:** Responsável por criar a rede, distribuir endereços, manter a rede segura e em funcionamento entre outras funções. Cada rede tem um e apenas um coordenador.
- **Roteador:** Tem capacidade de unir redes existentes, enviar e receber informações e rotear informações, atuando como um intermediário entre dispositivos. É permitido às redes terem múltiplos roteadores, bem como, possuírem nenhum. No entanto, no caso de existirem, cada roteador deve estar conectado a um coordenador ou outro roteador.
- **Dispositivo final:** É um tipo de nó capaz de se unir a redes e de enviar e receber informações da rede. Além disso, podem se desligar de tempos em tempos para poupar energia. Caso mensagens para um dispositivo final desligado sejam detectadas, o nó responsável por ele, podendo ser um coordenador ou roteador, armazena as mensagens até que o nó desperte.

Há diversas topologias suportadas que englobam os três tipos de nós e suas possíveis maneiras de organização (FALUDI, 2011):

- **Par a par:** Uma rede formada apenas por dois nós, sendo um deles, obrigatoriamente, um coordenador e o nó restante podendo ser um roteador ou dispositivo final.
- **Estrela:** Nesta topologia, o coordenador se situa no centro da rede e os demais nós, roteadores ou dispositivos finais, conectados apenas a ele, formando uma rede no formato de estrela.
- **Malha (do inglês, *Mesh*):** Os dispositivos finais circundam os demais nós roteadores e coordenador. O coordenador e roteadores atuam como intermediários, roteando mensagens para dispositivos finais, outros roteadores ou para o coordenador. Apesar da

nova função do coordenador, este permanece no controle e gerenciamento da rede.

- **Árvore de agrupamento (do inglês, *Cluster tree*):** Nessa topologia, cada roteador é responsável por um conjunto de dispositivos finais. As mensagens vindas desses dispositivos devem ser encaminhadas primeiramente para seu roteador responsável para então ser encaminhada ao destino na rede.

O Zigbee define três maneiras de identificação de nodos, que podem ser utilizadas em uma aplicação para diferenciar os nós.

- **64 bits:** Único e permanente para cada rádio fabricado.
- **16 bits:** Dinamicamente configurado pelo coordenador ao entrar em uma rede. É único apenas dentro do contexto da rede.
- **Node Id:** Pequena cadeia de texto. Não é possível garantir sua unicidade em nenhum contexto.

2.3.5 Wi-Fi

Wi-Fi, uma das diversas classes de redes WLAN, é normatizado pelo padrão IEEE 802.11, no qual foca nas camadas física e de enlace do modelo *Open System Interconnection* (OSI) (GAST, 2005). Além disso, há padrões específicos para o Wi-fi, como o 802.11a, 802.11b e 802.11g, além da possibilidade de unir alguns de padrões para formar outros híbridos, como o 802.11a/g e 802.11a/b/g (KUROSE; ROSS, 2012).

Apesar da distinção, os padrões citados compartilham diversas características, como o protocolo de acesso ao meio, estrutura de quadros da camada de enlace, habilidade de reduzir a taxa de transmissão a fim de alcançar distâncias maiores. A principal diferença é vinculada à camada física.

Os padrões a, b e g são regulamentados de acordo com a Tabela 1, sendo que pode variar em diversos países.

Tabela 1 – Resumo dos protocolos 802.11

Padrão	Faixa de Frequências	Taxa de dados
802.11b	2,4 - 2,485 GHz	até 11 Mbps
802.11a	5,1 - 5,8 GHz	até 54 Mbps
802.11g	2,4 - 2,485 GHz	até 54 Mbps

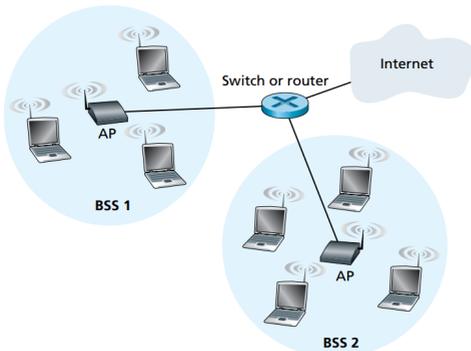
Fonte: Adaptado de Kurose e Ross (2012)

Além dos três protocolos citados há outros mais recentes ou que

estão em fase de criação. O protocolo 802.11n, por exemplo, criado em 2012, faz uso de múltiplas antenas e, além disso, permite atingir uma taxa de transmissão de centenas de megabits por segundo (KUROSE; ROSS, 2012). Há também o 802.11ac e, entre os mais recentes, o 802.11ax, ainda em estágio de desenvolvimento e que permitirá o uso eficiente do espectro além de aprimorar a experiência de usuário (AFAQUI; GARCIA-VILLEGAS; LOPEZ-AGUILERA, 2017).

A arquitetura básica do IEEE 802.11, exposta na Figura 3, é formada por *Basic Service Set* (BSS) onde cada um é composto de um *Access Point* (AP), um dispositivo para unir os conjuntos, sendo esse um roteador ou *switch*, responsável por ligar cada BSS à Internet e, por fim, os dispositivos que desejam se conectar a rede.

Figura 3 – Arquitetura básica para o IEEE802.11.



Fonte: Kurose e Ross (2012).

O IEEE 802.11 suporta dois tipos de interconexão de dispositivos: *ad-hoc* e ponto de acesso com dispositivo. No primeiro caso, é possível interconectar dispositivos, como *notebooks*, sem a necessidade de uma infraestrutura de rede, no entanto, com a impossibilidade de conexão à Internet. Assim, é possível efetuar transferência de arquivos de maneira rápida e sem cabos. Além de redes *ad-hoc*, suporta conexões entre um ponto de acesso e um dispositivo para conexão com a Internet. Em diversos casos, o AP e o roteador estarão incorporados em um mesmo dispositivo (KUROSE; ROSS, 2012).

Existem algumas funcionalidades mais avançadas no IEEE 802.11. Uma delas se refere à possibilidade de se adaptar a taxa de dados a partir da escolha da técnica de modulação da camada física de acordo com as características do canal. Há também a possibilidade de reduzir o consumo de energia fazendo com que o nó permaneça em modo *sleep*

por determinados períodos de tempo o que pode gerar uma economia de até 99% (KUROSE; ROSS, 2012).

No contexto da IoT, o Wi-fi é fundamental na inserção de novos dispositivos à Internet. O seu uso propiciará o crescimento destes sem a necessidade da expansão da infraestrutura a cada novo objeto conectado (SURESH et al., 2014).

2.3.6 Outros

Entre as tecnologias utilizadas em Smart Homes está o Z-Wave, um protocolo sem fio focado em automação residencial e comercial de pequeno porte, criado pelo ZenSys e hoje representado pela *Z-Wave Alliance* (GOMEZ; PARADELLS, 2010). O protocolo foi desenvolvido especificamente para controle, monitoramento e verificação de estado. Em relação a aspectos técnicos, o Z-Wave opera na faixa de frequências em torno de 1GHz, o que evita interferências com outras tecnologias como *Bluetooth* e Wi-Fi que operam em 2,4GHz, em geral. Entre as principais vantagens do Z-Wave está a interoperabilidade, além da segurança obtida a partir do uso de criptografia AES128 (Z-WAVE ALLIANCE, 2015).

Por outro lado, há a tendência de dispositivos IoT conectados à Internet usarem o protocolo de endereçamento IPv6 para serem identificados na rede. No entanto, algumas das aplicações terão limitações como fonte de energia e capacidade de transferências de dados limitadas. Como proposta de solução, tem-se o *IPv6 Over Wireless Personal Area Network* (6LoWPAN), definido no RFC 6282 pela *Internet Engineering Task Force* (IETF), focado em dispositivos com restrições de consumo de energia (OLSSON, 2014). A principal característica desse protocolo é a redução da transmissão de dados a partir da compressão dos cabeçalhos do IPv6. Com isso, o 6LoWPAN é capaz de reduzir a sobrecarga de pacote para dois bytes (AL-FUQAHA et al., 2015). As redes 6LoWPAN são conectadas às redes IPv6 a partir de roteadores de borda, capazes de trocar dados entre os dispositivos dentro da rede 6LoWPAN e a Internet, além de serem responsáveis por manter a rede em funcionamento. Outra característica importante neste padrão é a viabilidade de se implementar o IPv6 em redes IEEE 802.15.4 (OLSSON, 2014).

2.4 AMBIENTES INTELIGENTES

A IoT vem promovendo avanços tecnológicos importantes nos mais diversos ambientes, aprimorando desta maneira funcionalidades já existentes ou promovendo novas. A seguir, alguns ambientes em destaque são expostos e como a IoT atua nestes casos.

2.4.1 Smart Grid

Na rede elétrica tradicional, a inteligência, ou seja, o controle, sensoriamento etc., é concentrada nas unidades geradoras de energia e parcialmente nos distribuidores. Além disso, o fluxo de energia é unidirecional, seguindo apenas um caminho entre a geração e o consumo. No entanto, com o aumento do uso de fontes próprias de geração de energia em residências, como placas fotovoltaicas, além do crescimento do consumo, tem-se a necessidade de adaptação do modelo de rede elétrica existente. As *smart grids* surgiram, então, como modelo alternativo de geração e distribuição de energia elétrica, onde o fluxo de energia passa a ser bidirecional e o uso de tecnologias de medições de consumo permitem prever demandas, otimizar a distribuição e aprimorar a eficiência e a confiabilidade do sistema elétrico (CECILIA; SUDARSANAN, 2016).

2.4.2 Smart Home

O conceito de *smart home* ou casa inteligente propõe um novo modelo para um ambiente domiciliar. A implementação e o uso da tecnologia nesse ambiente abrem espaço para novas formas de interação, além de proporcionar mais comodidade e um melhor gerenciamento dos equipamentos presentes. Isso será possível graças ao uso de sensores e atuadores tanto no ambiente, como nos eletrodomésticos e utensílios. E, para interconectar todos os dispositivos, será feito uso das tecnologias de rede existentes, como o Zigbee e a Internet.

A interconexão dos dispositivos em uma casa inteligente proporcionará novas funcionalidades de interação de acordo com as ações e preferências dos moradores. Um exemplo é apresentado por Silva et al. (2012) declarando que seria possível a implementação de um sistema controlasse as luzes de acordo com a presença ou não do indivíduo e da hora do dia.

Entre as apostas para as casas inteligentes está o aumento da

eficiência do consumo energético. O uso da tecnologia por meio de medidores de energia, tomadas e aparelhos inteligentes permitirá o monitoramento e controle do consumo dos dispositivos da casa. Com base nisso, é viável a otimização do consumo de cada equipamento controlando-o para ativá-lo somente quando necessário e, assim, evitar desperdícios. Além disso, é viável a previsão da demanda de energia para cada momento do dia (STOJKOSKA et al., 2017).

As casas inteligentes necessitam que os dispositivos sejam organizados hierarquicamente para garantir o bom desempenho dos componentes do sistema. Stojkoska et al. (2017) propõe um modelo, ilustrado na Figura 4, para organização de casa inteligente que integra *smart grid* e envolve cinco componentes principais: a casa inteligente em si, a nuvem, unidade geradora de energia, aplicações de terceiros e interfaces de usuário. Nesse contexto, a casa inteligente contém redes de sensores sem fio que adquirem dados do ambiente e enviam esses dados para um *home hub*, um ponto central capaz de se conectar à uma rede externa. Já a unidade geradora de energia é responsável por, além da geração e fornecimento de energia, trocar informações sobre custo da energia, consumo atual e futuro da casa entre outros. A nuvem é responsável por armazenar todos os dados provenientes de sensores e outros dispositivos da casa e por comportar uma infraestrutura de processamento.

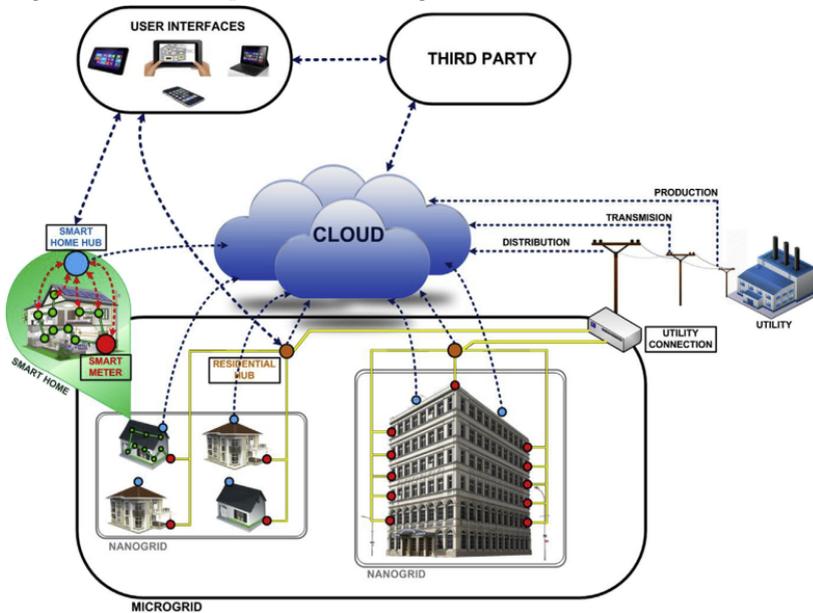
A partir dos dados existentes na nuvem é possível que as aplicações de terceiros entreguem soluções web ou aplicações mobile para os usuários. Para obter acesso às soluções, o último componente é necessário: a interface de usuário. Nesse ponto, o usuário tem em mãos a capacidade de monitorar em tempo real os gastos de energia dos equipamentos de sua casa, bem como controlá-los de acordo com a sua necessidade e desejo.

Uma casa inteligente permite que os moradores tenham maior independência no seu dia a dia, especialmente em caso de pessoas idosas, com dificuldade de locomoção, além daquelas com deficiências físicas e visuais. Silva et al. (2012) propõe um sistema que usa imagens de uma casa, capaz de detectar o dia a dia de uma pessoa idosa. É possível, também, identificar possíveis quedas e avisar o responsável ou o atendimento médico. Apesar da aplicação citada possuir um enfoque no morador, não há muitas propostas para casa inteligente com o foco nos usuários. No entanto, existem muitas que focam nos aspectos técnicos, como dispositivos, arquiteturas entre outros (WILSON; HARGREAVES; HAUXWELL-BALDWIN, 2015).

A empresa *Amazon*®³ oferece o *Amazon Echo*, um dispositivo

³<https://www.amazon.com/>

Figura 4 – Modelo para casas inteligentes.



Fonte: Stojkoska et al. (2017).

que dispõe de diversas funcionalidades multimídia, como reprodução de músicas através de controle por voz, além de oferecer informações como previsão do tempo, notícias, tráfego entre outros através do *Alexa Voice Service* (Serviço de Voz Alexa). É capaz de controlar a luz, tomadas e termostatos além de ser compatível com produtos de empresas como SAMSUNG⁴, Philips⁵ entre outras, com foco em *smart homes* (AMAZON, 2017).

Seguindo a lógica das casas inteligentes, as *Smart Kitchens* ou cozinhas inteligentes, promovem o aprimoramento dos dispositivos da cozinha com a inserção da tecnologia. Utensílios como panelas, talheres entre outros podem fazer uso de tecnologia para entregar novas funcionalidades (STÄNDER et al., 2012). Por exemplo, no caso das panelas, é possível utilizar sensores de temperatura e câmera para determinar a temperatura atual e o estado atual do alimento que está sendo cozido. A partir disso, o sistema computacional presente na panela, processa os dados e realiza a comunicação com o fogão para ajustar a intensidade

⁴<http://www.samsung.com/br/>

⁵<http://www.philips.com.br/>

do fogo caso ainda não esteja pronto, ou simplesmente, desligar o fogo, caso já esteja.

2.4.3 Outros

Entre os ambientes inteligentes em expansão está a cidade inteligente ou *smart city*. Apesar de não ter uma definição conceitual clara (COCCHIA, 2014), no contexto da IoT, a ideia principal por trás desse ambiente é trazer qualidade de vida aos cidadãos, crescimento sustentável e melhor uso de recursos públicos, aos quais são possíveis graças ao uso da IoT com foco no ambiente urbano. A IoT, neste contexto, permite uma melhor gerenciamento, otimização dos serviços públicos como transporte, iluminação, vigilância e manutenção de áreas públicas entre outros (ZANELLA et al., 2014).

Já no ambiente industrial, a IoT em conjunto com sistemas interconectados promoverá a Indústria 4.0, também chamada quarta revolução industrial. Ademais, os sistemas cyber-físicos, aos quais podem ser definidos como sistemas que integram processos físicos, computacionais, de comunicação e de rede, integrados com a Indústria 4.0, poderão ser definidos como a *smart factory* ou fábrica inteligente (LEE, 2015). Por outro lado, a Indústria 4.0 é vista como uma possível solução para problemas atuais como a poluição, o consumo de combustíveis fósseis, entre outros (HUSSAIN, 2016).

2.5 DESAFIOS

Apesar dos avanços constantes, a área de IoT terá de superar alguns desafios para que possa se expandir sem prejudicar o desempenho das aplicações e a experiência dos usuários. Esses desafios, segundo Hussain (2016), são a heterogeneidade dos dispositivos, a interoperabilidade, a escalabilidade, segurança, privacidade e Qualidade de Serviço (QoS).

O primeiro dos desafios, a heterogeneidade, se refere as diferenças de *hardware* e *software* dos dispositivos, bem como, seu propósito, como objetivos, plataforma de *hardware*, modos de interação, entre outros (HUSSAIN, 2016).

A Interoperabilidade diz respeito à capacidade de dispositivos, que usam diferentes tecnologias, terem a capacidade de trocar informações e utilizá-las para algum fim (ELKHODR; SHAHRESTANI; CHEUNG,

2016). Nesses casos, é necessário um dispositivo que atue como mediador ao qual tem acesso a ambas tecnologias para que a troca de dados ocorra (HUSSAIN, 2016).

Outro grande desafio é a escalabilidade. As aplicações de IoT devem suportar o crescimento do número de dispositivos conectados, usuários, aplicações, entre outros, sem qualquer comprometimento da Qualidade de Serviço (QoS). O aumento de dispositivos e afins deve ser refletido nos recursos que sustentam a IoT (HUSSAIN, 2016).

A segurança e privacidade, da mesma forma, requerem atenção. A restrição de recursos computacionais nos dispositivos torna difícil proteger as informações. Ainda assim, é necessário garantir transações seguras e o não comprometimento dos dados dos usuários. No entanto, os métodos tradicionais de segurança não podem ser utilizados, pois diferentes padrões estão envolvidos nas aplicações IoT (HUSSAIN, 2016). Portanto, há a necessidade de novos mecanismos, que garantam a segurança e privacidade, focados em aplicações IoT (ELKHODR; SHAHRESTANI; CHEUNG, 2016).

Por fim, a Qualidade dos Serviços em IoT vem sendo estudado com frequência. Entre os principais desafios estão a disponibilidade, a confiabilidade, a mobilidade, o desempenho, a escalabilidade, entre outros. No entanto, nem toda aplicação exige que os pontos citados sejam atendidos integralmente (HUSSAIN, 2016).

3 SISTEMAS DE RECOMENDAÇÃO

Neste capítulo, apresenta-se a área de SRs considerando um histórico, as principais abordagens e aplicações em que se inserem.

3.1 INTRODUÇÃO

A web tem proporcionado diversas formas de interação, seja entre usuários ou entre sistemas e como resultado, tem-se gerado uma grande quantidade de dados. Os usuários que lidam com esses dados brutos certamente terão dificuldades em assimilar alguma informação útil e de seu interesse. Se faz necessário, portanto, um modo de processar tal montante de dados e extrair informações relevantes (AGGARWAL, 2016). Entre os possíveis métodos estão os mecanismos de busca, em relação à páginas web (BRIN; PAGE, 1998), e SRs, em relação a itens.

SRs surgem como possível solução, com base na análise do perfil de cada usuário e, a partir deste, fornecer recomendações de itens que possam lhe interessar. Os itens recomendados podem ser filmes, livros, receitas, páginas web entre outros (BOBADILLA et al., 2013). Deste modo, a tarefa de SRs é transformar os dados e preferências dos usuários em previsões de itens aos quais pode-se demonstrar interesse (Lü et al., 2012).

As informações de preferências de usuário, utilizadas como entrada por SRs, podem ser adquiridas de duas maneiras: explícita ou implicitamente. No primeiro caso, o usuário é indagado sobre suas preferências, já no segundo, as informações são extraídas de acordo com o comportamento do usuário e sem o questionamento direto (BOBADILLA et al., 2013). No entanto, informações adicionais podem ser utilizadas (JANNACH et al., 2010). Deste modo, as fontes de informações utilizáveis são: avaliações de itens pelos usuários, conjunto de características específicas que o item deve possuir, além de detalhes sobre seu conteúdo.

Os SRs são subdivididos em abordagens, entre elas, a filtragem colaborativa, a baseada em conteúdo, a baseada em conhecimento entre outras. Estas diferem na forma como geram sugestões e nas informações que utilizam para a realização de sugestões (JANNACH et al., 2010).

3.2 HISTÓRICO

A web primordial ou Web 1.0 era estática, na qual a única perspectiva de interação era o consumo de conteúdo, ou seja, apenas a leitura se fazia possível. Era, portanto, amplamente utilizada por organizações na divulgação de seus produtos e serviços (AGHAEI; NEMATBAKSH; FARSANI, 2012).

A Web 2.0, por outro lado, agregou dinamicidade à Internet, desde a viabilização da interação entre usuários até a possibilidade de inserção de conteúdo na rede por parte desses, a partir de blogs e redes sociais, por exemplo (NATH; DHAR; BASISHTHA, 2014).

Com a Web 3.0, se deu a transformação da Web de Documentos, presente nas versões anteriores, para a Web de Dados, onde os diversos conteúdos deixam de se relacionar por links e passam a ser por dados e, assim, podem ser utilizados não apenas por usuários, mas por máquinas (AGHAEI; NEMATBAKSH; FARSANI, 2012).

Já se discute a Web 4.0, apesar de, conceitualmente, não estar bem definida. Propõe-se que, no futuro, haveria uma simbiose entre os computadores e as pessoas e, como consequência, seria possível a construção de interfaces mais poderosas, entre elas, as controladas pela mente (AGHAEI; NEMATBAKSH; FARSANI, 2012).

A ideia de fazer uso de todo o volume de dados por muitos usuários, com a Web 2.0, para auxiliar na procura por conteúdos mais úteis e interessantes, já existia desde a década de 1990 (JANNACH et al., 2010).

O primeiro sistema ao qual continha a ideia de recomendação de conteúdo, foi o PARC Tapestry System, que introduziu o conceito de filtragem colaborativa. Ademais, era um sistema experimental de e-mail, onde se objetivava categorizar o grande volume de mensagens eletrônicas recebidas em categorias de acordo com o interesse do usuário (GOLDBERG et al., 1992). Alguns anos mais tarde, o *GoodNews* foi desenvolvido com o foco em notícias, onde cada artigo era avaliado de acordo com a média de avaliações dos usuários e os melhores eram recomendados. Dessa forma, o sistema não levava em conta gostos individuais e eliminava, assim, a necessidade de armazenamento de dados de usuários. Outro sistema desenvolvido, o Ringo, provia recomendações aos seus usuários a cerca de músicas. Inicialmente o sistema fornecia avaliações de aproximadamente 125 artistas e, de acordo com as respostas era realizada uma avaliação do perfil. A aplicação, então, passava a recomendar novos artistas e álbuns que o usuário poderia gostar (RESNICK et al., 1994).

Os SRs surgiram em um contexto de alto crescimento de negócios

relacionados à Internet, o que fez com que a sua comercialização se iniciasse rapidamente. Assim, diversas companhias foram criadas como, *Pattie Maes*, *Net Perceptions*, entre outras. Por outro lado, não apenas pesquisadores apresentaram interesse, mas também profissionais da área de marketing. Por fim, desenvolveu-se novas abordagens baseadas em conceitos de inteligência artificial, recuperação de informação, mineração de dados, segurança, privacidade além de pesquisas em negócios e marketing (JANNACH et al., 2010).

3.3 FILTRAGEM COLABORATIVA (FC)

Em diversas ocasiões do cotidiano as pessoas requisitam opiniões de outras a cerca de certos produtos ou serviços, sejam filmes, restaurantes, equipamentos eletrônicos, entre outros. A opinião do indivíduo, então, influencia na escolha do outro e o ajuda a tomar uma decisão sobre o problema.

Por outro lado, um amigo recomenda a outro que assista um filme de ação em cartaz nos cinemas, sabendo que este ainda não assistiu-o e que gosta de filmes do gênero. O indivíduo que recebeu a sugestão certamente levará em conta o conselho, assistirá o filme, provavelmente gostará dele e recomendará a um outro amigo que também não viu o filme. Com base nesse contexto de recomendações entre indivíduos, tem-se o conceito de Filtragem Colaborativa (FC), em que, a partir de um perfil de preferências de um certo indivíduo, obtido através de seu histórico e em conjunto com as opiniões de outros usuários semelhantes a ele, prevê quais os itens possuem a maior possibilidade de gostar ou de se interessar (JANNACH et al., 2010).

Os sistemas baseados em filtragem colaborativa se utilizam da matriz de avaliações de itens pelos usuários, como mostrado na Tabela 2. Como saída, gera-se previsões de avaliações que usuários aplicariam para itens por eles não avaliados ou um conjunto de melhores itens para recomendação. Portanto, a partir do conjunto de dados da matriz, é possível fazer uso de algoritmos que levem em conta as avaliações de todo o conjunto de usuários, para então definir qual é a avaliação plausível para um determinado item ou quais itens recomendar (BOBADILLA et al., 2013).

Segundo Ricci et al. (2010), os métodos de filtragem colaborativa podem ser agrupados em duas classes: os baseados em memória ou em vizinhança e os métodos baseados em modelo. A principal diferença entre as abordagens está no modo de uso da matriz de avaliações na

Tabela 2 – Matriz de avaliações de itens por usuários

	Item 1	Item 2	Item 3	Item 4	Item 5	Item 6
Jack	5	4	2	?	5	1
Will	3	5	3	5	1	1
Elizabeth	5	3	3	4	2	4
Hector	3	5	4	5	4	4

Fonte: Elaborado pelo Autor

geração de recomendações.

3.3.1 Método de FC Baseado em Memória

Métodos de recomendação baseados em memória operam diretamente sobre a base de dados de avaliações de itens pelos usuários para geração de recomendações. Além disso, as recomendações estarão sempre atualizadas devido ao uso das mais recentes avaliações recebidas dos usuários (BOBADILLA et al., 2013).

Em geral, os sistemas produzem recomendações com base no conceito de vizinho mais próximos, onde o objetivo é encontrar semelhanças entre usuários ou entre itens com suporte nas diversas avaliações adquiridas pela base de dados (MUSTAFA et al., 2017). Por exemplo, se um usuário tem preferência em certos filmes de ficção científica e existe um outro que também tem algum gosto pelo gênero, ambos poderão ser classificados como vizinhos próximos. Em casos como esse, o grau de semelhança é obtido a partir de cálculos de similaridade.

3.3.1.1 Medidas de Similaridade

A similaridade entre usuários, itens, etc., podem ser obtidas a partir da matriz de avaliações dos usuários em relação ao itens. Os diversos algoritmos operam sobre as linhas ou colunas da tabela para encontrar um valor numérico que caracterize o grau de afinidade entre os objetos da comparação (AGGARWAL, 2016). Além disso, uma abordagem geométrica (JONES; FURNAS, 1987) pode ser utilizada para aprimorar a observação do comportamento desses algoritmos.

O grau de semelhança entre dois usuários pode ser mensurado a partir de sua correlação, na qual estima a relação linear entre ambos. Dentre os diversos métodos, a correlação de *Pearson* avalia ve-

tores de mesma dimensão (RICCI et al., 2010). Considerando, um conjunto de produtos $P = \{p_1, p_2, \dots, p_n\}$, um conjunto de usuários $U = \{u_1, u_2, \dots, u_m\}$ e uma matriz de avaliações $R = \{r_{1,1}, r_{1,2}, \dots, r_{n,m}\}$ desses produtos em função dos usuários, com dimensão $n \times m$, tem-se a Equação 1 que descreve a correlação de Pearson entre dois usuários a e b .

$$\text{sim}(a, b) = \frac{\sum_{p \in P} (r_{a,p} - \bar{r}_a)(r_{b,p} - \bar{r}_b)}{\sqrt{\sum_{p \in P} (r_{a,p} - \bar{r}_a)^2} \sqrt{\sum_{p \in P} (r_{b,p} - \bar{r}_b)^2}} \quad (1)$$

Observa-se, inicialmente, a subtração de cada posição pelo valor médio das avaliações, o que reduz o efeito negativo, no cálculo, das notas de um determinado usuários que, em sua maioria, são ou altas, ou baixas. Além disso, tem-se um produto interno como numerador e a multiplicação dos comprimentos dos vetores de avaliação de cada usuário como denominador. Como possíveis resultados, a correlação de Pearson gera valores entre -1 a 1 , onde o primeiro indica correlação negativa perfeita, ou seja, usuários com preferências opostas, e o segundo demonstra correlação positiva perfeita, implicando em gostos equivalentes entre os usuários (JANNACH et al., 2010).

Como exemplo, considerando a Tabela 2, deseja-se encontrar a similaridade entre os usuários Will e Elizabeth a partir de suas respectivas avaliações para os seis (6) itens e a correlação de Pearson. Fazendo uso da Equação 1, tem-se o seguinte cálculo:

$$\begin{aligned} \text{sim}(W, E) &= \frac{(3-3)(5-3,5) + (5-3)(3-3,5) + \dots}{\sqrt{(3-3)^2 + (5-3)^2 + \dots} \sqrt{(5-3,5)^2 + (3-3,5)^2 + \dots}} \\ \text{sim}(W, E) &= 0,21 \end{aligned}$$

Os usuários Will e Elizabeth têm portanto uma similaridade medida pela correlação de Pearson de 0,21 indicando que ambos têm alguma semelhança entre suas preferências.

Em relação a similaridade de itens, o método do *coseno* é considerado o padrão. Como base para o seu cálculo, se faz uso das avaliações dadas por todos os usuários a cada item, ou seja, as colunas da matriz de avaliação são utilizadas. No entanto, o método do *coseno* não leva em conta o perfil de cada usuário ao considerar apenas a avaliação dada ao item em questão (JANNACH et al., 2010).

A Equação 2 define o cálculo de similaridade pelo método do

cosseno onde, calcula-se o produto interno entre os vetores de avaliações dos itens, como numerador e a multiplicação dos comprimentos de cada um como denominador.

$$sim(a, b) = \frac{\sum_{u \in U} (r_{u,a})(r_{u,b})}{\sqrt{\sum_{u \in U} (r_{u,a})^2} \sqrt{\sum_{u \in U} (r_{u,b})^2}} \quad (2)$$

Em outras palavras, para cada usuário u pertencente ao conjunto de usuário U , é calculada a multiplicação das suas avaliações para cada item e somada aos demais resultados da operação e, por fim, calcula-se o módulo de cada vetor. Um outra interpretação para o cálculo é considerar como sendo o produto interno entre os vetores de avaliação normalizados (JONES; FURNAS, 1987). Assim, com a divisão pelo comprimento, os possíveis resultados permanecem entre 0 e 1 (JANNACH et al., 2010), sendo que geometricamente, esses resultados podem ser avaliados como ângulos. As avaliações de um item podem ser consideradas componentes de um vetor que representa o objeto. Inserindo, então, os vetores num plano será formado um ângulo θ no qual, no contexto das avaliações de itens é obtido a partir do arco cosseno do resultado da similaridade. Quanto mais próximo esse ângulo estiver de zero grau (0°), maior será a semelhança entre os itens.

Como exemplo, pretende-se encontrar o grau de similaridade entre Item 2 e Item 5 da Tabela 2. Para tanto, considera-se as respectivas colunas de avaliações que usuários forneceram à cada um dos itens e a Equação 2. Por fim, tem-se o seguinte cálculo:

$$\begin{aligned} sim(2, 5) &= \frac{(4 \cdot 5) + (5 \cdot 1) + (3 \cdot 2) + (5 \cdot 4)}{\sqrt{4^2 + 5^2 + 3^2 + 5^2} \sqrt{5^2 + 1^2 + 2^2 + 4^2}} \\ sim(2, 5) &= 0,87 \end{aligned}$$

Os itens 2 e 5, portanto tem alta similaridade. Além disso, ao considerar a visão geométrica, têm-se um ângulo de $29,5^\circ$ formado entre os itens.

Como dito anteriormente, o método do cosseno não leva em conta o perfil de avaliações do usuário no cálculo da similaridade entre itens, no entanto, um método semelhante chamado *cosseno ajustado*, corrige essa imperfeição. Primeiramente, define-se o cálculo pela Equação 3.

$$sim(a, b) = \frac{\sum_{u \in U} (r_{u,a} - \bar{r}_u)(r_{u,b} - \bar{r}_u)}{\sqrt{\sum_{u \in U} (r_{u,a} - \bar{r}_u)^2} \sqrt{\sum_{u \in U} (r_{u,b} - \bar{r}_u)^2}} \quad (3)$$

Observa-se, então, que o ajuste se refere à subtração da média das avaliações dadas pelo usuário u a todos os itens. Assim, o efeito negativo causado pela média, alta ou baixa de avaliações do usuário é reduzido, deslocando as avaliações para a média do usuário ao invés da média do item. Além disso, o intervalo de valores possíveis com o método do cosseno ajustado, neste contexto, é de -1 a 1 (JANNACH et al., 2010; RICCI et al., 2010). Por outro lado, nota-se a semelhança do método do cosseno ajustado em relação à correlação de Pearson, descrita na Equação 1. No entanto, apesar de semelhantes, os contextos aos quais aplica-se cada método é diferente. A correlação de Pearson é utilizada para o cálculo de similaridade entre usuários, já o cosseno ajustado destina-se a encontrar a semelhança entre itens, apesar de ambas fazerem uso da média de avaliações de cada usuário.

3.3.1.2 Vizinhos Mais Próximos

O algoritmo k *Nearest Neighbors* (kNN) é um dos principais algoritmos para geração de recomendação e predições de avaliações (BOBADILLA et al., 2013), além de ter o objetivo geral de operar como classificador. Assim, dado um ponto em um espaço, o kNN encontrará os k pontos mais próximos com base em um conjunto de outros pontos pré-classificados relevando a classe de pertinência de determinado objeto.

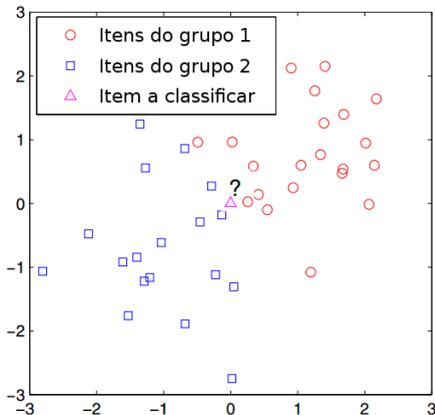
Como exemplo, a Figura 5 traz dois conjuntos de pontos, azuis mais abaixo na imagem e vermelhos acima. Em meio a esses pontos, há um outro, rosa, ao qual deseja-se saber à qual grupo pertence (independentemente de sua cor).

A partir de cálculos de similaridade o algoritmo encontrará os k pontos mais próximos, onde tal valor varia de acordo o contexto da aplicação. Duda, Hart e Stork (2000) sugerem um k igual a raiz quadrada do total de pontos n , ou seja, k é igual \sqrt{n} , no âmbito geral de classificadores, já no contexto de SRs, onde há bases com milhares de usuários, Jannach et al. (2010) afirma que k entre 20 a 50 é uma boa estimativa.

Em um aspecto gráfico, k pode ser interpretado como o número de pontos aos quais podem ser inseridos dentro de um círculo centrado no ponto que será classificado, como pode ser visualizado na Figura 6.

O algoritmo de k vizinhos mais próximos opera em três etapas, sendo a primeira, a determinação dos vizinhos mais próximos do usuário x conforme cálculos de similaridade. A seguir, previsões são com-

Figura 5 – Exemplo de grupos para classificação com o kNN



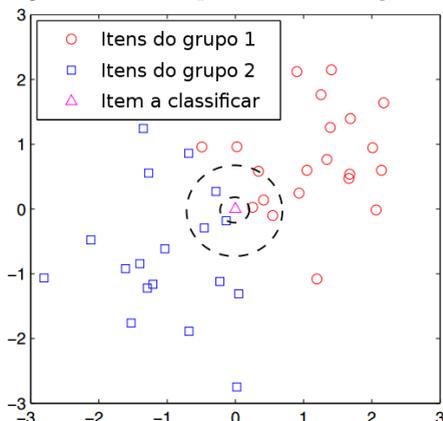
Fonte: Adaptado de Ricci et al. (2010)

putadas sobre as avaliações que x atribuiria a itens, aos quais, ainda não conhece, a partir de funções de agregação como, por exemplo, média e soma ponderada de notas de outros usuários ao item. Por fim, com base nas avaliações obtidas, os m itens com melhores notas são recomendados ao usuário (BOBADILLA et al., 2013).

O kNN pode ser aplicado nas duas categorias de filtragem colaborativa baseada em memória. A primeira delas é *baseada em usuário*, onde as sugestões são fundamentadas em outros utilizadores com preferências semelhantes. Assim, os itens recomendados não foram comprados pelo usuário ou este não os conhece, no entanto, os mais semelhantes o fizeram (RICCI et al., 2010). Contudo, a abordagem tem um custo elevado para processamento da matriz de avaliações e geração de recomendações, onde, a cada recomendação produzida todos os cálculos são re-executados, ou seja, opera em modo *online*.

A segunda abordagem é *baseada em item*, onde um item i é avaliado e indicado com base nas notas que o usuário u forneceu para itens similares aquele em questão. Itens são, então, similares se diversos usuários os avaliaram de maneira equivalente (RICCI et al., 2010). Todavia, o desempenho em termos de processamento, comparada à abordagem anterior, é superior, já que parte considerável do processamento pode ser feito *offline* (JANNACH et al., 2010; MIRANDA, 2010).

Figura 6 – Exemplo de classificação com o kNN



Fonte: Adaptado de Ricci et al. (2010)

3.3.2 Método de FC Baseado em Modelo

SRs baseados em modelo não fazem uso direto da matriz de avaliações para geração de recomendação, contudo, ela é utilizada para o aprendizado de um modelo que fará as recomendações (ADOMAVICIUS; TUZHILIN, 2005). Primeiramente, os dados de avaliações são processados internamente, ou seja, *offline*, antes mesmo de recomendações serem calculadas. Assim, no momento em que se recomendar itens apenas o modelo será necessário (JANNACH et al., 2010). Entre as possíveis métodos para recomendação baseada em modelo tem-se a fatoração de matriz, métodos probabilísticos, redes neurais e baseados em regras de associação, como será descrito nas seções seguintes.

3.3.2.1 Fatoração de Matriz

Os modelos de fatoração de matriz levam em conta usuários e itens para explicar as avaliações providas a partir de vetores de fatores resultantes da inferência dos padrões de notas (KOREN; BELL; VOLINSKY, 2009). Tais fatores podem ser considerados características do item como, por exemplo, no contexto de livros, o autor, o gênero, no entanto, podem não ser interpretáveis, ou seja, não se consegue determinar a qual característica se refere. A partir disso, recomendações serão realizadas quando usuários e itens forem semelhantes em relação

a esses fatores (JANNACH et al., 2010). Por outro lado, o uso de avaliações explícitas pode não ser possível, devido à quantidade insuficiente de notas atribuídas por cada usuário. Apesar disso, o método permite o emprego de informações adicionais para obter as preferências de usuários. Avaliações implícitas obtidas a partir de seu comportamento, além de históricos de compra, navegação e padrões de busca são utilizáveis nesse contexto (KOREN; BELL; VOLINSKY, 2009).

Entre as diversas técnicas existentes para encontrar os fatores latentes, há o método de *Singular Value Decomposition* (SVD). Neste modelo, cada item é ligado com um vetor q_i , no qual, os elementos indicam o quanto o item possui os fatores do vetor. Cada usuário é associado a um vetor p_u , que indica o grau de interesse do usuário nos itens que tem tais fatores altos ou baixos. Nesses casos, os valores que os fatores podem assumir estão entre -1 e 1 . A Equação 4 demonstra o cálculo para predição de avaliações do usuário u ao item i (RICCI et al., 2010).

$$\hat{r}_{ui} = \mu + b_u + b_i + q_i^T p_u \quad (4)$$

Ao efetuar o produto $q_i^T p_u$ exprime-se o interesse do usuário nas propriedades do item. Os demais termos da Equação 4 indicam a média global de avaliações de todos os itens (μ) e os desvios, em relação a μ , do usuário (b_u) e do item (b_i) (RICCI et al., 2010).

Por fim, o SVD é capaz de gerar boas recomendações, entretanto é computacionalmente caro e deve ser executado *offline*. Além disso, pode ser aplicado apenas em situações em que as informações de preferências não mudam com o tempo (BOBADILLA et al., 2013).

3.3.2.2 Métodos Probabilísticos

Os métodos probabilísticos procuram inferir a partir do uso de conceitos de estatística e probabilidade, as expectativas de eventos ocorrerem. No contexto de SR, significa mensurar a possibilidade de um usuário avaliar um determinado produto com a nota determinada. Para tanto, pode-se considerar a predição como um problema de classificação, onde se deseja colocar um objeto, entre diversas categorias, naquela que melhor se enquadra (JANNACH et al., 2010).

Entre os diversos métodos está o classificador de Bayes ao qual avalia a probabilidade de um evento ocorrer com base em outros eventos, ou seja, dados um conjunto de acontecimentos já decorridos no passado, qual a probabilidade de um determinado evento ocorrer no

futuro. Assim, o teorema de Bayes, descrito pela Equação 5, pode ser usado para o cálculo da probabilidade para o evento (AGGARWAL, 2016).

$$P(A | B) = \frac{P(B | A) \cdot P(A)}{P(B)} \quad (5)$$

Considerando-se os eventos A e B, a Equação 5 define a expectativa de o evento A ocorrer no futuro sabendo que B transcorreu ($P(A | B)$). Tal possibilidade é determinada a partir da probabilidade do evento A e B ocorrerem sem considerar um ao outro ($P(A)$ e $P(B)$, respectivamente) e a probabilidade do evento B ocorrer em função de A ($P(B | A)$).

No contexto de SRs o evento A, presente na Equação 5, é visto como a probabilidade do usuário u promover uma determinada nota v_s , dentre as possíveis notas, ao item i , tendo como base as avaliações já fornecidas por u (AGGARWAL, 2016).

$$P(r_{ui} = v_s | r_u) = \frac{P(r_{ui} = v_s) \cdot P(r_u | r_{ui} = v_s)}{P(r_u)} \quad (6)$$

O método probabilístico com o Teorema de Bayes apresenta algumas vantagens, entre elas, a compensação de pontos de ruídos nos dados de treinamento, não ter *overfitting*, ou seja, não gera resultados com boa precisão apenas o conjunto de dados de treinamento, podendo assim aprender com modelos generalizados, além de ser capaz de operar com um conjunto de dados pequeno (JANNACH et al., 2010).

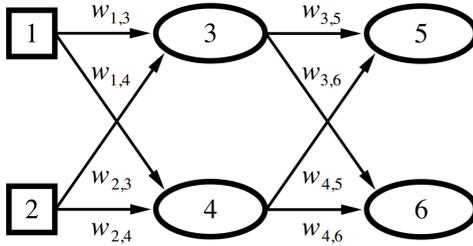
3.3.2.3 Redes Neurais

Redes Neurais Artificiais (RNAs) tentam retratar, de forma matemática, o comportamento do cérebro biológico, ao qual é formado por células chamadas neurônios e suas diversas interconexões, onde, a cada uma das ligações, é atribuído um peso. Desse modo, a aprendizagem consiste em alterar, a partir de treinamento, os valores de cada peso a fim de se ter um comportamento específico para a rede. Além disso, a entrada e saída da rede é composta por um conjunto de sinais de entrada e de neurônios, respectivamente, que são ligados a parte externa da rede. (RUSSELL; NORVIG, 2009).

A Figura 7 mostra uma RNA chamada *Multilayer Perceptron* (MLP), onde os neurônios são representados por elipses e sinais de

entrada por quadrados. As conexões entre eles são indicadas por setas com os pesos a elas associados. A RNA mostrada tem duas entradas, representadas pelos sinais um (1) e dois (2); dois neurônios, três (3) e quatro (4), na camada intermediária, também chamada oculta e, por fim, mais dois neurônios, cinco (5) e seis (6) na camada de saída.

Figura 7 – Rede MLP



Fonte: Extraído de Russell e Norvig (2009)

Redes neurais são capazes de aprender os padrões em dados de entrada e atuarem como classificadores. Entre as principais vantagens de RNAs de múltiplas camadas entre os demais classificadores é a capacidade de lidar com funções não-lineares, ou seja, a relação entre entradas e saídas é variável. (AGGARWAL, 2016).

No contexto de SRs, redes neurais podem ser utilizadas para detectar padrões nas avaliações atribuídas pelos usuários aos diversos itens, e a partir disso, fazer predições de notas à itens que o usuário ainda não avaliou (RICCI et al., 2010). Assim, considerando uma matriz de avaliações de usuários para itens, como na Tabela 2, a forma com a qual o usuário *Jack* avaliaria o *Item 4* pode ser determinada por RNA.

3.3.2.4 Baseado em Regras de Associação

Há uma relação entre sistemas baseados em regras e os SRs baseados em regras, onde o primeiro foi proposto para a descoberta das relações entre transações. Assim, busca-se, por exemplo, descobrir qual a relação de compra de produtos entre as diversas transações, ou seja, se a aquisição de um item pode implicar na compra de outro (AGGARWAL, 2016).

Recomendações são feitas para um usuário com base nas regras de associação que melhor se encaixam no seu histórico de transações. Por fim, a partir de informações de relação de compras de produtos é possível aplicar promoções e mudanças de *layout* de estabelecimentos,

ou seja, disposição das gôndolas, visando impactar positivamente na venda de produtos (JANNACH et al., 2010).

3.4 ABORDAGEM BASEADA EM CONTEÚDO

SRs baseados em conteúdo, aos quais têm como origens as pesquisas de filtragem de informação e recuperação de informação (CAZELLA; NUNES; REATEGUI, 2010), tentam recomendar itens ao usuário de acordo com as características de itens que ele gostou e das características do item em específico (RICCI et al., 2010). A recomendação será feita a partir da correspondência do perfil do usuário com as características dos itens. Assim, para esse tipo de sistema necessita-se apenas dos dados referentes aos itens, ou seja, sua descrição, e às preferências de usuário, isto é, seu perfil, não carecendo de uma grande comunidade de usuários para fazer recomendações. (JANNACH et al., 2010).

3.4.1 Descrição do Item

Um item pode ser descrito em termo de seus atributos ou de seu conteúdo. No contexto de SR baseado em conteúdo essa definição pode ser obtida a partir de duas formas, sendo elas a explícita e implícita (JANNACH et al., 2010). A forma explícita faz uso de características bens definidas dos itens. No caso de um livro, por exemplo, essas características são autor, gênero, preço, número de páginas entre outros. Em um SR essas informações devem ser inseridas manualmente para que possam ser utilizadas nos algoritmos. Por outro lado, a forma implícita faz uso de algoritmos que extraem informações dos itens. Além disso, essa abordagem é amplamente utilizada no contexto de recomendação de documentos textuais como, por exemplo, artigos científicos (GARCIA; FROZZA, 2013).

Entre as diversas abordagens de representação de itens textuais está o modelo vetor de espaço baseado em palavras-chave. Nesse caso, busca-se representar um documento por um conjunto de palavras que melhor o descrevem (JANNACH et al., 2010). Como forma de encontrar os termos mais relevantes em um documento, pode-se utilizar o cálculo do TF-IDF (MANNING; RAGHAVAN; SCHÜTZ, 2008).

O TF-IDF é composto de um produto de dois valores, o *Term Frequency* (TF) e a *Inverse Term Frequency* (ITF). O primeiro indica a frequência de cada termo no texto, no entanto, documentos maiores

terão frequências maiores para as palavras e os documentos menores o contrário, tornando injusta a medição por frequência absoluta. Por isso, é necessária uma normalização (JANNACH et al., 2010).

A Equação 7 apresenta o cálculo do TF, onde calcula-se a frequência normalizada de um termo i em um item j com base na frequência absoluta do termo no documento dividido pela número de ocorrências da palavra mais frequente no documento (JANNACH et al., 2010).

$$\text{TF}(i, j) = \frac{\text{freq}(i, j)}{\max\text{Outros}(i, j)} \quad (7)$$

Já o IDF tem por objetivo reduzir o impacto de palavras demasiadamente frequentes, ou seja, que são comuns em diversos documentos, como preposições e artigos. A Equação 8 demonstra o cálculo do IDF para o termo i de acordo com o número total de documentos recomendáveis N e $n(i)$, o número de documentos em que i aparece (JANNACH et al., 2010).

$$\text{IDF}(i) = \log \left(\frac{N}{n(i)} \right) \quad (8)$$

O cálculo de TF-IDF é, portanto, definido pela Equação 9

$$\text{TF-IDF}(i, j) = \text{TF}(i, j) \cdot \text{IDF}(i) \quad (9)$$

Por fim, técnicas são necessárias para eliminar termos irrelevantes do documento. A primeira se refere a retirada de palavras presentes em uma determinada lista (chamada de *stop list*), como artigos e preposições. Outra técnica, a lematização, consiste em substituir palavras semelhantes por sua palavra original, como “ligado”, “ligou” e “liga” poderiam ser trocadas por “ligar”. Outra maneira é reduzir o tamanho do vetor que representa o item para as n palavras que melhor o representam (JANNACH et al., 2010).

3.4.2 Perfil de Usuário

O perfil do usuário consiste num conjunto de características em que demonstrou-se, no passado, interesse por parte do indivíduo. Além disso, tal perfil pode ser adquirido de duas maneiras: explícita ou implicitamente. Na abordagem explícita, o usuário é diretamente indagado sobre seus gostos e preferências através de um conjunto de questionamentos elaborados pelo sistema e, fundamentando-se nas respostas, o

perfil é traçado (ADOMAVICIUS; TUZHILIN, 2005).

Na forma implícita, por outro lado, é utilizado o histórico do usuário para extrair suas preferências a partir de algoritmos de aprendizado de máquina ou *machine learning*. Segundo Mitchell (1997), aprendizado de máquina consiste em permitir que um computador aprenda a executar um conjunto de tarefas a partir de um conjunto de dados de experiências prévias. Entre as técnicas de aprendizado de máquina aplicadas à extração de perfil de usuário estão Árvores de Decisão, Redes Neurais, *Feedback* de Relevância, além da computação evolucionária a partir de algoritmos genéticos e, por fim, métodos probabilísticos (RICCI et al., 2010).

3.4.3 Recomendação

Recomendações são feitas, no contexto de vetores de espaço, a partir da combinação dos vetores que descrevem os itens com o vetor que descreve as preferências de usuário. Assim, os itens com maiores semelhanças com o perfil do usuário são recomendados (AGGARWAL, 2016).

3.5 BASEADA EM CONHECIMENTO

Quando se trata de recomendar, nem sempre se terá à disposição uma base de dados com o histórico de interações de usuários. Além disso, mesmo com a existência de tal base, os dados contidos podem não ser úteis quando trata-se de itens com longa duração como carros, casas, entre outros, onde a ocorrência de compras é muito baixa, em torno de anos (JANNACH et al., 2010). Assim, as abordagens descritas anteriormente, ou seja, baseada em filtragem colaborativa e baseada em conteúdo, não são aplicáveis já que não há uma base de dados confiável para extrair informações e traçar um perfil para cada usuário (RICCI et al., 2010). Por outro lado, há ocasiões em que o usuário esteja disposto a adquirir um produto que possua um conjunto de características específicas.

Em meio às situações descritas, surge uma abordagem denominada recomendação baseada em conhecimento. Essa abordagem explora outros meios de informações, sendo elas informações sobre o usuário e sobre o item. Assim, pode ser descrita como uma forma de se obter um conjunto de itens para recomendação aos quais satisfazem um con-

junto de restrições definidas pelo usuário, podendo ser características, recursos, etc. (JANNACH et al., 2010).

Segundo Ricci et al. (2010) e Aggarwal (2016), há dois tipos específicos, sendo eles, baseado em restrições e baseado em casos, que diferem de acordo com o modo utilizado para obter itens para indicação.

3.5.1 Baseado em Restrições

É mais rígido onde apenas itens com as características definidas pelas regras são escolhidos. Além disso, a tarefa de levantar um conjunto de itens que satisfaz as necessidades do consumidor é denotada como uma tarefa de recomendação (RICCI et al., 2010). Segundo Schreiber et al. (1999), tarefa define, em termos de pares de entrada e saída, um objetivo de raciocínio. Assim, a tarefa de recomendação busca, a partir de um conjunto de requisitos, elencar um conjunto de itens que a satisfaz.

3.5.2 Baseado em Caso

Essa abordagem confere uma tolerância maior ao não cumprimento das regras, já que recomenda itens semelhantes às restrições. Itens são recuperados usando medidas de similaridade que descrevem o quanto as propriedades do item se aproximam com alguns requisitos do usuário (AGGARWAL, 2016). Caso os usuários considerem inadequados os itens resgatados, este pode modificar os requisitos e uma nova recomendação é feita (LORENZI; RICCI, 2005). Assim, tem-se a distância de similaridade para comparação de requisitos e itens, onde um item (p) e os requisitos (r) pertencentes ao conjunto total de requisitos (REQ) são comparados através da Equação 10, onde w é a importância do requisito r e $\text{sim}(p, r)$ é a distância da característica em relação à expressa pelo usuário (JANNACH et al., 2010).

$$\text{sim}(p, REQ) = \frac{\sum_{r \in REQ} w_r \cdot \text{sim}(p, r)}{\sum_{r \in REQ} w_r} \quad (10)$$

Um sistema baseado em caso terá uma base de casos, na qual condiciona um conjunto de problemas e soluções prévias. Problemas novos são, então, solucionados a partir da adaptação das soluções de problemas similares anteriores (BRIDGE et al., 2005).

3.6 ABORDAGEM HÍBRIDA

As abordagens descritas até o presente momento se destacam em determinadas situações, mas deixam a desejar em outras. Por exemplo, a Filtragem Colaborativa, como será descrito na Seção 3.8, apresenta dificuldades em gerar recomendações adequadas para um novo usuário e para um novo item (RICCI et al., 2010). Deste modo, como forma de contornar as limitações das abordagens, surgem os SRs híbridos, onde se aplicam em um mesmo SR, diversas abordagens para gerar recomendações, permitindo que os pontos fortes de cada uma sejam utilizados, enquanto os pontos fracos, atenuados. Para tanto, os SRs fazem uso de múltiplos dados de entrada, geralmente utilizados por cada abordagem, sendo eles, avaliações de itens, perfis de usuários, modelos de conhecimento, características dos itens, entre outros. As abordagens chamadas “puras” utilizam algumas dessas entradas, enquanto a abordagem híbrida pode empregar múltiplas fontes de informação (JANNACH et al., 2010).

O processo de hibridização de um SR, ou seja, a mesclagem de diversas abordagens, pode seguir algum método específico que indique como e quando os itens de recomendação de cada abordagem serão utilizados. Jannach et al. (2010) expõe três métodos para tornar SRs híbridos: monolítico, paralelo e sequencial, cada um com suas respectivas subdivisões.

O método monolítico apresenta um único componente que integra múltiplas abordagens por pré-processamento e combinação de múltiplas fontes de dados (AGGARWAL, 2016), ou seja, apenas um componente abriga todas as abordagens aplicadas no sistema, onde troca-se o comportamento explorando os diferentes tipos de dados de entrada. Sistemas híbridos com *design* monolítico podem ser sub-categorizados em dois outros *designs*, sendo eles, por combinação de características e aumento de características (JANNACH et al., 2010).

O modo paralelo faz uso de mais componentes, ao contrário do monolítico, cada qual contendo um SR e que, assim, são utilizados de forma simultânea e independente (AGGARWAL, 2016). As respectivas saídas são combinadas a partir de mecanismos de agregação, sendo o mesclado, ponderado e chaveado (JANNACH et al., 2010).

A forma sequencial aplica as diversas abordagens sequencialmente (JANNACH et al., 2010), ou seja, a saída da abordagem atual é aplicada como entrada na seguinte e, assim, sucessivamente até a última abordagem gerar o conjunto de itens para recomendação ao usuário (BURKE, 2002). Esse tipo de *design* pode ser dividido, além

disso, em duas categorias: cascata e meta-nível (JANNACH et al., 2010).

3.7 OUTRAS ABORDAGENS

Além das abordagens clássicas para SRs, há outras relevantes que merecem ser citadas. Nas próximas subseções algumas delas são brevemente apresentadas.

3.7.1 Baseada em Contexto

Muitos SRs não levam em conta as circunstâncias e outras informações de contexto que levam ao usuário a decidir pela aquisição de um item como, por exemplo, a quem se destina, quando e onde será feito usufruto, onde ocorre a compra, entre outras informações relevantes (RICCI et al., 2010; PANNIELLO; GORGOGNONE, 2012).

Sistemas baseados em contexto pode ser divididos em duas classes: por consulta dirigida ao contexto e por estimativa e elicitación de preferência contextual. O primeiro é utilizado por aplicações que se utilizam das informações de contexto para buscas em repositórios de recursos aos quais sugerem serviços correspondentes. Já o segundo se refere à inclusão de informação de contexto em SRs a fim de aprimorar as recomendações (PANNIELLO; GORGOGNONE, 2012).

3.7.2 Baseada em Utilidade

Quando usuários interagem com o conjunto de itens recomendados por um SR tendem a dar mais atenção aos posicionados no topo da lista. Assim, é essencial que a lista de recomendações seja ordenada de acordo com a relevância do item ao usuário. Nesse sentido, a abordagem baseada em utilidade busca, como a própria nomenclatura exprime, ranquear os itens de acordo com a sua utilidade. Para tanto, cada objeto é avaliado a partir de um conjunto de dimensões ou características como qualidade, preço, entre outras. A utilidade é, então, calculada a partir da soma das contribuições do item para cada dimensão, bem como, pelo interesse do usuário na característica (JANNACH et al., 2010). Por fim, sistemas baseados em utilidade tem sido classificados como uma subdivisão de sistemas baseados em conhecimento (AGGARWAL, 2016).

3.7.3 SRs Sociais

Os SRs passaram a incorporar dados de interações sociais como *posts*, *tags*, lista de amigos etc., com o desenvolvimento da Web 2.0. A partir dessas informações pode-se aprimorar a qualidade das recomendações fornecidas pelas abordagens, como a baseada em filtragem colaborativa. Além disso, essas informações podem ser utilizadas para criar novas recomendações, bem como, elucidar as relações entre os processos colaborativos e os dados de interações sociais (BOBADILLA et al., 2013). Com base nisso, é possível recomendar conexões entre usuários, páginas web, entre outros (AGGARWAL, 2016).

3.7.4 SRs Demográficos

SRs Demográficos utilizam dados relativos aos usuários como idade, sexo, profissão, além de hábitos como o de assistir a certos canais de televisão, prática de esportes, entre outros (KRULWICH, 1997). Com base nesses dados, esses sistemas fazem uso de classificadores para dividir os usuários em grupos que compartilham das mesmas características (AGGARWAL, 2016), partindo da premissa de que pessoas em um mesmo grupo tendem a gostar dos mesmos tipos de itens (PAZZANI, 1999).

SRs Demográficos isoladamente não são capazes de recomendações melhores que abordagens tradicionais, como filtragem colaborativa ou baseada em conteúdo. Entretanto, quando incorporados a essas e outras abordagens, a qualidade das recomendações pode ser significativamente melhorada (AGGARWAL, 2016).

3.8 DESAFIOS

Os SRs apresentam algumas limitações e obstáculos que dificultam que as recomendações sejam calculadas e realizadas.

Quando o sistema recebe novos usuários para recomendação não há informações suficientes sobre suas preferências que possibilite a geração de recomendações para ele (BOBADILLA et al., 2013). Por outro lado, em relação aos itens, não existe nenhuma interação com usuários que permita ser recomendado a alguém. Os SRs “puros”, ou seja, baseados em filtragem colaborativa, baseados em conteúdo, entre outros, não conseguem lidar com esses problemas, também chamados de *cold*

start ou partida fria. Tais problemas, no entanto, podem ser superados por sistemas híbridos (MIRANDA, 2010).

Além do problema em recomendar novos itens há o efeito gerado pela adição deste item, ou seja, o conjunto de recomendação prévio não leva em conta esse novo item e, deste modo, pode não ser preciso. Assim, é necessário que o sistema ajuste as bases de recomendação para que o novo item seja recomendado. No entanto, tais bases contêm entre centenas à milhares de itens e usuários e, por isso, efetuar a atualização de uma base de grande porte pode ser custoso e inviável para cada novo item acrescentado. Esse problema se refere à escalabilidade de SRs (Lü et al., 2012).

Outro desafio se refere a esparsidade, ou seja, a proporção dos itens avaliados por usuários em relação ao número total de itens é consideravelmente pequena e mal distribuída. Além disso, a intersecção do conjunto de itens avaliados por pares de usuários tende a ser modesta. Isso acontece em função da baixa taxa de avaliação de itens, seja explícita ou implicitamente (Lü et al., 2012; SHARMA; GOPALANI; MEENA, 2017).

A diversidade das recomendações é outra questão relevante, à qual se refere à capacidade dos SRs sugerirem recomendações variadas, seja em relação aos usuários, ou seja, diferentes resultados para diferentes usuários, seja em relação aos itens, através da sugestão de itens distintos para um mesmo usuário (Lü et al., 2012). Nesse sentido, um usuário que demonstra preferência por livros de ficção científica, por exemplo, teria como sugestão não apenas obras do gênero.

3.9 APLICAÇÕES

A aplicabilidade de SRs é ampla, indo desde sites de comércio eletrônico até a área da saúde. Os primeiros sistemas, como descrito no início do capítulo, objetivavam reduzir a carga de informações ao usuário categorizando e recomendando os itens (GOLDBERG et al., 1992; RESNICK et al., 1994). No entanto, com o expansão da área e da Internet novas aplicações de SRs surgiram, entre elas, no comércio eletrônico, em plataformas de *streaming*, turismo e, recentemente, na IoT.

Na área de comércio eletrônico, as avaliações são costumeiramente utilizadas, além do histórico de interações com os produtos, seja na forma de visualização ou compra. Com base nesses dados de usuários, esses sistemas geram recomendações (LU et al., 2015). Empresas

como Amazon^{®1}, Saraiva^{®2} e Walmart^{®3} recomendam produtos para seus usuários. Tratando-se da Amazon por exemplo, recomendações são disponibilizadas aos usuários por diversos meios, como página *web* ou por e-mail. Tais sugestões são computadas através de filtragem colaborativa baseada em item. Entre as entradas para a abordagem de recomendação tem-se o conjunto de produtos visualizados e/ou comprados pelo usuários, bem como, os itens mais vendidos, entre outras informações (KRAWIEC, 2016).

SRs também são utilizados em plataformas de *streaming*, como Netflix^{®4} e Spotify^{®5}, onde filmes, séries ou músicas são recomendados. A Netflix[®], por exemplo, lançou, em 2006, uma competição chamada *Netflix Prize* em que oferecia um milhão de dólares a quem, a partir de um conjunto de dados fornecido, aprimorasse o SR baseado do em fatoração de matriz. Para tanto, a solução proposta deveria em reduzir, em 10%, o *Root Mean Square Error* (RMSE). Como resultado, as pesquisas sobre a técnica eclodiram, resultando em um vencedor em 2009 (JANNACH et al., 2016). Como resultado, as pesquisas sobre a técnica eclodiram, resultando em um vencedor em 2009 (JANNACH et al., 2016).

O novo paradigma da IoT comportará aplicações que comportarão SRs. Para tanto, dados locais e pessoais serão coletados implicitamente através dos vários sensores e dispositivos de IoT. A partir disso, tem-se a representação do contexto de usuários em que recomendações proativas poderão ser entregues no momento mais apropriado e sem a requisição direta da sugestão (SALMAN et al., 2015). As possíveis recomendações poderão abranger, além de itens, serviços (MASHAL; CHUNG; ALSARYRAH, 2015).

SRs são aplicáveis não apenas nas áreas apresentadas anteriormente, mas também na saúde (FERRETTO; CERVI; MARCHI, 2017), educação (WAI, 2016; MONTUSCHI et al., 2015), turismo (SMIRNOV et al., 2013; FRIKHA et al., 2016), engenharia de software (HAMZA; WALKER, 2015), jogos eletrônicos (BERKOVSKY et al., 2010), entre outros.

¹<https://www.amazon.com.br>

²<https://www.saraiva.com.br>

³<https://www.walmart.com.br>

⁴<https://www.netflix.com>

⁵<https://www.spotify.com>

4 MODELO PROPOSTO

Este capítulo tem por objetivo detalhar o sistema proposto apresentando uma visão lógica e uma visão física promovendo, assim, um entendimento do como os diversos componentes interagem e se comportam.

4.1 INTRODUÇÃO

Geladeiras inteligentes têm sido lançadas por fabricantes como Samsung[®] e LG[®], tendo estas muitas características em comum. Em relação ao modelo tradicional, essas geladeiras proporcionam uma maior interação com os usuários a partir de uma interface *touch screen*, além do uso de câmeras no interior do equipamento.

A partir da interface é possível criar lembretes para os demais moradores da casa, ler notícias e ver a previsão do tempo. Além disso, é possível adicionar itens ao calendário e visualizar receitas. Por outro lado, conta-se com o auxílio de assistentes virtuais como a Alexa[®], da Amazon[®], e a Cortana[®] da Microsoft[®], que possibilitam que ações sejam executadas a partir de comandos de voz como, por exemplo, compras de novos produtos.

Apesar de as funcionalidades serem úteis e interessantes, geladeiras como estas não observam os hábitos e preferências por produtos de seus usuários. Como exemplo, tais eletrodomésticos não são capazes de inferir que um usuário seja vegetariano ou que tenha intolerância à lactose.

O modelo descrito nesse capítulo foca na questão mencionada e apresenta uma proposta de geladeira inteligente que seja capaz de observar os hábitos de seus usuários e disponibilizar uma experiência personalizada de modo a facilitar o seu dia a dia. Para tanto, o modelo foi materializado em um sistema computacional composto de três componentes principais: a geladeira, servidor e mercado.

A geladeira contém dois subsistemas, ou seja, um mecanismo de leitura de itens e a interface de interação com o usuário. Já o servidor contém as bases de dados e processos que compõe o sistema de análise de interações e recomendações. E, por fim, o mercado é responsável por permitir a compra de produtos, a verificação de disponibilidade destes e a obtenção de informações detalhadas sobre os mesmos.

Baseando-se nos três componentes, o sistema disponibiliza como

funcionalidades a listagem dos produtos contidos na geladeira, a compra automática e recomendação de produtos e receitas, como será detalhado posteriormente.

O modelo foi subdividido em duas visões, sendo elas, lógica e física. A primeira apresenta os componentes do sistema abstraindo as tecnologias envolvidas na sua composição, tendo como foco as funcionalidades. Já o modelo físico complementa a visão lógica a partir do detalhamento de cada componente, bem como as tecnologias empregadas em suas respectivas implementações.

4.2 MODELO LÓGICO

O modelo lógico do sistema proposto neste trabalho é apresentado na Figura 8. Pode-se observar cinco camadas: aplicação, serviços, repositórios, processamento e agente externo. A primeira delas envolve os componentes externos ao servidor principal, mas que são relacionados ao sistema, sendo eles, a geladeira e a interface de usuário. Já as camadas de serviços, repositórios e processamento fazem parte do servidor de aplicação. Por fim, a camada de agente externo abriga o mercado que apresenta um arquitetura independente àquela aqui proposta.

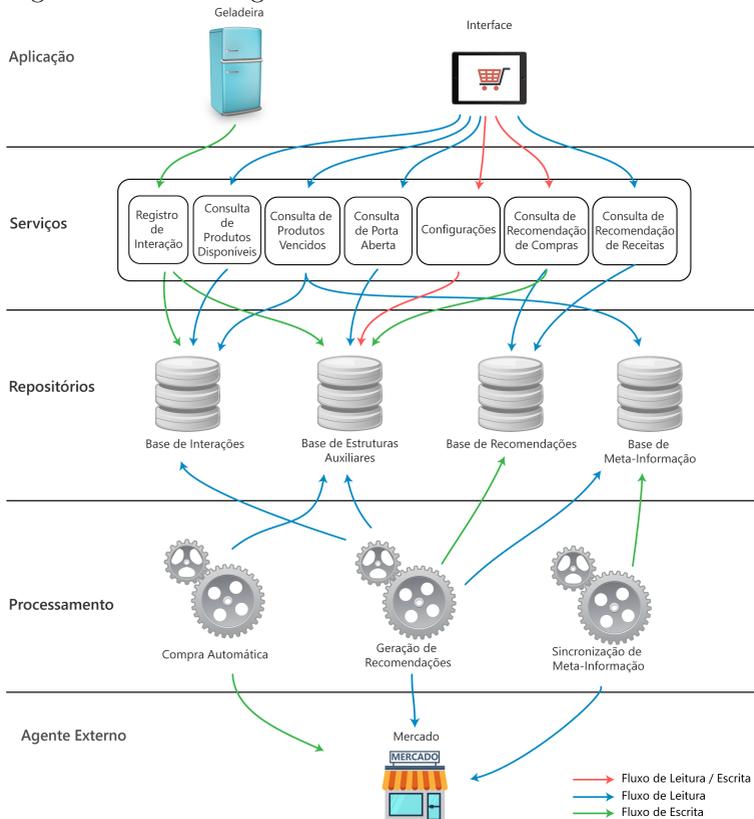
4.2.1 Camada de Aplicação

A camada de aplicação, como descrito, envolve os componentes externos ao sistema principal. O primeiro deles é a geladeira à qual se responsabiliza por monitorar os produtos nela contidos. Deste modo, a cada interação do usuário com a geladeira é realizada uma varredura a fim de verificar o conjunto de produtos existentes. Em seguida, envia-se tais informações para o servidor através do serviço de registro de interação.

Outra funcionalidade da geladeira consiste na verificação da condição de fechamento da porta. Caso esteja aberta por um determinado período, a geladeira faz um registro na base de estruturas auxiliares através do serviço de registro de interação. Assim, o sistema é capaz de emitir um aviso ao usuário.

O componente seguinte é a interface de usuário, incorporada à porta da geladeira. Ela se responsabiliza por permitir ao usuário a interação com o eletrodoméstico. Assim, tem-se como funcionalidades

Figura 8 – Modelo lógico



Fonte: Elaborado pelo Autor

deste componente: a listagem de produtos contidos, conjunto de produtos prestes a vencer, notificações de alerta caso o usuário esqueça a porta aberta, configurações personalizáveis e, por fim, recomendações de possíveis compras de produtos e receitas.

As recomendações podem ser exibidas automaticamente ou quando o usuário desejar. Assim, a aplicação realiza automaticamente a requisição e alerta o usuário através de uma notificação ou, ainda, o usuário solicita as recomendações através da interface.

4.2.2 Camada de Serviços

A camada de serviços disponibiliza um conjunto de funcionalidades aos componentes da camada de aplicação, se comportando como meio de entrada do sistema principal. Assim, há um conjunto de serviços específicos disponibilizados conforme a Figura 8 e que serão descritos nos parágrafos seguintes.

O serviço de registro de interação recebe informações dos itens contidos da geladeira além do alerta de porta aberta. Em seguida, registra-se tais informações na base de interações e de estruturas auxiliares, respectivamente.

Já o serviço de consulta de produtos disponíveis pode ser requisitado pelo usuário através da interface. Então, o conjunto de produtos contidos na geladeira é obtido a partir do último registro inserido na base de interações, já que este último mostra o estado mais recente da geladeira.

O serviço de consulta de produtos vencidos é acionado periodicamente pela interface. Desse modo, é efetuada uma busca pelo itens disponíveis na geladeira e o tempo que estão presentes, através da base de interações. Logo após, se realiza uma consulta na base de metainformação para determinar o período de validade (após aberto) de cada produto encontrado. A partir da comparação entre tempo de acondicionamento e prazo de expiração, sabe-se se o produto está vencido ou não. A estimativa é feita pois o prazo de validade transcrito nos produtos se reduz após sua abertura.

O serviço de consulta de porta aberta é requisitado pela interface de usuário periodicamente de forma automática. Como efeito da requisição, faz-se uma consulta à base de estruturas auxiliares a fim verificar a existência de um registro recente de porta aberta. O resultado é então encaminhado para a interface que alertará o usuário, caso necessário.

O serviço de configurações permite que o usuário personalize algumas características do funcionamento da geladeira. A primeira delas se refere ao mercado no qual as compras são realizadas. Além disso, é possível determinar quais produtos devem sempre estar disponíveis para consumo e qual a quantidade mínima necessária.

O serviço de consulta de recomendação de compras é requisitado pela interface periodicamente e também pelo usuário. Assim, quando é feita uma requisição, automática ou não, o serviço faz uma consulta à base de recomendações em busca de possíveis sugestões. O conjunto existente é então retornado para a interface que, por sua vez, indaga ao

usuário se deseja realizar a compra e quais produtos, dentre os apresentados, deseja adquirir. A lista é retornada ao serviço que, então, faz o registro na base de estruturas auxiliares.

O serviço de recomendação de receitas recebe uma requisição do usuário e faz uma consulta à base de recomendações. Caso existam receitas para recomendar, essas serão listadas ao usuário na interface sendo possível a escolha de qual receita se deseja visualizar.

4.2.3 Camada de Repositórios

O conjunto de repositórios desta camada atuam na persistência de informações geradas pelos diversos componentes das camadas de aplicação e de processamento, sendo divididas em quatro bases: de interações, de estruturas auxiliares, de recomendações e de metainformação. A primeira base é responsável, como descrito anteriormente, pelo registro de produtos acondicionados na geladeira. A partir disso, as consultas realizadas nessa base podem recuperar os itens constantes após cada interação do usuário.

A base de estruturas auxiliares contém informações que são utilizadas por mais de um serviço. Tais informações representam alertas de porta aberta, configurações e as listas de compras efetuadas pelo usuário.

Já a base de recomendações armazena todas as sugestões de receitas e de compras de produtos que foram elaboradas pelo módulo de geração de recomendações e que serão apresentadas ao usuário.

A última base, de metainformação, contém informações referentes ao conteúdo dos produtos adquiridos e que são utilizadas pelo módulo de geração de recomendações e pelo serviço de verificação de produtos vencidos. Tais informações incluem características do produto, como código de barras, fabricante, informações nutricionais, categoria além do tempo estimado de validade. Além disso, inclui-se registros de receitas e suas respectivas informações, ou seja, ingredientes, e passos para o preparo destas.

4.2.4 Camada de Processamento

A camada de processamento contém os módulos de geração de recomendações, de compras automáticas e de sincronização de metainformação. O primeiro deles faz uso das informações armazenadas na

base de interação e das características de cada item, mantidas na base de metainformações.

As recomendações de receitas fazem uso da base de interações para ter conhecimento dos produtos contidos atualmente e de metainformações para resgatar as receitas e seus respectivos ingredientes. A partir disso, é feita uma comparação entre as bases. Caso alguma receita tenha a necessidade de itens que já estão presentes, essa será recomendada ao usuário.

Compras são sugeridas com base na quantidade existente de um certo produto. Assim, quando tal valor fica abaixo da quantidade mínima, determinada pelo usuário, é realizada a recomendação de compra do produto. No entanto, o mercado pode não ter à disposição o produto específico, mas pode conter similares. Neste caso, o sistema efetua uma busca por itens similares e solicita a aprovação do usuário para a compra deste, ao invés do original. Além disso, sugere-se novos itens, aos quais tenha apresentado interesse, que, por ventura, o mercado venha a disponibilizar.

O processo de compra é executado automaticamente quando há uma lista de compras pendente. Assim, a partir da verificação de tal pendência na base de estruturas auxiliares, a compra é requisitada ao mercado.

Já o processo de sincronização de metainformações, periodicamente consulta o serviço de sincronização do mercado para verificar se há metainformações de produtos que foram adicionados ou alterados.

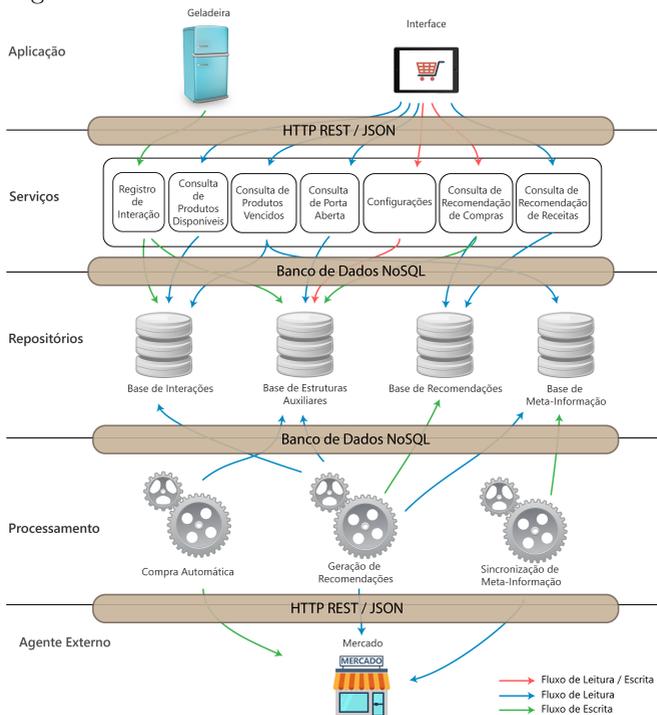
4.2.5 Camada de Agente Externo

O componente desta camada é o mercado. Através dele, torna-se possível verificar a disponibilidade de produtos e efetivar compras a partir da lista de produtos selecionados pelo usuário. Além disso, há a funcionalidade de sincronização de metainformação de produtos onde, para isso, o mercado disponibiliza um serviço possibilitando que a base de metainformação possa ser periodicamente atualizada. Essas informações são utilizadas posteriormente na recomendação de produtos e receitas.

4.3 MODELO FÍSICO

A modelagem física deste trabalho é apresentada na Figura 9. Nas seções a seguir serão detalhados os diversos componentes do sistema, em relação aos aspectos internos.

Figura 9 – Modelo físico



Fonte: Elaborado pelo Autor

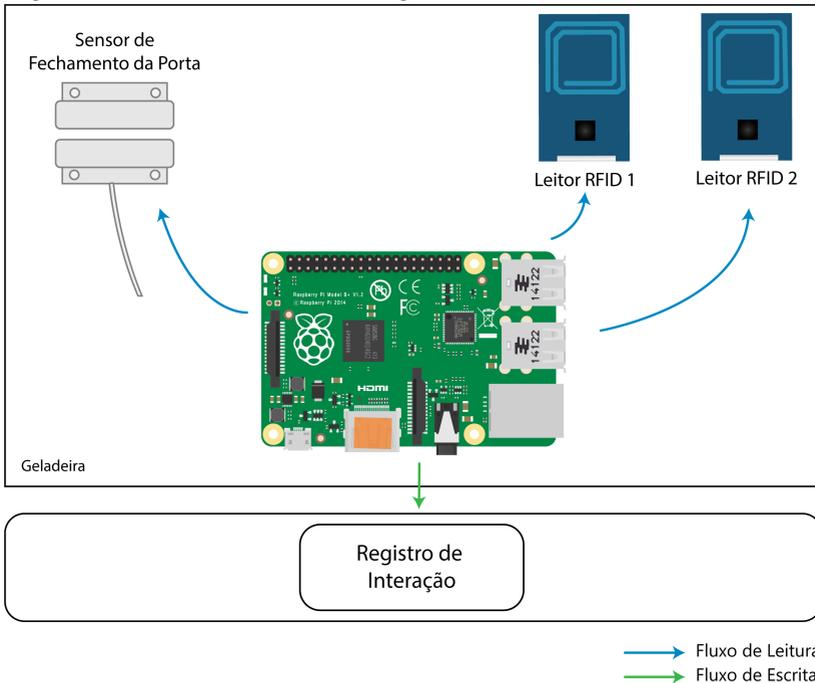
4.3.1 Camada de Aplicação

4.3.1.1 Geladeira

A geladeira, presente no modelo lógico da Figura 8, foi construída de acordo com a Figura 10. Assim, observa-se três componentes principais: os leitores de etiquetas MF522 para RFID e NFC, o sen-

sensor de fechamento para a porta e a placa Raspberry PI¹ 3 Modelo B. O primeiro deles, o conjunto de leitores, responsabiliza-se por efetuar varreduras de etiquetas NFC próximas a cada leitor quando for requerido. A partir disso, os dados lidos, referentes aos produtos, são transferidos para o Raspberry PI que, por sua vez, os transfere para o serviço de registro de interação. Os dados das etiquetas se encontram no formato *Electronic Product Code* (EPC), no qual, identifica-se o fabricante, a classe do produto e a instância do produto a partir de um número de 96 bits, de forma semelhante ao código de barras presente nos produtos (GS1 BRASIL, 2017). Vale destacar que as etiquetas utilizadas nesse trabalho operam na faixa HF de 13,56 MHz e foram configuradas no formato NDEF.

Figura 10 – Estrutura interna da geladeira



Fonte: Elaborado pelo Autor

O sensor de fechamento de porta, por outro lado, é responsável por determinar quando ações devem ocorrer. O seu funcionamento envolve dois componentes: o primeiro é dotado de um ímã e o ou-

¹<https://www.raspberrypi.org>

tro contém um mecanismo que é influenciado pela presença ou não do ímã. Assim, quando estes se aproximam, indica-se o fechamento da porta. Haverá, deste modo, um curto-circuito entre os terminais do mecanismo. Por outro lado, quando afastados indica-se abertura, determinando portanto, um circuito aberto.

Considerando que inicialmente a porta está fechada. Em um dado momento, o usuário abre a porta. Caso esta não seja fechada durante um determinado período de tempo, será feita uma requisição para o serviço de registro de interação indicando a situação. Caso contrário, ou seja, a porta estava aberta e é fechada dentro do período estipulado, realiza-se uma varredura dos produtos e, em seguida, uma requisição é enviada ao serviço para que se efetue o registro de interação.

Por fim, o último componente, o Raspberry PI, opera como um centro de controle, onde obtém dados do sensor de fechamento para, então, comandar leituras de etiquetas e/ou fazer requisições descritas anteriormente.

Para a comunicação entre os três componentes fez-se uso de dois protocolos específicos: a *Serial Peripheral Interface* (SPI) e *Hypertext Transfer Protocol* (HTTP) com *Representational State Transfer* (REST). O primeiro deles foi empregado na comunicação entre os leitores RFID e o Raspberry, já o segundo, para a troca de informações entre o Raspberry e o serviço de registro. Por fim, a comunicação com o sensor de fechamento ocorre através de sinais digitais.

Como parte do processo de implementação, uma estrutura em madeira foi construída a fim de simular a interação. O resultado pode ser observado na Figura 11. Assim, apesar da aparência rústica, observa-se três níveis: o primeiro, inferior, abriga o Raspberry, já o segundo e terceiro abrigam os leitores e os produtos.

Figura 11 – Estrutura externa da geladeira



Fonte: Elaborado pelo Autor

4.3.1.2 Interface de Usuário

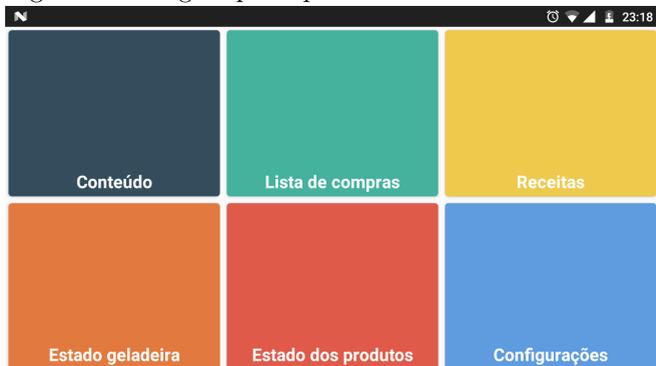
Como já descrito, a interface de usuário destina-se à interação entre usuários e a geladeira. Assim, conforme Figura 12, as funcionalidades ficam disponíveis em uma tela principal e podem ser acessadas de acordo com a necessidade do usuário ou em momentos em que notificações forem disparadas.

A primeira das funcionalidades, de listagem de conteúdo, é exibida como um conjunto de produtos com as respectivas informações de descrição, fabricante e quantidade disponível, conforme Figura 13.

A próxima função permite que o usuário visualize receitas recomendadas. Assim, inicialmente será listado um conjunto de receitas selecionadas pelo sistema. Em seguida, é possível visualizar os detalhes de qualquer uma delas, como ingredientes e passos para o preparo, conforme Figura 14.

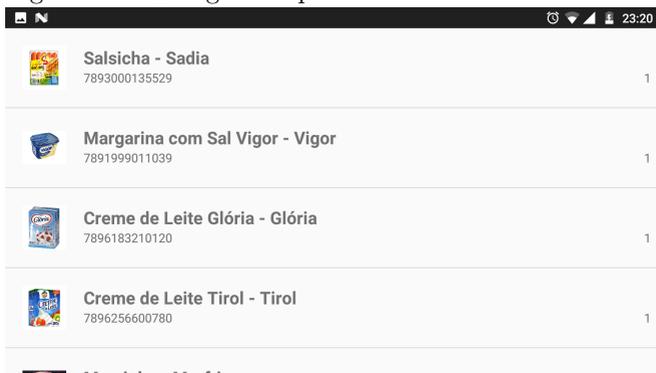
A última funcionalidade implementada é a exibição do estado da geladeira, ou seja, se está aberta ou fechada no momento. Acessando a respectiva opção no menu da Figura 12 uma nova tela é aberta e o estado atual é exibido. Outra forma na qual a aplicação permite ter conhecimento do estado da geladeira é através de notificações que

Figura 12 – Página principal da interface



Fonte: Elaborado pelo Autor

Figura 13 – Listagem de produtos



Fonte: Elaborado pelo Autor

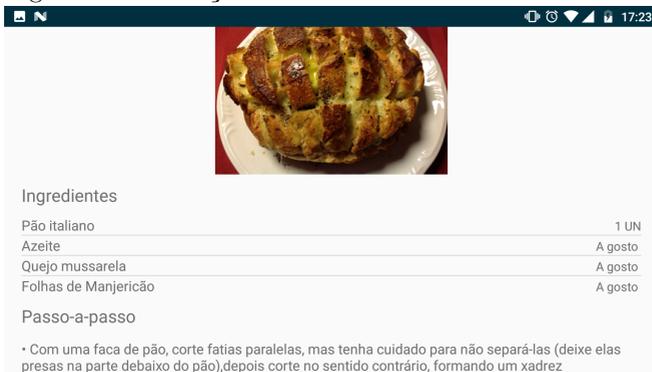
alertam em caso de a porta estar aberta durante muito tempo.

Toda a interface de usuário foi desenvolvida a partir de um aplicação para a plataforma móvel Android®.

4.3.2 Camada de Serviços

Como descrito anteriormente, a camada de serviços atua como porta de entrada do sistema para os componentes da camada de aplicação. Conforme demonstrado na Figura 9, utiliza-se, sobre o HTTP, o REST, um estilo arquitetural que opera como um modelo abstrato da arquitetura da *Web*. Em outras palavras, qualquer informação contida

Figura 14 – Exibição de detalhes de uma receita



Fonte: Elaborado pelo Autor

em um servidor pode ser abstraída como um recurso. Além disso, cada recurso é identificado por um *Uniform Resource Identifier* (URI) e o acesso a esse recurso ocorre por meio de métodos HTTP, como o GET e o POST (FIELDING; TAYLOR, 2000).

Para a implementação dos serviços REST utilizou-se a linguagem Java a partir do *Integrated Development Environment* (IDE) Eclipse *Java Enterprise Edition* (JEE) com a especificação *Java API for XML Web Services* (JAX-WS) para a referida linguagem.

Como exemplos, é possível apresentar os serviços de registro de interação e de consulta do estado da porta, conforme Quadro 1 e Quadro 2, respectivamente.

Quadro 1 – Serviço de registro de interação

```
@POST
@Path("/register")
@Produces(MediaType.APPLICATION_JSON)
public String register(@QueryParam("type_record") Integer typeRecord, String data) {

    // ...

    return "{\"status\": \"OK\"}";
}
```

Fonte: Elaborado pelo Autor

Como descrito, a estrutura de um serviço conta com um método HTTP para ser acessado. Nos exemplos, utiliza-se os métodos POST e GET, respectivamente. Além disso, para cada serviço atribuiu-se um endereço, sendo eles, `/register` e `/open_door`, nessa ordem.

É possível especificar a interação com o serviço a partir de pa-

Quadro 2 – Serviço de consulta de estado de porta

```

@GET
@Path("/open_door")
@Produces(MediaType.APPLICATION_JSON)
public String openDoorQuery(@QueryParam("id_fridge") Integer idFridge) {

    // ...

    return ESTADO_PORTA;
}

```

Fonte: Elaborado pelo Autor

râmetros, aos quais variam de acordo com o método HTTP utilizado. Assim, é possível informar parâmetros na URL na própria requisição HTTP, tanto no POST quanto no GET, ou apenas no corpo da mesma, no caso do POST.

Por fim, cada serviço poderia ser acessado pelas seguintes URIs.

- http://ipserver:8080/context/register?type_record=1
- http://ipserver:8080/context/open_door?id_fridge=1

A interação dos serviços com as bases de repositórios, por outro lado, ocorre por meio de classes Java disponibilizadas pelo próprio mecanismo de armazenamento, ou seja, classes do MongoDB².

4.3.3 Camada de Repositórios

As bases de dados nesse trabalho estão relacionadas ao servidor principal de serviços e recomendação. Conforme a Figura 9, tem-se quatro bases de dados: de interações, estruturas auxiliares, recomendações e metainformação. Tais bases promovem suporte para todas as funcionalidades do sistema, desde o registro de interações até a recomendação de produtos.

A tecnologia utilizada para implementação dos repositórios baseia-se no conceito de banco de dados não relacionais, como o NoSQL. Tem-se como principal característica, nesse conceito, o não suporte ao modelo relacional para alcance de desempenho ou confiabilidade. O intuito desse tipo de banco de dados é ser utilizado em aplicações de grande escala, nas quais supera o desempenho de bancos relacionais. Os dados são registrados em coleções, que não restringem os tipos de dados armazenados. Conseqüentemente, é possível, por exemplo, registrar em

²<https://www.mongodb.com>

uma mesma coleção cadastros de usuários e de fornecedores. (BOICEA; RADULESCU; AGAPIN, 2012).

Neste trabalho optou-se pelo MongoDB®, um sistema de banco de dados NoSQL baseado em documentos, ao qual o armazenamento decorre no formato *JavaScript Object Notation* (JSON), um formato baseado em chave e valor.

O sistema desenvolvido neste trabalho possui um conjunto expressivo de interações provenientes dos dispositivos que o compõem, sendo que em um ambiente real resultaria em um número expressivo de inserções e recuperações de informação. Por isso, na implementação utilizou-se o conceito de base de dados NoSQL.

Nas seções que seguem, os repositórios serão detalhados em seus aspectos internos, como tipos de dados armazenadas, a origem da necessidade destes e em que momento são utilizados.

4.3.3.1 Base de Interações

Como descrito na Seção 4.2.3, essa camada é responsável pelo registro das interações de usuários com produtos. A cada registro, ter-se-á um conjunto de códigos EPC de itens atuais, além da identificação da geladeira e o *timestamp*, ou seja, o momento no qual ocorreu a interação. O Quadro 3 demonstra um exemplo de registro que é inserido na base.

Quadro 3 – Registro na base de interações

```
{
  "epc_codes":[
    "8665580287680110110875621443",
    "8665580291139087601250171203",
    "8665580288832901105227749441",
    "8665580301514879150771066396"
  ],
  "id_fridge":1,
  "timestamp":"2017-09-13 13:26:22.209"
}
```

Fonte: Elaborado pelo Autor

Nota-se, pelo Quadro 3, que haviam quatro itens na geladeira no dia 13 de setembro de 2017 à 13h26. No entanto, não é claro quais produtos estão contidos. Para tanto, operações de deslocamento de bit são realizadas sobre o código EPC revelando, desse modo, o fabricante, o produto e o número de série da instância. O Quadro 4 exhibe estrutura de um código EPC.

Esse tipo de registro é a principal fonte de informação sobre os

Quadro 4 – Estrutura de um código EPC

Cabeçalho EPC (8 bits)	Fabricante (28 bits)	Produto (24 bits)	Código da Instância (36 bits)
---------------------------	-------------------------	----------------------	----------------------------------

Fonte: Elaborado pelo Autor

hábitos dos usuários, uma vez que explicita os produtos com os quais mais se tem contato, bem como os horários em que isso ocorre. A partir dessas informações, é possível calcular as recomendações.

4.3.3.2 Base de Estruturas Auxiliares

A base de estruturas auxiliares tem como principal objetivo intermediar a comunicação entre serviços e processos que fazem parte da camada de processamento. Assim, ela contém diversos tipos de registros, sendo eles, de estado da porta, configurações de cada geladeira e listas de compras pendentes.

O primeiro dos registros, informa qual o último estado registrado por uma determinada geladeira, ou seja, aberto ou fechado. Assim, tal informação será requisitada pela interface, através do serviço de consulta de porta, e alertará o usuário caso necessário. O Quadro 5, demonstra um registro de estado da porta.

Quadro 5 – Estrutura de um registro de estado da porta

```
{
  "id_fridge": 1,
  "record_type": "open_door",
  "door_status": 0
}
```

Fonte: Elaborado pelo Autor

Como é visível no Quadro 5, três informações são guardadas: a identificação da geladeira, o tipo de registro que será inserido, ou seja, estado da porta, e o estado em si. Segundo a implementação, “0” significa porta aberta e, “1”, fechada.

O segundo tipo de registro, de configurações, mantém um conjunto de parâmetros específicos de cada geladeira, conforme Quadro 6. Tais parâmetros incluem os dados do servidor do mercado escolhido e o tempo mínimo necessário que deve decorrer até que o usuário seja alertado que deixou a porta aberta. Além disso, inclui-se o intervalo de tempo em que ocorrem as compras automáticas e, por fim, a lista de produtos que são considerados essenciais.

As informações referentes ao mercado são utilizadas pelos pro-

cessos do sistema. Já informações de tempo de notificação são requisitados pela interface através do serviço de configurações. Por outro lado, o tempo mínimo entre compras é requisitado pelo processo de compras automáticas. Por fim, a lista de produtos requeridos pelo usuário é utilizada pelo processo de recomendação na sugestão de novas compras.

Quadro 6 – Estrutura de um registro de configurações

```
{
  "market": {
    "hostname": "192.168.0.110",
    "port": 8080,
    "resources": {
      "sync_metainfo": "/sync_database",
      "purschase": "/purchase",
      "availability": "/product_av"
    },
    "path_name": "/tcc_market"
  },
  "notification_period": 30,
  "id_fridge": 1,
  "purchase_period": 7200,
  "record_type": "settings",
  "products": [
    {
      "product_quantity_unit": "UN",
      "bar_code": "7893000084315",
      "product_quantity": 5
    },
    {
      "product_quantity_unit": "UN",
      "bar_code": "7891999011039",
      "product_quantity": 2
    },
    {
      "product_quantity_unit": "UN",
      "bar_code": "7894900093056",
      "product_quantity": 3
    },
    {
      "product_quantity_unit": "UN",
      "bar_code": "7894900011517",
      "product_quantity": 2
    }
  ]
}
```

Fonte: Elaborado pelo Autor

A terceira categoria de registros se refere às listas de compras definida pelo usuário. Neste caso, tem-se informações de identificação da geladeira, o momento no qual ao registro foi feito, bem como a lista de produtos e suas respectivas quantidades. Assim, tal lista será, posteriormente, analisada e efetivada pelo processo de compra automática.

4.3.3.3 Base de Metainformação

Os produtos disponibilizados pelo mercado possuem suas informações armazenadas nessa base de dados. Desta forma, o sistema terá acesso a preços, códigos de barras, informações nutricionais, entre outros. Assim, torna-se possível utilizar tais informações em recomendações como, por exemplo, produtos similares a um em específico.

A estrutura do registro de um produto em específico é demonstrada no Quadro 7.

Quadro 7 – Estrutura de um registro de metainformação de produto

```
{
  "nutritional_info": {
    "reference": "1L",
    "kcal": 600,
    "sodium": 650,
    "total_fat": 30,
    "protein": 30
  },
  "weight_volume": "1L",
  "product_manufacturer": "Tirol",
  "classification": {
    "especification": 1,
    "class": 1
  },
  "product_expired_time": 4,
  "product_quantity": 150,
  "price": 1.9900000095367432,
  "bar_code": "7896256601848",
  "metainfo_type": "meta_info_product",
  "epc": {
    "product": 1,
    "manufacturer": 2
  },
  "_id": {
    "$oid": "59c1998edc412244bd1b6400"
  },
  "product_description": "Leite integral TIROL",
  "product_url_image":
http://www.tirol.com.br/media/cache/product\_vertical/files/product/1506d7c617f17e34ce63d60adccacb249.png,
  "timestamp": "2017-09-19 19:26:22.03"
}
```

Fonte: Elaborado pelo Autor

A primeira parte do registro indica as informações nutricionais, que poderão ser utilizadas, futuramente, na recomendação de produtos segundo uma dieta específica do usuário. A seguir, tem-se informações de peso/volume e fabricante.

Cada produto cadastrado é classificado em dois níveis: classe e especificação. O primeiro relaciona-se a um determinado tipo de pro-

duto como, por exemplo, bebidas e laticínios. A especificação determina qual produto em si é representado como, refrigerante e leite. Assim, torna-se possível recomendar produtos através da abordagem baseada em conteúdo. Na sequência, é informado o tempo estimado em dias para considerar o produto adequado para consumo e, em seguida, a quantidade disponível no mercado, o preço unitário, o código de barras e o parâmetro que indica que o registro se trata da metainformação de um produto.

Outra informação relevante se refere aos parâmetros do código EPC que exemplares do produto terão. Considerando, novamente, o Quadro 4, tais parâmetros se referem ao fabricante e ao produto.

Por fim, tem-se informações de descrição do produto, de endereço da respectiva imagem ilustrativa e do instante em qual esse registro foi atualizado. Tanto a descrição como o endereço da imagem são empregados pela interface de usuário na demonstração do produto. Já o processo de sincronização de metainformação faz uso do momento do registro para verificar a necessidade por atualizações de metainformações.

As receitas disponibilizadas possuem a estrutura demonstrada na Quadro 8. Assim, a receita terá um nome ou uma descrição breve de seu conteúdo, além de um conjunto de passos para o preparo. Haverá também uma lista de produtos que fazem parte da receita, bem como suas respectivas classificações e quantidades necessárias à receita. Por fim, cada receita terá sua própria classificação, indicando que se trata de uma torta ou doce de leite, por exemplo. Tal informação de classificação é utilizada na recomendação de novas receitas.

4.3.3.4 Base de Recomendações

Nessa base se encontram todos os diversos tipos de recomendação que o sistema pode prover, sendo elas: de compra de produtos faltantes, de novos produtos além de receitas selecionadas a partir do conteúdo da geladeira ou do perfil do usuário.

Cada recomendação de produto, independente do seu tipo, apresenta a estrutura demonstrada no Quadro 9.

No registro que consta no Quadro 9 é apresentada uma recomendação de um novo produto ao usuário. Cada registro especifica o seu tipo, ou seja, uma recomendação de um produto faltante ou um novo. Além disso, o momento em que a recomendação foi gerada é armazenado para diferenciar recomendações novas e antigas. A informação que

Quadro 8 – Registro de receita

```

{
  "recipe_description": "Doce de leite caseiro",
  "metainfo_type": "meta_info_recipe",
  "recipe_steps": [
    "Coloque o leite e o açúcar em uma panela grande de fundo largo",
    "Leve ao fogo médio, mexendo sempre com uma colher de pau, até obter fervura (cerca de 15 minutos)",
    "Diminua o fogo e continue mexendo até obter um doce marrom claro de consistência cremosa (cerca de 45 minutos)",
    "PPasse o doce para um refratário, deixe esfriar bem e sirva colheradas em pratos de sobremesa com fatias de queijo branco"
  ],
  "classification": {
    "especification": 3,
    "class": 3
  },
  "url":
  "https://abrilmdemulher.files.wordpress.com/2017/04/receita-torta-mar-more-de-leite-condensado163.jpeg?quality=90&strip=info&w=654",
  "products": [
    {
      "product_quantity_unit": "L",
      "bar_code": "98700013456",
      "classification": {
        "especification": 1,
        "class": 1
      },
      "product_quantity": "2"
    },
    {
      "product_quantity_unit": "Xicaras",
      "bar_code": "98701063415",
      "classification": {
        "especification": 19,
        "class": 6
      },
      "product_quantity": "4"
    }
  ]
}

```

Fonte: Elaborado pelo Autor

segue no registro é a lista de produtos recomendados. Cada produto recomendado tem toda a sua metainformação anexada à recomendação.

O registro de recomendação de receitas, conforme Quadro 10, apresenta as seguintes informações: o tipo de recomendação, além da identificação da geladeira à qual se refere, bem como o momento em que foi gerada. Por fim, um lista de receitas é apresentada, cada qual com a estrutura demonstrada na Seção 4.3.3.3.

Quadro 9 – Registro de recomendação de produtos

```

{
  "recommendation_type": "product_rec_new",
  "id_fridge": 1,
  "timestamp": "2017-10-12 15:03:59.31",
  "products": [
    {
      "nutritional_info": {
        "reference": "0ml",
        "kcal": 0,
        "sodium": 0,
        "total_fat": 0,
        "protein": 0
      },
      "weight_volume": "2L",
      "product_manufacturer": "Pepsi",
      "classification": {
        "especification": 10,
        "class": 3
      },
      "product_expired_time": 2,
      "product_quantity": 136,
      "price": 5.97,
      "bar_code": "7892840800000",
      "metainfo_type": "meta_info_product",
      "epc": {
        "product": 3218,
        "manufacturer": 17
      },
      "product_description": "Refrigerante",
      "product_url_image": "https://www.magodrive.com.br/Imagem/produtos/7892840800000.png",
      "timestamp": "2017-10-12 14:58:51.562"
    },
    ...
  ]
}

```

Fonte: Elaborado pelo Autor

4.3.4 Camada de Processamento

Nas próximas seções, os aspectos da implementação dos processos serão detalhados.

4.3.4.1 Processo de Compras Automáticas

A compra automática ocorre quando existirem listas de compras pendentes na base de estruturas auxiliares. Quando isso ocorrer o processo deve contatar o serviço de compras do mercado para efetuar a aquisição definida pelo usuário. Isso é realizado a partir de uma requisição HTTP que é enviada ao serviço do mercado contendo a lista de produtos requeridos e as respectivas quantidades.

Quadro 10 – Registro de recomendação de receitas

```

{
  "recommendation_type": "recipe_rec",
  "id_fridge": 1,
  "timestamp": "2017-10-13 14:13:19.974",
  "products": [
    {
      "recipe_description": "Trança de leite condensado",
      "metainfo_type": "meta_info_recipe",
      "recipe_steps": [
        "Aqueça o forno em temperatura alta, a 200 °C",
        "Dissolva o fermento no leite com o açúcar, junte os ovos, o leite condensado e o óleo. Misture bem.",
        "Aos poucos, adicione a farinha de trigo e trabalhe a massa até ficar homogênea.",
        "Cubra-a e deixe descansar até dobrar de tamanho.",
        "Amasse novamente e forme a trança.",
        "Coloque-a numa assadeira levemente untada e leve ao forno durante 45 minutos ou até dourar.",
        "Ainda quente, regue com o leite condensado."
      ],
      "classification": {
        "especification": 4,
        "class": 3
      },
      "url": "https://abrilmdemulher.files.wordpress.com/2017/04/receita-torta-marmore-de-leite-condensado163.jpeg?quality=90&stri_o=info&w=654",
      "products": [
        {
          "product_quantity_unit": "xicara",
          "bar_code": "Leite Morno",
          "classification": {
            "especification": 1,
            "class": 1
          },
          "product_quantity": "1"
        },
        ...
      ]
    },
    ...
  ]
}

```

Fonte: Elaborado pelo Autor

4.3.4.2 Processo de Geração de Recomendações

Neste trabalho, implementou-se quatro formas distintas de recomendação conforme descrito a seguir, sendo elas, recomendação de produtos faltantes ou novos, além de receitas a partir do conteúdo disponível ou do perfil.

- **Recomendação de Produtos Faltantes**

A recomendação de produtos faltantes baseia-se na ideia de lembrar ao usuário quando determinados produtos considerando essenciais estão em falta e efetuar a compra desses itens. Assim, o usuário será alertado quando isso ocorrer e poderá decidir se aceita que se efetive a compra ou não.

Para que as recomendações sejam possíveis são necessárias duas informações: lista de produtos essenciais, obtida a partir das configurações de usuário, e da lista de interações.

A partir dessas informações, um processo em segundo plano, periodicamente, verificará a necessidade da compra desses produtos.

Para a geração das recomendações, inicialmente será criada uma lista com os produtos contidos atualmente na geladeira e suas respectivas quantidades, a partir do conjunto de registros de interações. Em seguida, será comparado produtos requisitados com as respectivas quantidades de produtos existentes e, então, uma lista com os itens em falta será criada e gravada na base de registros de recomendação.

• **Recomendação de Produtos Novos**

A recomendação de produtos novos tem como princípio fundamental o conceito de filtragem colaborativa, descrita na Seção 3.3. Assim, sugestões são criadas a partir da comparação entre usuários com preferências parecidas. Tendo conhecimento do usuário com maior semelhança, é possível recomendar produtos que um usuário interagiu mas que o outro não conhece. Apesar de não conhecer o produto sugerido, a probabilidade de a recomendação agradar o usuário é alta, já que a sugestão emergiu de um usuário com perfil similar.

A comparação entre usuários foi realizada utilizando da correlação de Pearson, descrita na Seção 3.3.1.1. As informações utilizadas para as sugestões de itens são compostas pelos registros de interações e as metainformações dos produtos.

Primeiramente, uma matriz idêntica à matriz da Tabela 2 foi construída. No entanto, cada par de usuário e item é interpretado como o número de interações entre usuário e item, ao contrário da matriz de avaliação da tabela mencionada. A partir da matriz, é possível calcular a média de interações para cada usuário. Tendo o número de interações entre cada usuário e cada item além da média de interações, é possível obter a similaridade entre cada usuário.

A partir da similaridade entre usuários, ordena-se uma lista de usuários de maneira descendente, tendo como referência o usuário ao qual deseja-se recomendar um item. Após isso, a lista ordenada é percorrida. Para cada usuário presente nela, é calculada uma subtração de conjuntos envolvendo tal indivíduo e o usuário de receberá as recomendações. Tais conjuntos se referem aos produtos aos quais cada usuário interagiu. E, como consequência do cálculo, o conjunto de itens resultantes releva os produtos aos quais o usuário de referência ainda não interagiu mas o outro o fez. Por fim, o resultado é adicionado ao conjunto de recomendação.

Assim, o processo será realizado para os demais usuários da lista até que se atinja um conjunto de produtos com a quantidade desejada que, então, será registrado na base de recomendações.

• **Recomendação de Receitas com Base nos Produtos Dis-**

poníveis

Este tipo de recomendação objetiva selecionar as receitas que englobem em seu conteúdo apenas os itens disponíveis, tanto quanto possível. Para o cálculo das recomendações, são necessárias as metainformações dos produtos e receitas, além dos registros de interação. Assim, é possível comparar produtos atuais com os itens contidos em receitas.

Cada receita não especifica um produto em particular, mas deixa claro a classificação do produto. Assim, ao invés de especificar uma caixa de leite da marca X, deixa restrito a um produto que é um laticínio e, mais especificamente, uma caixa de leite.

Para o processo de criação de recomendação, inicialmente, a lista de itens atualmente contidos na geladeira é criada. Após isso, para cada receita na base de dados é contabilizado o número de itens presentes na receita e na geladeira. Em seguida, ordena-se a lista de receitas começando por aquela que contém o maior número de correspondências entre receita e conteúdo. Por fim, um conjunto contendo as primeiras receitas da lista é gravado na base como uma recomendação já efetuada.

- **Recomendação de Receitas com Base no Perfil do Usuário**

As recomendações de receitas a partir do perfil do usuário buscam trazer receitas ao usuário a partir das suas preferências por produtos em específico. Assim, seleciona-se receitas que contenham produtos que o usuário tem maior preferência. As informações necessárias à recomendação são as interações dos usuários e as metainformações de produtos e receitas.

Para gerar as sugestões, inicialmente cria-se uma lista com todos os produtos com os quais o usuário em questão interagiu e as contagens de interações com cada produto. Seleciona-se, em seguida, o conjunto de produtos com maior frequência de interações. Por fim, seleciona-se receitas que contenham tais produtos

4.3.4.3 Processo de Sincronização de metainformação

A sincronização é feita a partir da comparação entre os momentos em que se criou o registro presente na base de metainformação e o registro contido no mercado. Caso o registro do mercado seja mais recente, esse será enviado para o servidor para atualização do registro.

Para que a sincronização seja possível, em cada metainformação tem-se um campo chamado *timestamp* que indica a data de criação de tal registro. Por fim, a operação de sincronização deve ser realizada periodicamente por um processo em segundo plano.

4.3.5 Camada de Agente Externo

A camada descrita nesta seção refere-se ao componente independente do modelo proposto, isto é, o mercado. Ele possui um sistema próprio, mas que disponibiliza um conjunto de serviços pelos quais é possível a interação externa. O primeiro serviço é a sincronização de metainformação de produtos, onde periodicamente serão verificadas alterações, ou inserções de novos produtos. Caso existam dados desatualizados, estes serão enviados ao servidor principal.

Além disso, há o serviço de compras, onde uma lista de produtos será informada em conjunto com as respectivas quantidades. Uma verificação de disponibilidade dos itens solicitados será realizada e, como retorno, o serviço indica quais produtos foram adquiridos com sucesso e quais não puderam ser atendidos. Vale destacar que, apesar de a verificação de disponibilidade ser realizada antes mesmo da sugestão ao usuário, é possível que o produto acabe até o momento em que a compra seja realmente solicitada.

5 APLICAÇÃO DO MODELO E ANÁLISE DOS RESULTADOS

Nesse capítulo será realizada a apresentação dos resultados obtidos a partir da aplicação do modelo proposto materializado em um sistema computacional a um cenário de estudo.

5.1 INTRODUÇÃO

As discussões nesse capítulo estão decompostas em três partes, sendo elas:

- **Fluxo de execução do sistema:** Apresenta a dinâmica do sistema a começar pela leitura dos produtos contidos na geladeira e finalizando na apresentação de recomendações e receitas, além de algumas funcionalidades, dentre as descritas no Capítulo 4.
- **Cenário de Aplicação:** Apresenta o cenário em que o sistema será avaliado. Assim, detalha-se o ambiente da simulação, os dados utilizados, sua obtenção, organização, além das ações executadas pelo sistema.
- **Avaliação do Protótipo:** Nesta seção, a partir do cenário proposto, serão demonstradas as interações com o protótipo e o resultado das interações, seja na forma de recomendações de produtos e receitas ou através de informações de estado da geladeira e de produtos contidos nesta.

5.2 FLUXOS DE EXECUÇÃO DO SISTEMA

No sistema diversas operações são executadas, às quais incluem os diversos componentes que o compõem. A seguir, são apresentados e explanados alguns fluxos de execução.

5.2.1 Leitura de Conteúdo

No momento em que a geladeira for ligada, conforme a Figura 15, o sistema será inicializado e as portas (ou terminais) serão configurados a fim de permitir a comunicação com os leitores e com o mecanismo de fechamento. Ademais, os eventos, disparados pela mudança do es-

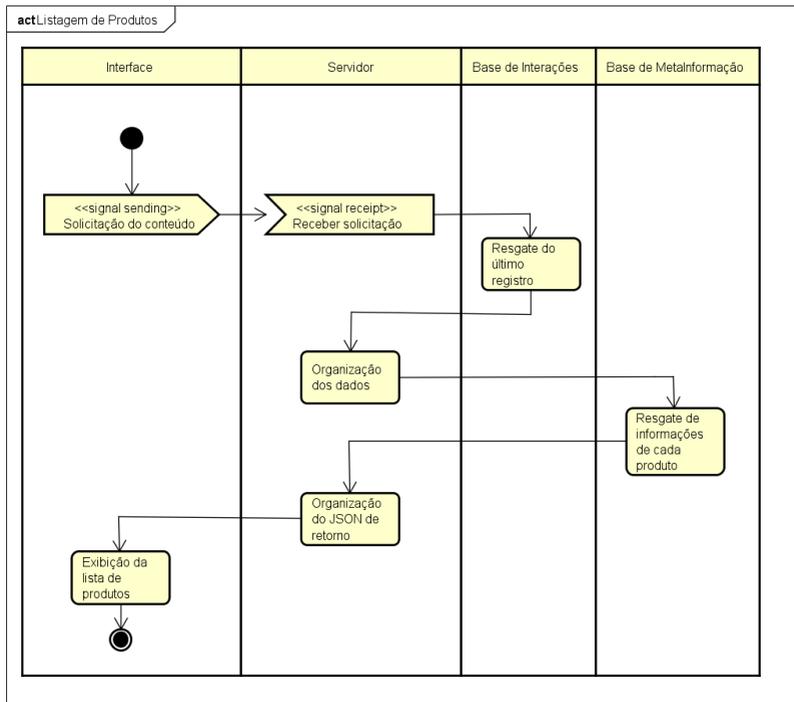
tado da porta, também são configurados. Após a conclusão das ações mencionadas, o sistema entra em modo de espera.

A partir desse ponto, o sistema dependerá da ação do usuário para operar. Assim, quando o usuário abrir ou fechar a porta, o sensor de fechamento irá propagar um novo sinal para o sistema. Quando o evento de mudança ocorre verifica-se qual o tipo de evento ocorreu, ou seja, abertura ou fechamento. Caso aberto, o sistema entra em modo de espera por alguns segundos até prosseguir com a operação, garantindo que a porta esteja realmente aberta e reduzindo as chances de ruídos interferirem no funcionamento do leitor. Além disso, garante-se que o usuário tenha tempo suficiente para fechar a porta de maneira voluntária.

Após o período transcorrer, uma nova leitura é realizada e caso ainda aberta, um registro de porta aberta é enviado ao servidor. Caso for verificado, após a interação do usuário, que a porta está fechada, espera-se também alguns segundos. Após esse tempo, um comando de leitura é enviado para os leitores de etiquetas. Estes, por sua vez, realizam a captura das informações das *tags* ao alcance e as enviam ao sistema da geladeira. Por fim, um registro de interação é enviado no servidor e gravado na base de interações.

enviará uma requisição da lista de produtos referentes à uma geladeira específica. Ao receber a solicitação, o servidor realiza uma busca na base de interações pelo último registro gravado ao qual contém os códigos EPC lidos das etiquetas. Após isso, tendo o conjunto de códigos EPC, fará uma busca pelo produto correspondente a cada um. Assim, se terá uma lista de produtos e suas respectivas quantidades. Por fim, a lista de produtos, em formato JSON, é retornada à interface e apresentada ao usuário.

Figura 16 – Fluxo para listagem de conteúdo da geladeira



Fonte: Elaborado pelo Autor

5.2.3 Recomendação de Produtos Novos

O processo de geração de recomendações, como já dito, é automaticamente inicializado pelo servidor, conforme Figura 17. Inicialmente, a matriz de frequência de interações de usuários com produtos é criada.

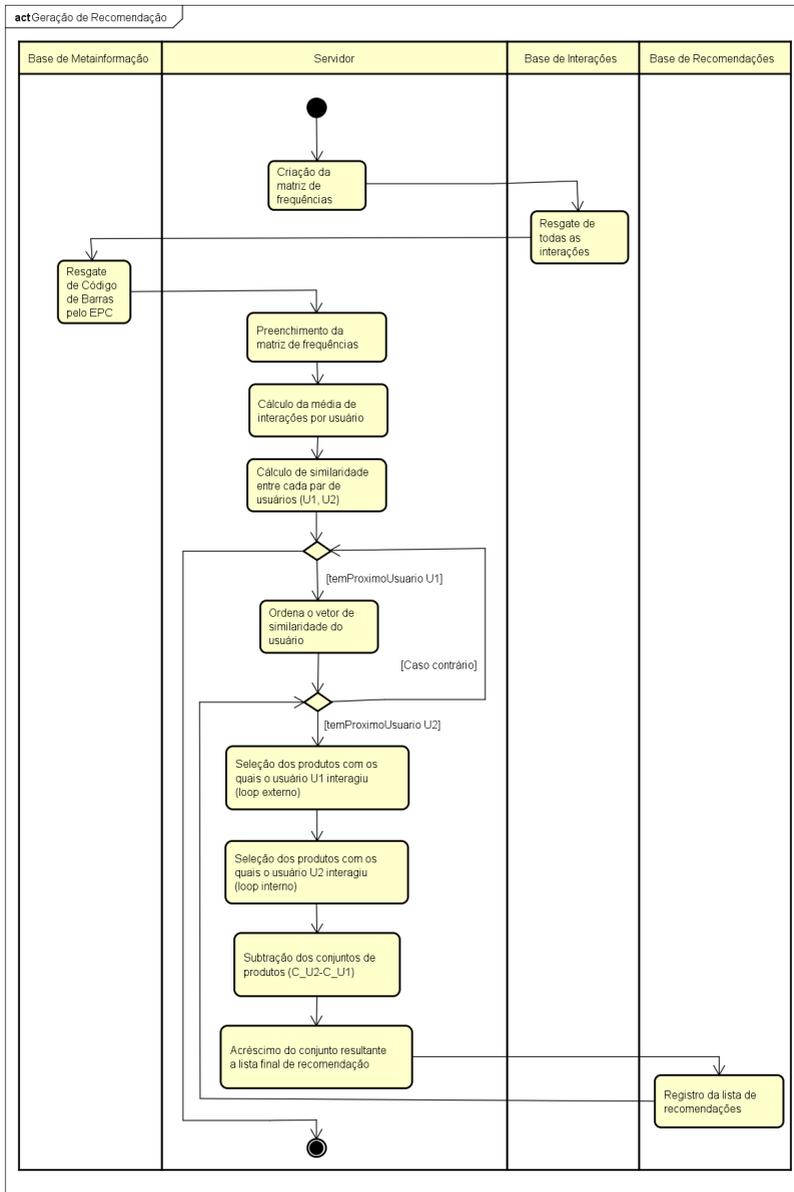
Vale destacar, que um usuário está relacionado à uma geladeira. Em seguida, busca-se na base de interações todas as interações armazenadas. A partir das interações, na base de metainformação é efetuada a combinação entre códigos EPC e código de barras. A matriz de frequências é, então, preenchida com os dados obtidos no processo anterior.

Como parte do cálculo da correlação de Pearson, a média de interações de cada usuário deve ser calculada. Logo após, é computada a similaridade com a Equação 1 entre os pares de usuários, indicados na Figura 17 como $U1$ e $U2$.

Utilizando as similaridades calculadas inicia-se o processo de recomendação para cada usuário ($U1$) cadastrado no sistema. Inicialmente, o conjunto de similaridades do usuário $U1$ com os demais é ordenado em ordem decrescente, ou seja, do usuário com maior similaridade ao menor. Em seguida, para cada usuário $U2$ na lista de similaridades é realizada uma subtração de conjuntos de produtos aos quais $U2$ interagiu pelos itens que $U1$ interagiu. Assim, tem-se um conjunto de produtos que $U1$ não conhece e que poderão ser sugeridos como novas opções de compra.

O processo citado é repetido até que todos os indivíduos na lista de usuários similares forneçam recomendações ou quando o número máximo de produtos recomendados for atingido. E quando uma das duas possibilidades ocorrer, o conjunto de recomendações será salvo na base de recomendações e o processo de recomendação se repetirá para o próximo usuário.

Figura 17 – Fluxo para recomendação de produtos novos



Fonte: Elaborado pelo Autor

5.2.4 Recomendação de Produtos Faltantes

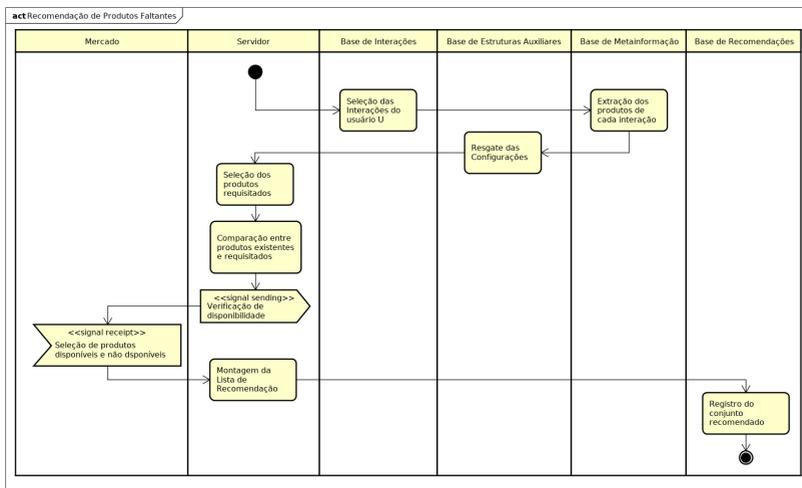
Da mesma forma que a seção anterior, o processo de recomendação é iniciado automaticamente pelo servidor, conforme Figura 18. A partir disso, para que se recomende produtos é necessário ter as listas de produtos disponíveis atualmente e de produtos requisitados. Para tanto, inicialmente, a base de interações é consultada para o resgate da última interação, tendo esta a indicação dos itens mais recentes. A partir da lista de códigos EPC extraídos das interações é realizada uma consulta à base de metainformação para que sejam obtidos os dados dos produtos.

O próximo passo consiste na obtenção, na base de estruturas auxiliares, das informações de configuração do usuário, às quais indicam os produtos essenciais. A partir da extração dessas informações é efetuada uma comparação de quantidade entre produtos disponíveis e essenciais. Caso o produto essencial esteja disponível na quantidade necessária, nada acontece. No entanto, caso o produto esteja disponível e em quantidade insuficiente, este é inserido na lista de recomendações tendo como quantidade sugerida a diferença entre o valor necessário e o existente. Caso o produto necessário não exista, sugere-se a quantidade total indicada nas configurações.

A seguir, para o conjunto de produtos recomendados, é executada uma verificação no mercado sobre a disponibilidade dos mesmos conforme a quantidade especificada no passo anterior. Assim, caso o item esteja acessível, uma indicação positiva será retornada. Caso contrário, o serviço do mercado fará uma busca por um produto similar e retornará tal item como alternativa. Por fim, podem haver casos em que nenhum item similar exista. Assim, apenas uma indicação negativa é retornada.

Com o conjunto de produtos indicados pelo mercado como disponíveis para compra, a lista final de recomendações é criada e inserida na base de recomendações.

Figura 18 – Fluxo para recomendação de produtos faltantes



Fonte: Elaborado pelo Autor

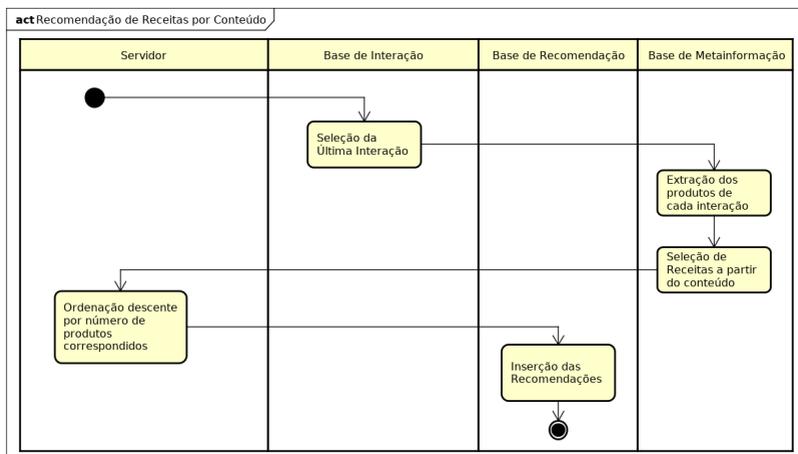
5.2.5 Recomendação de Receitas por Conteúdo

O processo de recomendação, conforme descrito na Seção 4.3.4.2, decorre a partir da recomendação de receitas que contenham alguns dos produtos disponíveis na geladeira.

O processo é iniciado automaticamente no servidor e o primeiro passo ocorre por meio na seleção da última interação, contendo os códigos EPC, na respectiva base de dados.

A partir dos códigos EPC, obtém-se o conjunto de produtos correspondentes a ele considerando a base de metainformação. Então, seleciona-se na base de metainformação as receitas que contenham pelo menos um dos produtos do conjunto. A partir do número de correspondências entre produtos da lista selecionada e da receita o conjunto de receitas é ordenado em ordem decendente, ou seja, receitas com maior número de correspondências primeiro. Por fim, o conjunto gerado é registrado na base de recomendações.

Figura 19 – Fluxo para recomendação de receitas por conteúdo



Fonte: Elaborado pelo Autor

5.2.6 Recomendação de Receitas por Perfil

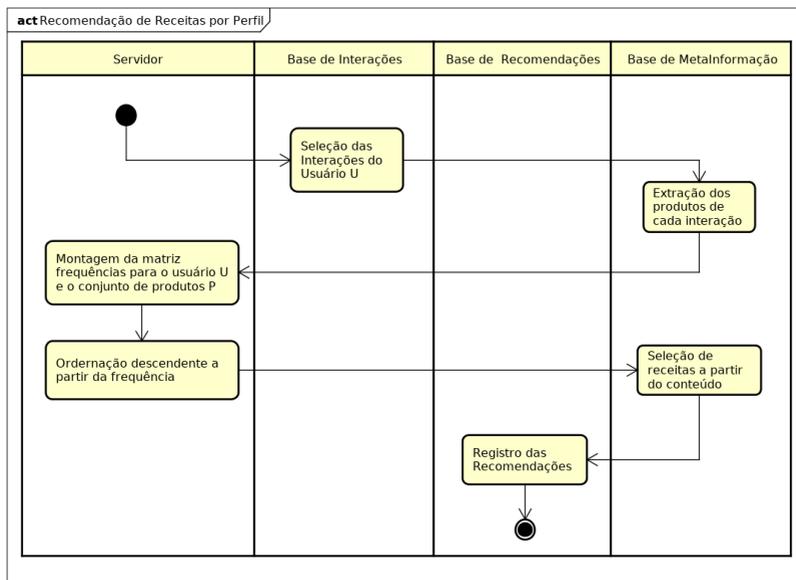
A sugestão de receitas por perfil, conforme Figura 20, considera os produtos com os quais o usuário mais interagiu durante a escolha de quais receitas recomendar.

E, como nos demais processos, inicia-se no servidor automaticamente. O primeiro passo consiste na seleção de todas as interações do usuário na base de interações, seguida pela extração dos produtos de cada interação na base de metainformação. A partir disso, a matriz de frequências é criada e preenchida com base nos obtidos e da quantidade de vezes em que aparecem nas interações. O próximo passo, portanto, é a ordenação decendente através da frequência. Os produtos com maior frequência serão, então, utilizados como base na seleção de receitas. Nessa implementação, limitou-se em cinco (5) o número de produtos utilizados.

Com a lista de produtos, obtém-se o conjunto de receitas que contêm pelo menos um desses itens. O próximo passo consiste em ordenar a lista em disposição decendente a partir do número de produtos na receita correspondidos na lista de produtos.

Por fim, o conjunto de receitas sugeridas é registrado na base de recomendações.

Figura 20 – Fluxo para recomendação de receitas por perfil



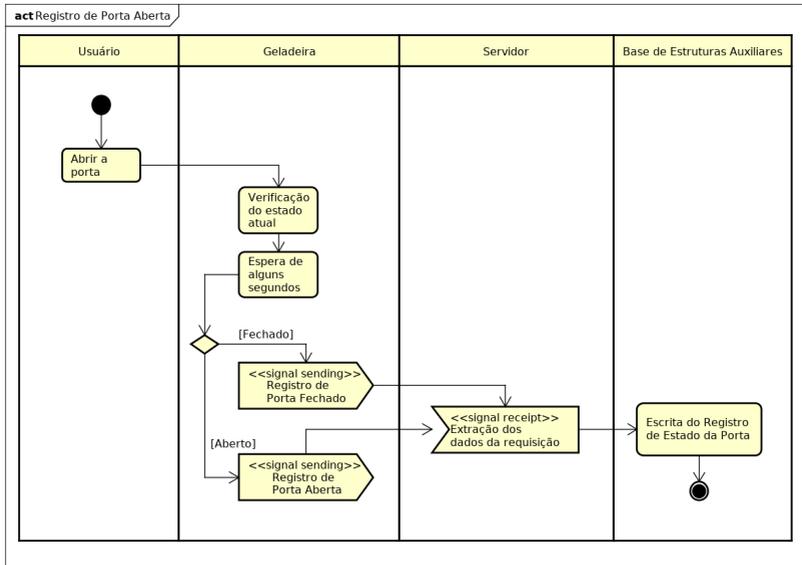
Fonte: Elaborado pelo Autor

5.2.7 Fluxo para Detecção e Registro de Porta Aberta

Considerando-se, inicialmente, que a geladeira se encontra fechada. Em um dado momento, o usuário abre-a e insere e/ou retira produtos, podendo, ao final, não fechar a porta. No momento da abertura, o sistema da geladeira detecta a ação e inicia um período de espera. Ao final desse tempo, um registro correspondente ao estado da porta é inserido na base de estruturas auxiliares.

Com relação à consulta de estado da porta, apesar de seu respectivo diagrama não ser apresentado neste trabalho, o fluxo é muito semelhante aos relacionados à consulta de listagem de produtos. Assim, quando a interface de usuário solicita o estado atual no servidor receberá o último registro realizado. A partir dele, caso indique estado aberto, uma notificação é emitida na interface.

Figura 21 – Detecção de porta aberta

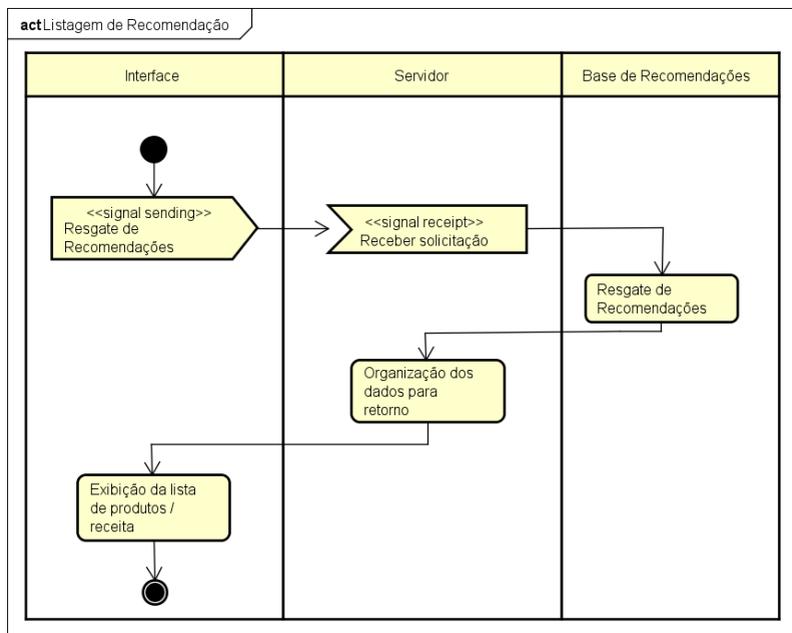


Fonte: Elaborado pelo Autor

5.2.8 Listagem de Recomendações

O processo de listagem de recomendações é disparado através da interface de usuário. Desse modo, a interface envia uma requisição ao servidor solicitando um conjunto de recomendações para um determinado usuário, conforme Figura 22. Ao receber a solicitação, o servidor faz uma busca na base de recomendações pelos produtos recomendados. Em seguida, os dados são organizados e o conjunto de recomendação é enviado à interface.

Figura 22 – Fluxo para listagem de recomendações



Fonte: Elaborado pelo Autor

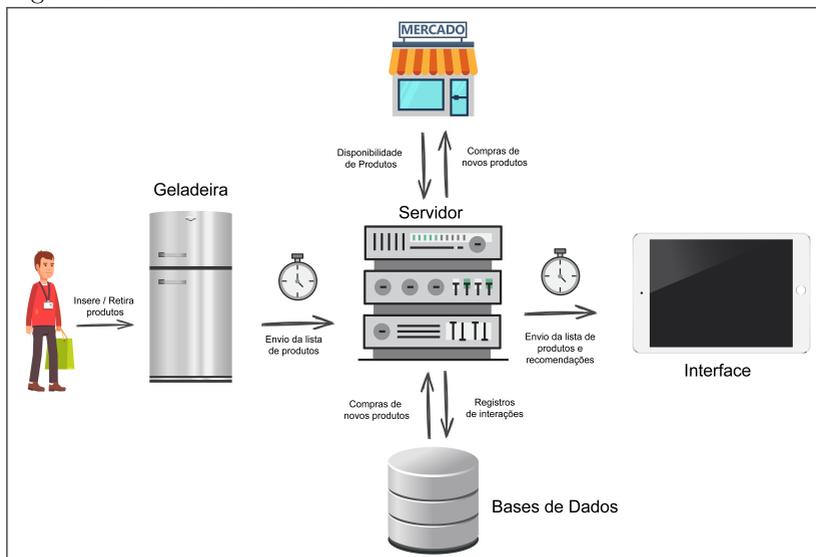
5.3 CENÁRIO DE APLICAÇÃO

A avaliação do modelo dar-se-á a partir do ambiente ilustrado na Figura 23. O ambiente consiste na demonstração de uma sequência de ações, começando pela interação do usuário, com o objetivo de observar o comportamento e as funcionalidades do protótipo implementado.

Em relação, as bases de dados, essas foram preenchidas antes da avaliação do sistema. Primeiramente, para a base de metainformação foram alocadas informações de quarenta (40) produtos, extraídas de produtos originais a partir de um supermercado na cidade de Aranguá. Por outro lado, a informação referente à URL da imagem do produto foi obtida em *websites* de supermercados. Já em relação às receitas, utilizou-se dez (10) receitas obtidas a partir de sites de culinária. Tanto as informações de produtos quanto as receitas foram formatadas conforme a Seção 4.3.3.3.

Quanto à identificação das geladeiras e, por consequência, dos usuários, não criou-se uma base específica para eles, apenas atribuiu-se

Figura 23 – Ambiente do cenário



Fonte: Elaborado pelo Autor

um identificador utilizado em cada registro específico a um determinado usuário. Como foram definidas dez (10) geladeiras, foram atribuídos os valores de um (1) a dez (10) para diferenciação de cada uma.

Para cada geladeira, foram criadas, de maneira aleatória, interações, cada qual com um conjunto de códigos EPCs representando os produtos. Assim, definiu-se que o número de interações seria maior ou igual a cinco (5) e menor ou igual a 25. Além disso, para cada interação o número mínimo de itens registrados seria de três (3) e, no máximo, dez (10).

Em relação às configurações, descritas na Seção 4.3.3.2, todas as geladeiras apresentaram parâmetros idênticos excetuando-se as listas de produtos essenciais e suas respectivas quantidades mínimas. Assim, tais produtos e suas respectivas quantidades foram definidos aleatoriamente para cada usuário. Quanto à quantidade de produtos requisitados, estabeleceu-se o número de cinco (5) produtos e, em relação à quantidade, definiu-se um valor randômico entre um (1) e vinte (20).

Como forma de teste do protótipo referente à estrutura física da geladeira, dois produtos receberam etiquetas com o respectivo código EPC, sendo eles, a “Margarina com Sal Qualy^{®1}” e “Creme de Leite

¹<http://qualy.com.br/>

Tirol^{®2}”.

5.4 AVALIAÇÃO DO PROTÓTIPO

Nessa seção é descrita a avaliação do protótipo criado. Para tanto, este será aplicado aos fluxos desenvolvidos na Seção 5.2. Assim, para cada fluxo comparar-se-á os resultados obtidos com os esperados.

5.4.1 Leitura do Conteúdo

Inicialmente a geladeira está vazia. Ao adicionar dois produtos, sendo eles, a “Margarina com Sal Qualy[®]” e “Creme de Leite Tirol[®]”, respectivamente, depois de alguns minutos os seguintes códigos EPC são lidos.

- 8665580279609348107299713701
- 8665580277303506451141610373

Os dados são, então, enviados ao serviço de registro de interação e o registro é gravado na base de interações, conforme apresentado no Quadro 11.

Quadro 11 – Registro de interação dos produtos

```
{
  "epc_codes": [
    "8665580279609348107299713701",
    "8665580277303506451141610373"
  ],
  "id_fridge": 1,
  "_id": {
    "$oid": "59f935defe4c567b609fdadc"
  },
  "timestamp": "2017-11-01 00:47:58.97"
}
```

Fonte: Elaborado pelo Autor

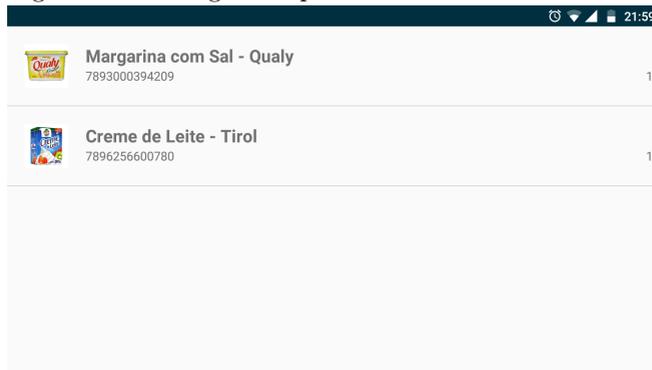
5.4.2 Listagem de Conteúdo da Geladeira

Continuando o fluxo da seção anterior, ao tentar ler o conteúdo da geladeira logo após o fechamento da porta, a listagem da interface

²<http://www.tirol.com.br/pt/>

ainda se mantém vazia. Alguns segundos depois, a listagem é atualizada e o conteúdo exibido é mostrado na Figura 24.

Figura 24 – Listagem de produtos na Interface



Fonte: Elaborado pelo Autor

Dessa forma, afirma-se que a listagem de produtos produz resultados de acordo com o esperado, já que a lista é alterada após a interação. No entanto, o fator temporal entre a interação e a exibição é compreensível. Assim, o intervalo de tempo decorre do aguardo, na geladeira, até a realização da leitura. Isso é necessário para garantir que exista tempo hábil para coletar ou inserir todos os produtos que se deseja.

5.4.3 Recomendações de Produtos Novos

Como exemplo, deseja-se gerar recomendações para o Usuário 1. Para tanto, seguiu-se o fluxo da Seção 5.2.3. Os passos foram executados até o cálculo de similaridade entre usuários sobre a matriz de frequências de interações e obteve-se o usuário mais semelhante. Tal indivíduo é identificado como Usuário 10 e o grau de similaridade entre este e o Usuário 1 foi de 0,15. A média de interações com produtos para o Usuário 1 foi de 2,05, já para o Usuário 10 foi de 2,12.

Como forma de verificação, conforme Tabela 3, tem-se as linhas da matriz de frequência referentes aos usuários.

Tabela 3 – Matriz de frequências de interações

U1	0	2	2	6	2	3	6	0	2	4	2	5	2	1	1	2	1	8	5	6	5	1	2	3	3	5	5	3	1	0	0	0	0	0	
U10	2	2	7	3	3	3	4	3	0	0	2	4	0	0	4	0	2	9	6	0	2	0	0	5	4	0	2	3	1	2	4	7	5	2	3

Fonte: Elaborado pelo Autor

Executando o cálculo da correlação de Pearson, descrita na Equação 1.

$$sim = \frac{\left[\begin{array}{l} (0 - 2,05)(2 - 2,12) + (2 - 2,05)(2 - 2,12) + \\ (2 - 2,05)(7 - 2,12) + (6 - 2,05)(3 - 2,12) + \\ (2 - 2,05)(3 - 2,12) + \dots \end{array} \right]}{\left[\begin{array}{l} \sqrt{(0 - 2,05)^2 + (2 - 2,05)^2 + (2 - 2,05)^2 + \\ (6 - 2,05)^2 + (2 - 2,05)^2 + \dots} \\ \times \sqrt{(2 - 2,12)^2 + (2 - 2,12)^2 + \\ (7 - 2,12)^2 + (3 - 2,12)^2 + \\ (3 - 2,12)^2 + \dots} \end{array} \right]}$$

$$sim = 0,15$$

Assim, demonstra-se que o cálculo de similaridade está correto. Percebe-se que o número de produtos com os quais o Usuário 1 não apresentou nenhuma interação, ou seja, as posições na linha do usuário mencionado preenchidas com zero (0) é igual a oito (8). Assim, espera-se que pelos menos esses produtos sejam recomendados.

No entanto, um número maior de itens podem ser sugeridos. Isso ocorrerá quando a quantidade obtida de recomendações através do usuário com maior similaridade for insuficiente. Assim, recomendações de outros usuários com graus de semelhança menores serão consideradas.

Obteve-se, a partir da consulta à base de recomendações, a seguinte lista de itens:

- 789034630442 - Creme de Leite Parmalat
- 7894900093056 - Iogurte Danone
- 7896648699453 - Leite Integral Langaru
- 7894904326044 - Pizza Calabresa Seara
- 7896256603422 - Leite Desnatado Tirol

- 7896256602050 - Iogurte de Morango Tirol
- 7891025101376 - Iogurte Danone
- 7896034680010 - Leite Condensado Parmalat
- 7891515490430 - Lasanha Calabresa Perdigão

Os primeiros oito produtos da lista são aqueles que o Usuário 1 não interagiu, mas que o Usuário 10 o fez, na mesma sequência mostrada na Tabela 3. Já os demais itens foram sugeridos com base em outros usuários com menor similaridade. Vale ressaltar que o JSON gerado pelo sistema não foi inserido diretamente neste trabalho visto a extensão do mesmo.

5.4.4 Recomendação de Produtos Faltantes

Nesta seção, busca-se avaliar a recomendação da reposição de produtos aos quais o Usuário 2 julga serem essenciais. Para tanto, considera-se o fluxo de execução demonstrado na Seção 5.2.4 e o conjunto de produtos contidos atualmente e suas respectivas quantidades:

- Mortadela Perdigão³ 5 UN
- Pizza Calabresa Sadia⁴, 4 UN
- Iogurte de Morango Activia⁵, 5 UN

E o conjunto de produtos que o Usuário 2 estipulou que sempre devem estar à disposição:

- Mortadela, 8 UN
- Pizza Calabresa, 6 UN
- Iogurte de Morango, 5 UN
- Linguiça de Pernil, 15 UN
- Leite integral, 8 UN

Percebe-se que alguns produtos estão ausentes e, outros, em falta como, por exemplo, o produto Pizza está em quantidade insuficiente e o produto Leite está ausente. Assim, a recomendação deve conter tais produtos além dos outros não citados.

Seguindo o fluxo da Seção 5.2.8, tem-se a listagem de sugestões na interface de usuário como é mostrado na Figura 25.

Pode-se verificar que há diferenciação entre os produtos, sendo de “Reposição” e “Sem Alternativas”. A reposição trata da recolocação de

³<http://www.perdigao.com.br/>

⁴<http://www.sadia.com.br/>

⁵<https://www.activiadanone.com.br/>

Figura 25 – Listagem de Recomendações por falta

Item	Quantidade	Nota
<input type="checkbox"/> Linguiça de Pernil Gold Meat Sem alternativas	15	
<input type="checkbox"/> Leite integral Aurora Reposição	8	
<input type="checkbox"/> Mortadela Perdigão Reposição	3	
<input type="checkbox"/> Pizza Calabresa Sadia Reposição	2	

ENVIAR

Fonte: Elaborado pelo Autor

produtos essenciais. O “Sem alternativas”, indica que não foi possível encontrar no mercado, o produto esperado nem um similar a ele. Há, além disso, outras duas formas de recomendação de compras: “Novo”, referente à recomendação de produtos novos, como descrito anteriormente, além de “Similar” que indica a reposição de produtos essenciais que não estavam disponíveis no mercado, mas que foram substituídos por produtos similares.

5.4.5 Recomendação de Receitas a partir de Conteúdo

A recomendação de receitas por conteúdo, como descrito na seção respectiva no Capítulo 4, busca disponibilizar um conjunto de receitas ao usuário de acordo com os itens que este possui em sua geladeira.

Considera-se que, inicialmente, os seguintes produtos estejam disponíveis com suas respectivas quantidades:

- Leite Integral, com 2 UN
- Leite Condensado Parmalat^{®6}, com 3 UN
- Queijo Mussarela Sadia[®], com 5 UN.

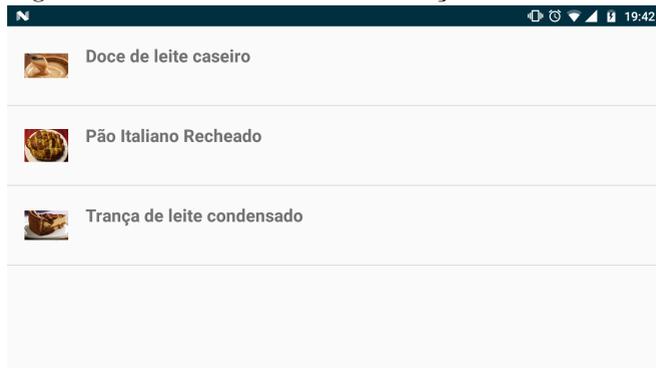
O processo de recomendação avaliará os produtos do ponto de vista de suas características, ou seja, terá um enfoque nos tipos de produtos e não em produtos de determinadas marcas.

O processo de recomendação analisa quais receitas satisfazem o requisito especificado e retornará um conjunto de itens como sugestão.

⁶<http://www.parmalat.com.br/>

Os itens sugeridos como recomendações são mostrados na Figura 26.

Figura 26 – Resultado da recomendação de receitas



Fonte: Elaborado pelo Autor

Como resultado da recomendação, tem-se três receitas sugeridas dentre as cinco utilizadas nesse cenário, ou seja, duas receitas não incluíam nenhum dos produtos contidos na geladeira. A primeira receita na lista conta com o Leite, a segunda com o Queijo Mussarela e a terceira com Leite e Leite Condensado.

5.4.6 Recomendação de Receitas por Perfil

Como descrito na Seção 4.3.4.2, a sugestão de receitas por perfil buscará receitas que contenham alguns dos itens com os quais o usuário mais interagiu. Para tanto, uma matriz de frequência de interações é elaborada. Com base nas frequências de interações do usuário em questão, uma lista é criada a partir das classes de produto.

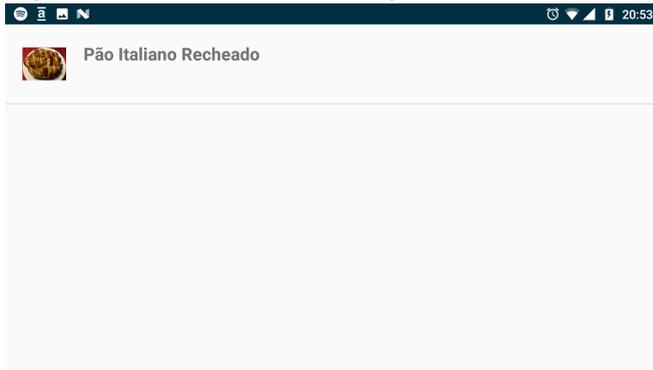
Considerando que o total de produtos para geração de recomendação foi limitado em cinco (5) tem-se os seguintes produtos:

- Margarina com Sal Qualy, com 9 interações
- Refrigerante de Guaraná Fanta, com 9 interações
- Linguiça de Pernil Gold Meat, com 8 interações
- Iogurte Danone, com 7 interações
- Queijo Mussarela Sulfrios, com 7 interações

Com base neste conjunto, o processo de recomendação realiza uma busca na base de interações pela receitas que possuem tais cate-

gorias de produtos. A partir disso, o conjunto de receitas da Figura 27 foi sugerido.

Figura 27 – Lista de Receitas Sugeridas por Perfil



Fonte: Elaborado pelo Autor

Apesar de apenas uma receita ter sido sugerida, devido ao total de receitas muito reduzido do cenário, é possível validar a recomendação, já que esta conta com o produto Queijo Mussarela.

5.4.7 Alerta de Porta Aberta

Os alertas enviados aos usuários que esquecem a porta da geladeira aberta, ou não a fecham corretamente, é importante para evitar gastos desnecessários com energia e, possivelmente, com alimentos estragados. Como descrito na Seção 4.3.2, o processo de verificação de porta aberta, dispara um registro no servidor. Para o exemplo, considera-se que inicialmente a porta estava fechada e, em um dado momento, foi deixada aberta.

Após alguns segundos o registro do Quadro 12 foi efetuado na base de estruturas auxiliares, informando a situação.

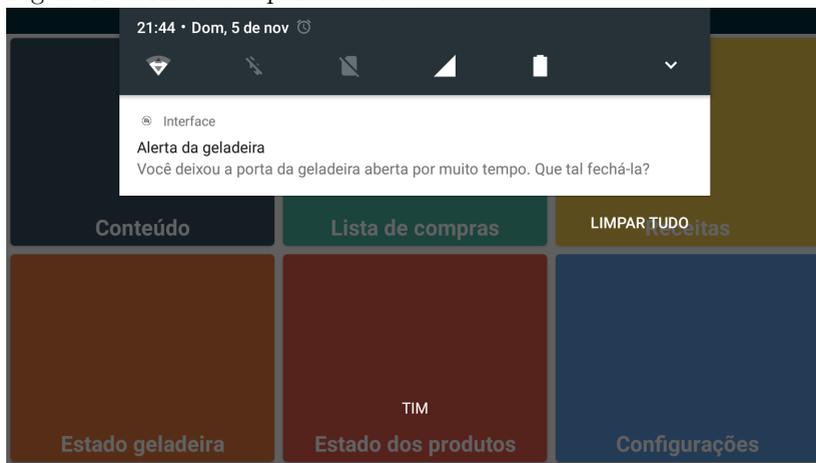
Quadro 12 – Registro de porta aberta

```
{
  "_id": "59ffa035b60a9718b971de4a",
  "id_fridge": 1,
  "record_type": "open_door",
  "door_status": 0
}
```

Fonte: Elaborado pelo Autor

Algum tempo depois, a interface de usuário realiza uma requisição ao serviço de estado de porta. Neste caso, a aplicação da interface verificou que o estado era aberto e notificou ao usuário, conforme a Figura 28.

Figura 28 – Alerta de porta aberta



Fonte: Elaborado pelo Autor

6 CONSIDERAÇÕES FINAIS

Este trabalho teve como objetivo o desenvolvimento de um modelo de geladeira inteligente que facilitasse o dia a dia dos usuários a partir da análises das interações destes, baseando-se nos conceitos de IoT e Sistemas de Recomendação.

Para atingir o objetivo geral, inicialmente, o modelo foi projetado. Assim, definiu-se o escopo do projeto, bem como, todos os seus componentes, sendo eles, o sistema da geladeira, o servidor de serviços, as bases de dados e de recomendações, a interface de usuário e, por fim, os serviços disponibilizados pelo mercado.

Com o modelo criado, um projeto de leitura e monitoramento dos produtos contidos na geladeira foi elaborado e desenvolvido. Para tanto, fez-se uso da tecnologia RFID e do conceito de códigos EPC. Assim, à cada produto foi agregada uma etiqueta RFID contendo o código único possibilitando a identificação de maneira simples no momento em que este fosse inserido na geladeira. Além disso, elaborou-se uma estrutura para conter os equipamentos de leitura e processamento. Ao final, todas as informações de produtos disponíveis são enviadas ao servidor principal.

A partir do projeto de leitura e monitoramento, ou seja, a fonte de dados sobre os hábitos do usuários, tornou-se viável a implementação do sistema de análise das interações e recomendação de produtos e receitas. Para tanto, utilizou-se de algumas abordagem de sistemas de recomendação. Ao final, o sistema foi capaz de recomendar produtos novos ao usuários a partir do conceito de filtragem colaborativa. Além disso, foi possível sugerir produtos essenciais considerando recomendações baseadas em conteúdo, bem como, sugestões de receitas, levando-se em conta tanto os produtos disponíveis na geladeira quanto o perfil do usuário, ou seja, os produtos em que o usuário teve mais interesse.

Como forma de avaliar o sistema implementado elaborou-se um cenário de testes, onde definiu-se parâmetros como o número de usuários, de produtos, de interações etc. Ademais, diagramas de fluxos de execução foram desenvolvidos a fim de fornecerem uma base para a avaliação do sistema.

Ao final, o sistema demonstrou, em todos os fluxos elaborados para o cenário, os respectivos comportamentos esperados. Portanto, conclui-se que o objetivo geral do trabalho foi atingido, já que a análise de interações implementada, em conjunto com o monitoramento

de produtos, proveem funcionalidades que eliminam ou facilitam algumas atividades diárias dos usuários e que, por consequência, objetiva facilitar o seu dia-a-dia.

Durante a implementação do trabalho algumas dificuldades foram encontradas. A principal delas se refere à limitação do número de produtos na geladeira, já que apenas dois leitores foram utilizados. Claramente, é improvável que uma geladeira contenha somente dois produtos, no entanto, não encontrou-se leitores capazes de efetuar a leitura de um maior número de etiquetas de forma simultânea que tivesse um custo acessível ao projeto.

6.1 TRABALHOS FUTUROS

Durante o desenvolvimento desse trabalho foram elencadas outras possibilidades como trabalhos futuros. As principais se relacionam ao sistema de leitura e monitoramento, além dos algoritmos de recomendação e na sincronização da metainformação. No que se refere ao sistema de leitura, percebeu-se que é factível o aprimoramento do mesmo a partir da modificação dos dispositivos de leitura RFID. Isso seria possível a partir do uso de RFID UHF, no entanto, seria necessário encontrar um meio de baratear os custos desta tecnologia. Outra maneira, seria a criação de uma plataforma única de leitura por RFID que se estendesse por todo o espaço de um “andar” da geladeira. Outra possibilidade de melhoria no monitoramento se refere ao uso de visão computacional como forma de reconhecer os produtos. Por fim, um avanço no projeto está na substituição da placa Raspberry® por um sistema computacional projetado de acordo com as necessidades do sistema, o que permitiria uma redução em custos.

Outra possibilidade de trabalho futuro, como mencionado, está na melhoria dos algoritmos de recomendação. O primeiro ponto a ser revisto refere-se aos dados de entrada, já que informações adicionais poderiam conferir maior precisão nas sugestões. Entre elas está a questão geográfica, ou seja, os costumes de uma determinada região tendem a determinar quais produtos e receitas os usuários apresentariam maior interesse. Além disso, informações específicas do usuário voltadas às restrições alimentares, tais como, intolerância à lactose, glúten entre outros, bem como veganismo. Como última melhora relacionada a captura de dados, tem-se a possibilidade de utilização de mais detalhes acerca dos produtos recomendados, como informações nutricionais, por exemplo.

Em relação à recomendação em si, um aspecto que pode ser melhorado é a questão temporal nas preferências de usuários, ou seja, os gostos do usuários variam com o tempo. Além disso, é possível utilizar algoritmos mais eficientes.

Há também implementações que ficaram pendentes neste trabalho. A primeira delas se refere à sincronização da base de metainformação a partir do mercado. Além disso, não foi implementada a possibilidade de o usuário personalizar suas configurações através do respectivo menu na interface.

Um ponto de alta importância que deve ser considerado é a segurança. Como descrito no Capítulo 2, em IoT, este é um dos desafios que devem ser superados. No contexto da aplicação, é imprescindível que se utilize de ferramentas e protocolos de segurança pra garantir transações de compras sem fraudes, envio preciso de informações sobre produtos contidos, entre outros.

Outro ponto relevante a ser considerado, no futuro, é a diferenciação dos usuários, ou seja, uma geladeira é utilizada por diversas pessoas em uma casa. Assim, um meio pode ser utilizado para diferenciar os usuários em meio às interações que ocorrem com a geladeira.

Por fim, possibilidades de integração com outras tecnologias e produtos existentes foram levantadas. A primeira delas é a integração com a assistente pessoal da Amazon®, a Alexa®, à qual permitiria que usuários comandassem a geladeira por comandos de voz. Além disso, o conceito de monitoramento de produtos e interações com o usuário poderiam ser expandidos à outros compartimentos, por exemplo, uma dispensa ou algum tipo de recipiente para alimentos não perecíveis.

REFERÊNCIAS

- ADOMAVICIUS, G.; TUZHILIN, A. Toward the next generation of recommender systems: a survey of the state-of-the-art and possible extensions. **IEEE Transactions on Knowledge and Data Engineering**, Institute of Electrical and Electronics Engineers (IEEE), v. 17, n. 6, p. 734–749, jun 2005.
- AFAQUI, M. S.; GARCIA-VILLEGAS, E.; LOPEZ-AGUILERA, E. Ieee 802.11ax: Challenges and requirements for future high efficiency wifi. **IEEE Wireless Communications**, v. 24, n. 3, p. 130–137, 2017.
- AGGARWAL, C. C. **Recommender Systems**. [S.l.]: Springer International Publishing, 2016.
- AGHAEI, S.; NEMATBAKHS, M. A.; FARSANI, H. K. Evolution of the world wide web: From web 1.0 to web 4.0. **International Journal of Web & Semantic Technology**, Academy & Industry Research Collaboration Center (AIRCC), v. 3, n. 1, p. 1, 2012.
- AL-FUQAHA, A. et al. Internet of things: A survey on enabling technologies, protocols, and applications. **IEEE Communications Surveys & Tutorials**, Institute of Electrical and Electronics Engineers (IEEE), v. 17, n. 4, p. 2347–2376, Fourthquarter 2015.
- AMAZON. **Amazon Echo - Black**. 2017. Disponível em: <<https://www.amazon.com/Amazon-Echo-Bluetooth-Speaker-with-WiFi-Alexa/dp/B00X4WHP5E>>. Acesso em: 09 abr. 2017.
- APPLE. **Getting Started with iBeacon**: Version 1.0. jun 2014. 1–11 p. Disponível em: <<https://developer.apple.com/ibeacon/Getting-Started-with-iBeacon.pdf>>. Acesso em: 09 abr. 2017.
- ASANO, S.; YASHIRO, T.; SAKAMURA, K. Device Collaboration Framework in IoT-Aggregator for Realizing Smart Environment. In: **2016 TRON Symposium (TRONSHOW)**. Tokyo: Institute of Electrical and Electronics Engineers (IEEE), 2016. p. 1–9.
- BERKOVSKY, S. et al. Recommender algorithms in activity motivating games. In: **Proceedings of the Fourth ACM**

Conference on Recommender Systems. New York, NY, USA: ACM, 2010. (RecSys '10), p. 175–182.

BLUETOOTH SIG. **Bluetooth 5**. 2017. Disponível em: <<https://www.bluetooth.com/specifications/bluetooth-core-specification/bluetooth5>>. Acesso em: 09 abr. 2017.

BLUETOOTH SIG. **Bluetooth Core Specification**. 2017. Disponível em: <<https://www.bluetooth.com/specifications/bluetooth-core-specification>>. Acesso em: 09 abr. 2017.

BLUETOOTH SIG. **How It Works**: Bluetooth is the foundation for transformative wireless connectivity. jan 2017. 58–71 p. Disponível em: <<https://www.bluetooth.com/what-is-bluetooth-technology/how-it-works>>. Acesso em: 09 nov. 2017.

BOBADILLA, J. et al. Recommender systems survey. **Knowledge-Based Systems**, Elsevier BV, Amsterdam, The Netherlands, The Netherlands, v. 46, p. 109–132, jul 2013.

BOICEA, A.; RADULESCU, F.; AGAPIN, L. I. Mongoddb vs oracle – database comparison. In: **2012 Third International Conference on Emerging Intelligent Data and Web Technologies**. [S.l.: s.n.], 2012. p. 330–335.

BRIDGE, D. et al. Case-based recommender systems. **The Knowledge Engineering Review**, Cambridge University Press, v. 20, n. 3, p. 315–320, 2005.

BRIN, S.; PAGE, L. The anatomy of a large-scale hypertextual web search engine. **Comput. Netw. ISDN Syst.**, Elsevier Science Publishers B. V., Amsterdam, The Netherlands, The Netherlands, v. 30, n. 1-7, p. 107–117, abr. 1998.

BURKE, R. Hybrid recommender systems: Survey and experiments. **User Modeling and User-Adapted Interaction**, Kluwer Academic Publishers, Hingham, MA, USA, v. 12, n. 4, p. 331–370, nov. 2002.

CARDOSO, I. G. et al. Vulcanus 2.0: A Recommender System for Accessibility. **CLEI Electronic Journal**, scielouy, v. 19, p. 6 – 6, 04 2016.

CARMONA, D.; DRSKA, M. **Varejistas recorrem à tecnologia da informação para integração**. 2014. Disponível em: <<http://economia.ig.com.br/empresas/comercioservicos/2014-02-17/varejistas-recorrem-a-tecnologia-da-informacao-para-integracao-.html>>. Acesso em: 08 ago. 2017.

CAZELLA, S. C.; NUNES, M.; REATEGUI, E. A ciência da opinião: Estado da arte em sistemas de recomendação. **André Ponce de Leon F. de Carvalho; Tomasz Kowaltowski..(Org.). Jornada de Atualização de Informática-JAI**, p. 161–216, 2010.

CECILIA, A. A.; SUDARSANAN, K. A survey on smart grid. In: **1st International Conference on Emerging Trends in Engineering, Technology and Science, ICETETS 2016 - Proceedings**. [S.l.: s.n.], 2016. p. 1–7.

CHIANG, M.; ZHANG, T. Fog and IoT: An Overview of Research Opportunities. **IEEE Internet of Things Journal**, v. 4662, n. c, p. 1–1, 2016. ISSN 2327-4662.

COCCHIA, A. Smart and digital city: A systematic literature review. In: _____. **Smart City: How to Create Public and Economic Value with High Technology in Urban Space**. Cham: Springer International Publishing, 2014. p. 13–43.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. [S.l.]: Wiley John + Sons, 2000.

ELKHODR, M.; SHAHRESTANI, S.; CHEUNG, H. The internet of things: New interoperability, management and security challenges. **International Journal of Network Security & Its Applications**, Academy and Industry Research Collaboration Center (AIRCC), v. 8, n. 2, p. 85–102, mar 2016.

FALUDI, R. **Building Wireless Sensor Networks: with ZigBee, XBee, Arduino, and Processing**. [S.l.]: O'Reilly Media, 2011. 322 p.

FERNANDES, M. Ávila. **O papel da tecnologia na evolução da manutenção industrial**. 2013. Disponível em: <<http://www.brasilengenharia.com/portal/noticias/noticias-da-engenharia/6981-o-papel-da-tecnologia-na-evolucao-da-manutencao-industrial>>. Acesso em: 08 ago. 2017.

FERREIRA, J. et al. Recommender system for drivers of electric vehicles. In: **ICECT 2011 - 2011 3rd International Conference on Electronics Computer Technology**. [S.l.: s.n.], 2011. v. 5, p. 244–248.

FERRETTO, L. R.; CERVI, C. R.; MARCHI, A. C. B. de. Recommender systems in mobile apps for health a systematic review. In: **2017 12th Iberian Conference on Information Systems and Technologies (CISTI)**. [S.l.: s.n.], 2017. p. 1–6.

FIELDING, R. T.; TAYLOR, R. N. Principled design of the modern web architecture. In: **Proceedings of the 2000 International Conference on Software Engineering, ICSE 2000 the New Millennium**. [S.l.: s.n.], 2000. p. 407–416.

FILHO, F. M. F.; GEUS, P. L.; ALBUQUERQUE, J. P. Sistemas de Recomendação e Interação na Web Social. **I Workshop de Aspectos da Interação Humano-Computador na Web Social**, p. 24–27, 2008.

FINEP. **Kevin Ashton – entrevista exclusiva com o criador do termo “Internet das Coisas”**. jan 2015. Disponível em: <<http://finep.gov.br/noticias/todas-noticias/4446-kevin-ashton-entrevista-exclusiva-com-o-criador-do-termo-internet-das-coisas>>. Acesso em: 09 abr. 2017.

FINKENZELLER, K. **RFID Handbook: Fundamentals and Applications in Contactless Smart Cards, Radio Frequency Identification and near-Field Communication**. [S.l.]: Wiley, 2010. ISSN 14337851.

FREEPIK. **Recursos gráficos gratuitos para designers**. 2017. Disponível em: <<http://br.freepik.com>>. Acesso em: 30 jul. 2017.

FRIKHA, M. et al. Using tmt ontology in trust based medical tourism recommender system. In: **2016 IEEE/ACS 13th International Conference of Computer Systems and Applications (AICCSA)**. [S.l.: s.n.], 2016. p. 1–8.

GARCIA, C. A.; FROZZA, R. Sistema de recomendação de produtos utilizando mineração de dados. **Tecno-lógica**, v. 1, n. 17, p. 78–90, 2013.

GAST, M. S. **802.11 Wireless Networks: The Definitive Guide, Second Edition**. [S.l.]: O’Reilly Media, Inc., 2005.

GOLDBERG, D. et al. Using collaborative filtering to weave an information tapestry. **Communications of the ACM**, Association for Computing Machinery (ACM), New York, NY, USA, v. 35, n. 12, p. 61–70, dec 1992.

GOMEZ, C.; PARADELLS, J. Wireless home automation networks: A survey of architectures and technologies. **IEEE Communications Magazine**, v. 48, n. 6, p. 92–101, June 2010.

GS1 BRASIL. **O que é o Código Eletrônico de Produto (EPC)?** 2017. Disponível em: <<https://www.gs1br.org/faq/o-que-e-epc>>. Acesso em: 17 nov. 2017.

HACHANI, A. et al. RFID based smart fridge. In: **2016 8th IFIP International Conference on New Technologies, Mobility and Security (NTMS)**. [S.l.]: Institute of Electrical and Electronics Engineers (IEEE), 2016.

HAMZA, M.; WALKER, R. J. Recommending features and feature relationships from requirements documents for software product lines. In: **2015 IEEE/ACM 4th International Workshop on Realizing Artificial Intelligence Synergies in Software Engineering**. [S.l.: s.n.], 2015. p. 25–31.

HUANG, A. S.; RUDOLPH, L. Bluetooth Essentials for Programmers. In: **Cambridge University Press**. [S.l.]: Cambridge University Press, 2007. p. 210.

HUSSAIN, M. I. Internet of things: challenges and research opportunities. **CSI Transactions on ICT**, Springer Nature, v. 5, n. 1, p. 87–95, dec 2016.

IEEE. **IEEE 802.15.4-2011**. IEEE, 2011. ISBN 0738166847. Disponível em: <<https://www.amazon.com/IEEE-802-15-4-2011/dp/0738166847?SubscriptionId=JYN1NVW651KCA56C102&tag=320&linkCode=3Dxm2&camp=3D2025&creative=3D1659>>. Acesso em: 09 abr. 2017.

IGOE, T.; COLEMAN, D.; JEPSON, B. **Beginning NFC: Near Field Communication with Arduino, Android, and PhoneGap**. first. [S.l.]: O’Reilly Media, Inc., 2014. 246 p.

JANNACH, D. et al. **Recommender Systems: An Introduction**. 1st. ed. New York, NY, USA: Cambridge University Press, 2010.

JANNACH, D. et al. Recommender systems — beyond matrix completion. **Commun. ACM**, ACM, New York, NY, USA, v. 59, n. 11, p. 94–102, out. 2016.

JONES, W. P.; FURNAS, G. W. Pictures of relevance: A geometric analysis of similarity measures. **Journal of the American Society for Information Science**, Wiley-Blackwell, New York, NY, USA, v. 38, n. 6, p. 420–442, nov 1987.

KARDACH, J. **Tech History: How Bluetooth got its name**. mar 2008. Disponível em: <http://www.eetimes.com/document-.asp?doc_id=1269737\page_number=1>. Acesso em: 09 nov. 2017.

KOREN, Y.; BELL, R.; VOLINSKY, C. Matrix factorization techniques for recommender systems. **Computer**, Institute of Electrical and Electronics Engineers (IEEE), Los Alamitos, CA, USA, v. 42, n. 8, p. 30–37, aug 2009.

KORESHOFF, T. L.; ROBERTSON, T.; LEONG, T. W. Internet of things: a review of literature and products. In: **Proceedings of the 25th Australian Computer-Human Interaction Conference on Augmentation, Application, Innovation, Collaboration - OzCHI '13**. New York, New York, USA: ACM Press, 2013. p. 335–344.

KRAWIEC, T. **The Amazon Recommendations Secret to Selling More Online**. 2016. Disponível em: <<http://rejoiner.com/resources/amazon-recommendations-secret-selling-online/>>. Acesso em: 21 jul. 2017.

KRULWICH, B. Lifestyle finder: Intelligent user profiling using large-scale demographic data. **AI magazine**, v. 18, n. 2, p. 37, 1997.

KUROSE, J. F.; ROSS, K. W. **Computer Networking: A Top-Down Approach**. [S.l.]: Pearson, 2012.

LABS, I. L. **Bluetooth Vs. Bluetooth Low Energy: What's The Difference?** nov 2015. Disponível em: <<https://www.link-labs.com/bluetooth-vs-bluetooth-low-energy/>>. Acesso em: 09 nov. 2017.

LEE, J. Smart factory systems. **Informatik-Spektrum**, Springer Nature, v. 38, n. 3, p. 230–235, may 2015.

LEINER, B. M. et al. **Brief History of the Internet**. 2012. Disponível em: <<http://www.internetsociety.org/internet/what-internet/history-internet/brief-history-internet>>. Acesso em: 09 nov. 2017.

LORENZI, F.; RICCI, F. Case-based recommender systems: A unifying view. In: _____. **Intelligent Techniques for Web Personalization: IJCAI 2003 Workshop, ITWP 2003, Acapulco, Mexico, August 11, 2003, Revised Selected Papers**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2005. p. 89–113.

LU, J. et al. Recommender system application developments: A survey. **Decision Support Systems**, v. 74, p. 12 – 32, 2015.

Lü, L. et al. Recommender systems. **Physics Reports**, Elsevier BV, v. 519, n. 1, p. 1–49, oct 2012.

MANNING, C. D.; RAGHAVAN, P.; SCHÜTZE, H. **Introduction to Information Retrieval**. New York, NY, USA: Cambridge University Press, 2008.

MASHAL, I.; CHUNG, T. Y.; ALSARYRAH, O. Toward service recommendation in internet of things. In: **2015 Seventh International Conference on Ubiquitous and Future Networks**. [S.l.: s.n.], 2015. p. 328–331. ISSN 2165-8528.

MATIAS-PEREIRA, J. **Manual de metodologia da pesquisa científica**. 3. ed.. ed. [S.l.]: Atlas, 2012.

MEOLA, A. **What is the Internet of Things ?** dec 2016. Disponível em: <<http://www.businessinsider.com/what-is-the-internet-of-things-definition-2016-8>>. Acesso em: 09 set. 2017.

MEYERS, J. **Watch The Incredible 70-Year Evolution Of The Cell Phone**. 2011. Disponível em: <<http://www.businessinsider.com/complete-visual-history-of-cell-phones-2011-5?op=1/\38-1>>. Acesso em: 20 jun. 2017.

MINIWATTS MARKETING GROUP. **World Internet Users Statistics and 2016 World Population Stats**. 2016. 3 p. Disponível em: <<http://www.internetworldstats.com/stats.htm>>. Acesso em: 09 nov. 2017.

MIRANDA, A. C. d. P. Filtragem colaborativa incremental para recomendações automáticas na web. Faculdade de Economia da Universidade do Porto, 2010.

MITCHELL, T. M. **Machine Learning**. 1. ed. [S.l.]: McGraw-Hill Education, 1997.

MONTUSCHI, P. et al. A semantic recommender system for adaptive learning. **IT Professional**, v. 17, n. 5, p. 50–58, Sept 2015.

MUSTAFA, N. et al. Collaborative filtering: Techniques and applications. In: **2017 International Conference on Communication, Control, Computing and Electronics Engineering (ICCCCEE)**. [S.l.]: IEEE, 2017. p. 1–6.

NATH, K.; DHAR, S.; BASISHTHA, S. Web 1.0 to web 3.0 - evolution of the web and its various challenges. In: **2014 International Conference on Reliability Optimization and Information Technology (ICROIT)**. [S.l.]: IEEE, 2014. p. 86–89.

NFC FORUM. **About the Technology**: Nfc and contactless technologies. jan 2016. 1–2 p. Disponível em: <<http://nfc-forum.org/what-is-nfc/about-the-technology/>>. Acesso em: 09 abr. 2017.

OLSSON, J. **6LoWPAN Overview**. 2014. Disponível em: <<http://www.ti.com/lit/wp/swry013/swry013.pdf>>. Acesso em: 16 abr. 2017.

PANNIELLO, U.; GORGOGLIONE, M. Incorporating context into recommender systems: an empirical comparison of context-based approaches. **Electronic Commerce Research**, v. 12, n. 1, p. 1–30, Mar 2012.

PAZZANI, M. J. A framework for collaborative, content-based and demographic filtering. **Artificial Intelligence Review**, v. 13, n. 5, p. 393–408, Dec 1999.

PERIYASAMY, M.; DHANASEKARAN, R. Evaluation of performance of uhf passive rfid system in metal and liquid environment. **2015 International Conference on Communication and Signal Processing, ICCSP 2015**, Institute of Electrical and Electronics Engineers (IEEE), p. 414–417, apr 2015.

QING, X.; CHEN, Z. N. Proximity effects of metallic environments on high frequency RFID reader antenna: Study and applications. **IEEE Transactions on Antennas and Propagation**, v. 55, n. 11 I, p. 3105–3111, 2007.

QUADROS, A. V.; SILVA, F. P. **Uma abordagem evolucionista do papel da tecnologia na agricultura**. 2011. Disponível em: <http://www.agrosecurity.com.br/anexos-uma_abordagem_evolucionista.pdf>. Acesso em: 08 ago. 2017.

RESNICK, P. et al. GroupLens: An open architecture for collaborative filtering of netnews. In: **Proceedings of the 1994 ACM conference on Computer supported cooperative work - CSCW '94**. New York, NY, USA: ACM Press, 1994. (CSCW '94), p. 175–186.

RICCI, F. et al. **Recommender Systems Handbook**. 1st. ed. New York, NY, USA: Springer-Verlag New York, Inc., 2010. ISBN 0387858199, 9780387858197.

RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. [S.l.]: PRENTICE HALL, 2009. ISBN 978-0-13-604259-4.

SALMAN, Y. et al. A proactive multi-type context-aware recommender system in the environment of internet of things. In: **2015 IEEE International Conference on Computer and Information Technology; Ubiquitous Computing and Communications; Dependable, Autonomic and Secure Computing; Pervasive Intelligence and Computing**. [S.l.: s.n.], 2015. p. 351–355.

SCHREIBER, G. et al. **Knowledge Engineering and Management**. [S.l.]: MIT Press Ltd, 1999.

SHARMA, R.; GOPALANI, D.; MEENA, Y. Collaborative filtering-based recommender system: Approaches and research challenges. In: **2017 3rd International Conference on Computational Intelligence Communication Technology (CICT)**. [S.l.: s.n.], 2017. p. 1–6.

SHWETA, A. Intelligent refrigerator using ARTIFICIAL INTELLIGENCE. In: **2017 11th International Conference on Intelligent Systems and Control (ISCO)**. [S.l.]: IEEE, 2017. p. 464–468. Acesso em: 09 abr. 2017.

SILVA, L. C. D. et al. State of the art of smart homes. **Engineering Applications of Artificial Intelligence**, Elsevier, v. 25, n. 7, p. 1313–1321, oct 2012. ISSN 0952-1976.

SMIRNOV, A. et al. Recommendation system for tourist attraction information service. In: **14th Conference of Open Innovation Association FRUCT**. [S.l.: s.n.], 2013. p. 148–155. ISSN 2305-7254.

STÄNDER, M. et al. A smart kitchen infrastructure. **Proceedings - 2012 IEEE International Symposium on Multimedia, ISM 2012**, Institute of Electrical and Electronics Engineers (IEEE), p. 96–99, dec 2012.

STOJKOSKA, R. et al. A review of Internet of Things for smart home: Challenges and solutions. **Journal of Cleaner Production**, Elsevier Ltd, v. 140, p. 1454–1464, jan 2017. ISSN 09596526.

SURESH, P. et al. A state of the art review on the Internet of Things (IoT) history, technology and fields of deployment. In: **2014 International Conference on Science Engineering and Management Research (ICSEMR)**. [S.l.]: Institute of Electrical and Electronics Engineers (IEEE), 2014. p. 1–8. Acesso em: 9 abr. 2017.

SYED, M. H.; FERNANDEZ, E. B.; ILYAS, M. A Pattern for Fog Computing. In: **Proceedings of the 10th Travelling Conference on Pattern Languages of Programs**. New York, NY, USA: ACM, 2016. (VikingPLoP '16), p. 1–10. ISBN 9781450342001.

THOMAS, A.; SUJATHA, A. K. Comparative study of recommender systems. In: **2016 International Conference on Circuit, Power and Computing Technologies (ICCPCT)**. [S.l.: s.n.], 2016. p. 1–6. ISBN 978-1-5090-1277-0.

VAQUERO, L. M.; RODERO-MERINO, L. Finding your way in the fog. **ACM SIGCOMM Computer Communication Review**, Association for Computing Machinery (ACM), v. 44, n. 5, p. 27–32, oct 2014.

WAI, L. Data science at udemy: Agile experimentation with algorithms. In: **2016 Future Technologies Conference (FTC)**. [S.l.: s.n.], 2016. p. 355–360.

WILSON, C.; HARGREAVES, T.; HAUXWELL-BALDWIN, R. Smart homes and their users: a systematic analysis and key

challenges. **Personal and Ubiquitous Computing**, Springer Nature, v. 19, n. 2, p. 463–476, sep 2015.

WOYKE, E. **The Smartphone: Anatomy of an Industry**. [S.l.]: The New Press, 2014.

YEUNG, K. F.; YANG, Y. A proactive personalized mobile news recommendation system. In: **Proceedings - 3rd International Conference on Developments in eSystems Engineering, DeSE 2010**. [S.l.: s.n.], 2010. p. 207–212.

Z-WAVE ALLIANCE. **About Z-Wave Technology**. 2015.

Disponível em:

<http://z-wavealliance.org/about_z-wave_technology/>. Acesso em: 16 abr. 2017.

ZANELLA, A. et al. Internet of things for smart cities. **IEEE Internet of Things Journal**, v. 1, n. 1, p. 22–32, Feb 2014.