

ALLAN DOUGLAS R. DE OLIVEIRA

LEONARDO NICACIO BESSA

THIAGO RODRIGUES ANDRADE

Dionisio:

Um sistema de recomendação baseado em confiança

São Paulo

2009

ALLAN DOUGLAS R. DE OLIVEIRA
LEONARDO NICACIO BESSA
THIAGO RODRIGUES ANDRADE

Dionisio:
Um sistema de recomendação baseado em confiança

Monografia apresentada à Escola
Politécnica da Universidade de São
Paulo para obtenção do título de
Engenheiro.

Área de Concentração:
Engenharia de Computação

São Paulo
2009

ALLAN DOUGLAS R. DE OLIVEIRA
LEONARDO NICACIO BESSA
THIAGO RODRIGUES ANDRADE

Dionisio:
Um sistema de recomendação baseado em confiança

Monografia apresentada à Escola
Politécnica da Universidade de São
Paulo para obtenção do título de
Engenheiro.

Área de Concentração:
Engenharia de Computação

Orientador: Prof. Dr. Jaime Simão
Sichman
Co-orientadora: Prof. Dra. Lucia
Filgueiras

São Paulo
2009

*Aos nossos pais, familiares e
companheiras, pelo apoio e incentivo
em nossa formação pessoal. Aos
mestres, pelo conhecimento
transmitido e pela paciência que
tiveram conosco.*

*"Innovation distinguishes between a
leader and a follower."*

Steven Paul Jobs
Co-fundador da Apple Inc.

Resumo

O comércio eletrônico brasileiro tem evoluído em termos de serviços prestados ao consumidor. Este trabalho apresenta a especificação e implementação de um sistema online de recomendação para facilitar o encontro do usuário com os produtos e serviços mais relevantes a ele. Para isso, são descritos em detalhes os requisitos funcionais e não funcionais do sistema, os algoritmos de recomendação utilizados e as escolhas na implementação do projeto. O sistema projetado é composto por três algoritmos de recomendação, sendo dois deles já difundidos, enquanto o terceiro é um novo, e que foi proposto para levar em consideração as relações de confiança do usuário com seus pares. A execução deste trabalho incluiu a realização de um experimento com pessoas interagindo com o sistema de recomendação através de uma rede social. A análise do experimento é apresentada através de gráficos e dados estatísticos que comparam os algoritmos utilizados. Os resultados do projeto podem ser aplicados no futuro no desenvolvimento de lojas virtuais online e/ou aplicativos de redes sociais.

Abstract

The Brazilian e-commerce has evolved in terms of services provided to the consumer. This paper presents the specification and implementation of an online recommendation system that eases the matching of a user with the most relevant products and services. Furthermore the functional and non-functional system requirements, the selected recommendation algorithms and the choices made in the implementation are described in detail. The designed system consists of three recommendation algorithms, two of them are already widely spreaded, while the third one is new and was proposed to consider the trust among users and their peers. This work also includes an experiment with people interacting with the recommendation system through a social network. The analysis of the experiment is presented through graphs and statistics that compare the algorithms. The results of the project can be applied in future development of virtual online stores and/or social networking applications.

Lista de Figuras

1.1	<i>RBP: Recomendação com base em similaridade entre perfis</i>	3
1.2	<i>RBI: Recomendação com base em similaridade entre produtos</i>	5
1.3	<i>RBC: Recomendação com base em confiança</i>	6
3.1	<i>Diagrama de blocos do sistema</i>	17
3.2	<i>Diagrama ilustrando o parâmetro de confiança na rede</i>	18
3.3	<i>Aspectos funcionais do sistema</i>	20
3.4	<i>Avaliação de produto via AJAX</i>	22
3.5	<i>Arquitetura em três camadas</i>	23
4.1	<i>Apresentação de produto para avaliação do participante</i>	26
4.2	<i>Interface de busca de produtos</i>	28
4.3	<i>Envio de recomendações de produtos</i>	29
5.1	<i>Nota média das avaliações realizadas comparadas com a nota média prevista pelos algoritmos</i>	34
5.2	<i>Erro médio absoluto (MAE) das recomendações</i>	35
5.3	<i>Notas por tipo de recomendação</i>	36
5.4	<i>Notas das recomendações diretas</i>	37
5.5	<i>Porcentagem das notas em cada faixa comparadas por tipo de recomendação</i>	38
5.6	<i>Taxa de serendipidade por tipo de recomendação</i>	39
5.7	<i>Taxa de serendipidade comparando amigos e desconhecidos</i>	40
5.8	<i>Resultado dos testes de hipótese</i>	42

Lista de Tabelas

4.1	<i>Número de participantes durante as etapas do experimento</i>	31
5.1	<i>Nota média das avaliações realizadas comparadas com a nota média prevista pelos algoritmos</i>	34
5.2	<i>Erro médio absoluto (MAE) das recomendações</i>	34
5.3	<i>Notas por tipo de recomendação</i>	35
5.4	<i>Notas das recomendações diretas</i>	36
5.5	<i>Porcentagem das notas em cada faixa comparadas por tipo de recomendação</i>	37
5.6	<i>Taxa de serendipidade por tipo de recomendação</i>	39
5.7	<i>Taxa de serendipidade comparando amigos e desconhecidos</i>	40
5.8	<i>Tempo de resposta das requisições ao banco de dados antes da otimização</i>	43
5.9	<i>Tempo de resposta das requisições ao banco de dados após a otimização .</i>	43
5.10	<i>Requisições bloqueantes</i>	44
A.1	<i>TH1: Amigos recomendam melhor do que Desconhecidos (H1)</i>	54
A.2	<i>TH2: Recomendações Diretas são melhores aceitas que RBC (H1)</i>	54
A.3	<i>TH3: RBC é melhor aceito que RBP (H1)</i>	54
A.4	<i>TH4: RBI é melhor que aceito que RBC (H1)</i>	54

Sumário

1	INTRODUÇÃO	1
1.1	Motivação	1
1.2	Objetivos	1
1.3	Metodologia	2
1.4	Organização	7
2	CONCEITOS BÁSICOS	8
2.1	Sistemas de Recomendação	8
2.1.1	Introdução	8
2.1.2	Contexto Histórico	8
2.1.3	Classificações dos Sistemas de Recomendação	9
2.1.4	Tipos de Filtragem Social	10
2.2	Web Social	13
2.2.1	O Que é Web Social	13
2.2.2	Qualidade da Informação	14
2.3	Necessidade de Sistemas de Recomendação	15
3	ESPECIFICAÇÃO DO PROJETO	16
3.1	Visão Geral do Sistema	16
3.2	Descrição do Sistema	16
3.3	Funcionalidades Principais	19
3.4	Requisitos Não-Funcionais	21
3.5	Implementação	21
4	ESPECIFICAÇÃO DO EXPERIMENTO	24
4.1	Descrição do Experimento	24
4.1.1	Primeira Etapa	25
4.1.2	Segunda Etapa	26
4.1.3	Terceira Etapa	27
4.1.4	Quarta Etapa	29
4.1.5	Quinta Etapa	30
4.1.6	Sexta Etapa	31
5	ANÁLISES E RESULTADOS	32
5.1	Introdução	32

5.2	Análise Comparativa dos Algoritmos de Recomendação	33
5.3	Análise de Rejeição das Recomendações	36
5.4	Taxa de Serendipidade	39
5.5	Análise do Algoritmo Baseado em Confiança	40
5.6	Testes de Hipótese	41
5.7	Análise de Desempenho	43
6	CONSIDERAÇÕES FINAIS	45
6.1	Conclusão	45
6.2	Trabalhos Futuros	46
6.2.1	Web Semântica	46
6.2.2	Confiança Dependente do Tempo	48
6.2.3	Feedback das Recomendações	48
6.2.4	Estudo dos Testes de Sensibilidade	49
	Referências Bibliográficas	51
	Apêndice	53
A	Resultados dos Testes de Hipótese	53
B	Termo de Consentimento Livre e Esclarecido (TCLE)	55
C	Instruções Fornecidas aos Participantes	59

Capítulo 1

INTRODUÇÃO

1.1 Motivação

Sistemas de Recomendação sugerem itens que as pessoas possam gostar, baseado em seu comportamento prévio. Fazendo suposições pertinentes sobre o tipo de objetos em que elas estão interessadas, é possível conquistar a sua confiança. A vantagem para os usuários é a facilidade de encontrar a informação sem ter a árdua tarefa de procurá-la.

As redes sociais online têm modificado a forma com que as empresas utilizam a comunicação para o comércio. Pessoas estão utilizando a Web para encontrar outras pessoas com interesses similares, fazer compras de forma mais eficiente, aprender sobre produtos e serviços e reclamar sobre produtos malfeitos [1].

A Web está rapidamente se tornando a mídia mais importante para o marketing. A tendência é que as pessoas cada vez mais bloqueiem os anúncios indesejados e queiram ter a capacidade de encontrar os produtos relevantes no momento adequado. É nesse contexto que surge a necessidade de uma plataforma que facilite a colaboração e que permita a criação e classificação de conteúdo pelos consumidores, de forma a permitir uma escolha mais inteligente dos melhores produtos e serviços, e ao mesmo tempo criando um mecanismo de feedback para as empresas interessadas.

Devido à grande variedade atual de produtos e serviços, as pessoas têm cada vez mais dificuldade nas suas escolhas e na argumentação sobre a possível decisão. Quanto maior for a quantidade de produtos similares de fabricantes diferentes, mais as pessoas se vêem desorientadas e sem saber se a decisão tomada foi a mais correta.

1.2 Objetivos

O principal objetivo deste projeto é criar um sistema de recomendação baseado em recursos disponíveis na Web, que possibilite a sugestão de itens confiáveis e relevantes ao usuário.

Este sistema utiliza três algoritmos de recomendação distintos: um baseado em perfis de usuários (RBP), outro baseado em similaridade entre produtos/itens (RBI) e um outro, proposto neste trabalho, que é baseado em uma função de confiança entre usuários (RBC).

Este último algoritmo utiliza informações fornecidas pelos próprios usuários, através do uso de uma rede social acoplada ao sistema, para calcular estes índices de confiança.

1.3 Metodologia

Inicialmente foi realizada uma pesquisa bibliográfica com os assuntos relacionados ao trabalho, como sistemas de recomendação (*recommender systems*), redes sociais (*social networks*), tomada de decisão (*common sense*), Web semântica (*semantic Web*), entre outros. Após isso, esta pesquisa bibliográfica foi detalhada sobre os assuntos que fariam parte do escopo do projeto, como sistemas de recomendação e redes sociais.

Algumas práticas das metodologias de desenvolvimento ágil foram adotadas neste projeto, como o Desenvolvimento Dirigido por Testes (TDD¹). Nesta prática, sempre que uma nova funcionalidade for adicionada ao sistema, o desenvolvedor deve iniciar o processo testando a mesma. Após executar o teste, em caso de falha o desenvolvedor deve verificar porque o teste falhou e então adicionar o código necessário para corrigi-la. Em uma etapa posterior, o desenvolvedor deve adicionar mais testes para a nova funcionalidade até que ela possa ser considerada pronta.

Outro processo de desenvolvimento de software utilizado no projeto foi a refatoração de código [2]. A refatoração de código consiste na mudança da estrutura interna do programa sem afetar o seu comportamento externo. Dessa forma, é possível aprimorar o código fonte existente melhorando a sua legibilidade, aplicando simplificações na estrutura, adequando a paradigmas de programação, melhorando a performance e a extensibilidade.

Foi realizado um experimento prático com a participação de pessoas externas ao projeto para o colhimento de resultados da utilização do sistema proposto.

Para a formação da base de dados que comporia o cadastro de produtos utilizado no experimento foram escolhidos os seguintes aspectos:

- Diversidade de produtos

Foram consideradas diversas categorias de produtos para que houvesse uma heterogeneidade no cadastro.

- Produtos com alto índice de relevância nas categorias

Os produtos mais relevantes em cada categoria foram cadastrados com o intuito da base de dados não ser composta apenas de produtos desconhecidos aos participantes do experimento.

¹ Do inglês *Test Driven Development*.

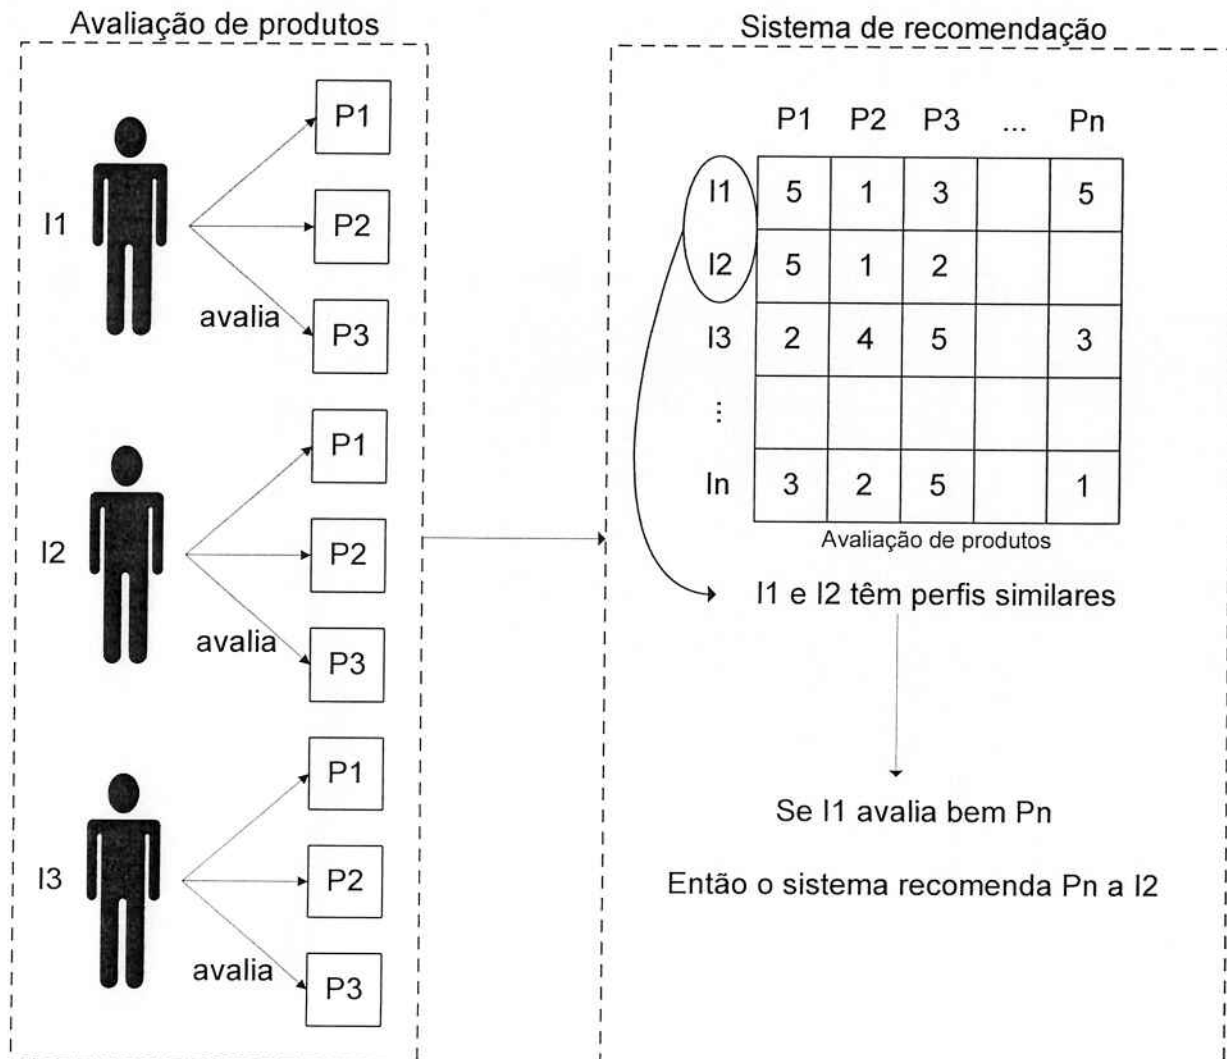


Figura 1.1: RBP: Recomendação com base em similaridade entre perfis

O experimento realizado foi dividido em etapas, sendo que enquanto uma etapa não era concluída por todos os participantes, as etapas subseqüentes não eram iniciadas. Com isso, o desenvolvimento das funcionalidades disponíveis pelo sistema foi gradual, proporcionando a correção de erros nas etapas a serem ainda liberadas.

Além disso, enquanto o experimento estava no ar, os participantes que já haviam terminado determinada etapa comunicavam espontaneamente por e-mail as dificuldades ou facilidades que tiveram durante a realização da mesma. Isso facilitava a correção imediata de erros com o sistema no ar e a mitigação dos mesmos na etapas seguintes.

O sistema de recomendação implementado utiliza 3 tipos de algoritmos para realizar as recomendações aos usuários.

A recomendação com base na similaridade entre perfis de usuários (RBP) utiliza a correlação de Pearson para calcular a semelhança entre os usuários. Como visto na Figura 1.1 inicialmente os usuários avaliam alguns produtos em comum. Comparando os usuários um-a-um com base nas notas que eles deram aos produtos, calcula-se a correlação de Pearson que resultará em alto grau de similaridade caso os dois usuários tenham avaliado produtos de forma semelhante. Desse modo, se dois usuários têm perfis similares e um deles avalia bem um produto P_n então o sistema recomenda este produto ao outro usuário.

A recomendação com base em similaridade entre produtos/itens (RBI) calcula a semelhança entre produtos para realizar as recomendações. Como mostrado na Figura 1.2 inicialmente os usuários avaliam alguns produtos em comum. O sistema de recomendação utiliza essas informações de avaliação de produtos para calcular uma-a-uma a correlação entre os produtos, calculando a sua distância Euclidiana. Caso dois produtos $P1$ e $P2$, tenham alto índice de correlação e um usuário avalia bem $P1$, então o sistema também recomenda $P2$ a ele.

Os dois algoritmos introduzidos anteriormente são conhecidos na comunidade científica e muito utilizados entre os sistemas de recomendação atuais. O algoritmo proposto pelo grupo é a recomendação com base em confiança (RBC). Neste caso, inicialmente um usuário avalia alguns produtos e depois recomenda um deles a outras pessoas. Depois dessas pessoas terem avaliado o produto recomendado, o sistema de recomendação calcula o índice de confiança entre o usuário recomendador e o usuário que recebeu a recomendação. Quanto melhor o produto recomendado for avaliado, maior será o índice de confiança que este usuário tem naquele que fez a recomendação. Caso o índice de confiança seja alto, o sistema recomenda produtos bem avaliados pelo usuário recomendador ao usuário recomendado. O RBC é ilustrado na Figura 1.3.

Após o desenvolvimento e implementação dos algoritmos, o sistema foi testado por uma coleção de 60 pessoas, agrupadas em 12 classes, sendo que cada classe indica um grupo de amigos, isto é, pessoas que confiam umas nas outras. Os resultados dos diferentes algoritmos de recomendação foram então comparados através de testes estatísticos.

O controle de versão do código fonte criado foi feito com o SVN². Esse sistema de controle ajudou muito no desenvolvimento paralelo do sistema do projeto por todos os integrantes do grupo. Os arquivos utilizados durante todo o desenvolvimento do projeto também foram versionados com o SVN.

² Do inglês *Subversion*. SVN é um sistema de controle de versão de documentos quaisquer.




Figura 1.2: *RBI: Recomendação com base em similaridade entre produtos*

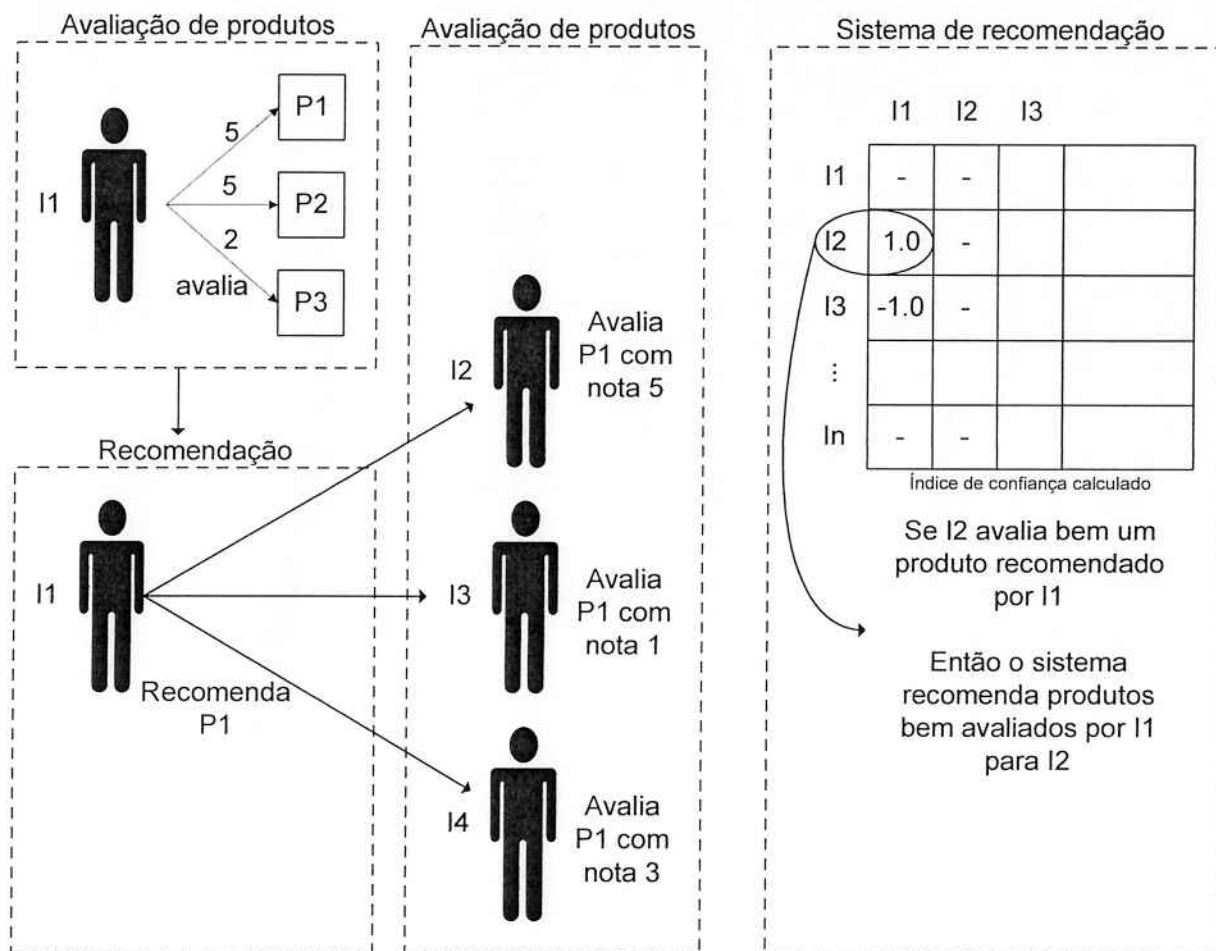


Figura 1.3: RBC: Recomendação com base em confiança

1.4 Organização

Este trabalho está estruturado em 6 capítulos e 3 apêndices.

O capítulo 1 consiste nesta introdução onde são apresentados a motivação da realização deste projeto, os objetivos a serem alcançados com o trabalho e a metodologia utilizada no projeto. Já o capítulo 2 descreve os conceitos básicos empregados e utilizados durante a realização do projeto. No capítulo 3, especifica-se o projeto mostrando a sua visão geral, descrição, funcionalidades e os detalhes técnicos da sua implementação. O capítulo 4 apresenta a especificação do experimento realizado durante o projeto para colhimento de dados. No capítulo 5 são mostradas as análises e os resultados obtidos do sistema com a realização do experimento. O capítulo 6 contém as considerações finais deste trabalho, sendo composto da conclusão e das propostas de trabalhos futuros.

No apêndice A são mostrados os resultados dos testes de hipótese realizados sobre a amostra obtida com o experimento. O apêndice B contém o Termo de Consentimento Livre e Esclarecido (TCLE) utilizado no experimento. Já o apêndice C descreve as instruções apresentadas aos participantes do experimento para a realização das tarefas de cada etapa.

Capítulo 2

CONCEITOS BÁSICOS

2.1 Sistemas de Recomendação

2.1.1 Introdução

Sistemas de recomendação ¹ são aqueles que sugerem itens ao seus usuários de forma a ajudá-los a encontrar mais efetivamente os itens de maior interesse dentre uma variedade imensa de opções.

A idéia de recomendar itens é algo que pode ser observado no dia-a-dia das pessoas. Como muitas escolhas precisam ser feitas sem que se tenha uma experiência pessoal das alternativas, as pessoas se baseiam no que as outras dizem sobre um determinado produto antes de comprá-lo ou experimentá-lo. Estas informações são transmitidas boca-a-boca entre amigos e colegas ou através de resenhas especializadas que podem ser encontradas em revistas e jornais.

Os sistemas de recomendação auxiliam este processo social, agregando opiniões e avaliações de uma comunidade de usuários sobre os produtos e recomendando itens de acordo com o perfil do usuário desta comunidade.

2.1.2 Contexto Histórico

O primeiro sistema de recomendação, Tapestry[3], foi desenvolvido no início dos anos 90. Na última década, tais sistemas foram um grande foco de estudo, principalmente os baseado em filtragem colaborativa [4] [5].

Observa-se hoje que vários sistemas de recomendação podem ser experimentados pelo usuários da Internet, como exemplo:

- A Amazon ² e o Submarino ³, lojas virtuais de artigos diversos, recomendam itens semelhantes para aqueles usuários que comprem um produto ou manifestam interesse em comprá-lo.

¹ Em inglês, *Recommender systems*.

² <http://www.amazon.com>.

³ <http://www.submarino.com.br>.

- O Last.fm ⁴, uma rede social focada em música, recomenda artistas e canções semelhantes às aquelas que os usuários mais gostam de ouvir.
- O Digg ⁵ e o Delicious ⁶, sistemas de compartilhamento de links ⁷, geram uma lista geral de links recomendados baseados nas opiniões dos usuários do sistema.
- O StumbleUpon ⁸, também um sistema online de compartilhamento de links, permite que os usuários recebam recomendações de links e avaliem se eles gostaram ou não daquele link, gerando recomendações personalizadas baseadas nessa avaliação.

2.1.3 Classificações dos Sistemas de Recomendação

Nas próximas seções serão apresentadas as diferentes abordagens existentes para a implementação de sistemas de recomendação. As primeiras abordagens foram a filtragem colaborativa e a filtragem baseada em conteúdo. Vários sistemas são híbridos, isto é, utilizam mais de uma abordagem.

Filtragem Baseada em Conteúdo

A filtragem baseada em conteúdo consiste na extração de características dos itens a serem recomendados e da comparação dessas características (*features*) com aquelas que formam o perfil histórico do usuário. Esse é um dos primeiros métodos que surgiram e sua origem está na comunidade de recuperação de informações (*information retrieval* [6]).

Como exemplo, suponha-se que se queira recomendar documentos em formato texto. As características nesse caso poderiam ser as palavras do texto. O perfil histórico do usuário seria formado pela frequência acumulada das palavras presentes em cada texto avaliado pelo usuário. Um documento neste caso é recomendado se as características (palavras) presentes podem ser encontradas em grande frequência nos documentos avaliados positivamente pelo usuário no passado.

Outros exemplos de características que podem ser usadas em um documento são meta-informações como autor, categoria do documento (artigo, jornal, revista, por exemplo), assunto (computação, matemática, artes, esportes), entre outras palavras-chave.

⁴ <http://last.fm>.

⁵ <http://digg.com>.

⁶ <http://del.icio.us>.

⁷ Também conhecidos como bookmarks.

⁸ <http://stumbleupon.com>.

Filtragem Social

A filtragem social⁹ consiste em um conjunto de técnicas que utilizam o contexto e as relações sociais de uma comunidade de usuários para fazer recomendações. Ao contrário da filtragem baseada em conteúdo, o conteúdo de cada item não é analisado, possibilitando-se recomendar qualquer tipo de item.

2.1.4 Tipos de Filtragem Social

As próximas seções descrevem diferentes abordagem baseadas na filtragem social.

Filtragem Colaborativa

O termo *collaborative filtering* foi cunhado por [3]¹⁰. A abordagem básica consiste em montar um sistema que permite os usuários fazerem avaliações¹¹ dos itens que podem ser recomendados, resultando em triplas (usuário, item, avaliação). A partir dessas avaliações, pode-se criar uma lista de recomendação para um determinado usuário.

Este é o algoritmo básico que nesta monografia será denominado RBP.

Na descrição a seguir, o usuário a quem se deseja recomendar algo será chamado usuário ativo. A avaliação de um item feita por um usuário será chamada de voto. Os passos são os seguintes:

1. Para cada usuário do sistema, determina-se a similaridade entre este usuário e o usuário ativo, conforme mostra a equação 2.4. Este valor será designado por s .
2. Para cada item do sistema não avaliado pelo usuário ativo, calcula-se o voto previsto p para aquele item, utilizando-se o voto de cada usuário que avaliou o item e a similaridade s entre este usuário e o usuário ativo. O voto previsto é uma estimativa da avaliação que aquele usuário faria do item caso já o conhecesse.

A lista de itens recomendados será formada pelos n itens com os maiores votos previstos em ordem decrescente.

Descrição matemática. Mais detalhadamente, o algoritmo básico é o seguinte:

Sendo $v_{i,j}$ o voto do usuário i para o item j , I_i o conjunto de itens que foram avaliados pelo usuário i , define-se voto médio de um usuário i por:

⁹ Termo originado em Malone et al[7] segundo Hill et al[8].

¹⁰ Conforme Resnick et al[4].

¹¹ Em inglês, *ratings* ou *votes*.

$$\bar{v}_i = \frac{1}{|I_i|} \sum_{j \in I_i} v_{i,j} \quad (2.1)$$

O valor previsto do voto do usuário ativo a para o item j , será dado por:

$$p_{a,j} = \bar{v}_a + k \sum_{i=1}^n s(a,i)(v_{i,j} - \bar{v}_i) \quad (2.2)$$

onde n é o número de usuários do sistema, $s(a,i)$ é a similaridade entre o usuário a e o usuário i e k é um fator de normalização, dado neste caso por:

$$k = \sum_{i=1}^n \frac{1}{s(a,i)} \quad (2.3)$$

Cálculo de s . O cálculo de s geralmente é realizado utilizando-se o coeficiente de correlação de Pearson [9], definido por:

$$s(a,i) = \frac{\sum_j (v_{a,j} - \bar{v}_a)(v_{i,j} - \bar{v}_i)}{\sqrt{\sum_j (v_{a,j} - \bar{v}_a)^2 \sum_j (v_{i,j} - \bar{v}_i)^2}} \quad (2.4)$$

Forma geral da Filtragem Colaborativa. Apesar das primeiras abordagens terem utilizado a similaridade s , qualquer peso w ¹² pode ser usado na equação 2.2. Pode-se então reescrevê-la da seguinte maneira geral:

$$p_{a,j} = \bar{v}_a + k \sum_{i=1}^n w(a,i)(v_{i,j} - \bar{v}_i) \quad (2.5)$$

Para mais detalhes, ver [9].

Filtragem Baseada em Confiança Explícita

A filtragem baseada em confiança explícita¹³ é muito similar à filtragem colaborativa, mas utiliza como peso $w(a,i)$ a confiança do usuário a no usuário i .

Esta confiança é fornecida de forma explícita pelo usuário. Este método se mostrou muito efetivo no casos em que a maioria dos usuários do sistema são *cold-users*, isto é, quando a maioria dos usuários avaliou poucos itens e portanto possuem poucos itens em comum. Em um cenário como esse, a filtragem colaborativa tradicional falha em encontrar usuários semelhantes pois há pouca intersecção de avaliações de itens¹⁴.

¹² Do inglês *weight*

¹³ Entendida aqui no contexto de *Trust-aware recommender systems* [10]

¹⁴ Em inglês, *rating-overlap*.

Filtragem por Similaridade de Item

Esta é uma técnica que também pertence à filtragem social e possui a mesma base da filtragem colaborativa por montar um sistema em que os usuários podem fazer as avaliações de diferentes itens.

A principal diferença é que a filtragem por similaridade de item analisa essas avaliações e monta um modelo da semelhança entre os itens. A este tipo de filtragem é dado o nome de *Model-based Collaborative Filtering*, em oposição ao *Memory-based Collaborative Filtering*, que é a técnica tradicional usada na filtragem colaborativa [11].

Nesta monografia este algoritmo será chamado de RBI.

O algoritmo é dividido em duas partes:

1. Cálculo da similaridade entre itens

Neste passo, é calculada a correlação entre as avaliações efetuadas pelos usuários para cada par de itens, usando, por exemplo, o coeficiente de correlação de Pearson (ver equação 2.4).

Para um sistema com n itens, o resultado é uma matriz $n \times n$ contendo a correlação entre um item e outro. Este é o “modelo” que diferencia esta abordagem daquela da filtragem colaborativa.

2. Cálculo do valor previsto do voto do usuário

O próximo passo é determinar o voto previsto $p_{a,i}$, que é o valor da avaliação prevista do produto i pelo usuário a .

Para cada item i utiliza-se a similaridade s para os N produtos j mais similares a este, onde $v(a, j)$ é a avaliação do usuário a para o produto j . A expressão de p é dada por:

$$p_{a,i} = \frac{\sum_{j=0}^N (s_{i,j} \times v_{a,j})}{\sum_{j=0}^N (|s_{i,j}|)} \quad (2.6)$$

Sistemas de Recomendação Baseados em Reputação

De acordo com [12], a reputação tem grande importância em relações sociais e comerciais e é composta por diversos elementos que resultam na visão geral de uma entidade. Por exemplo, a reputação de uma companhia aérea é composta da reputação de seus aviões, assim como a reputação do seu serviço de bordo, entre outras. O REGRET¹⁵ [12]

¹⁵ Do inglês *Reputation Model for Gregarious Societies*

é um modelo de reputação que se utiliza de impressões que um agente tem de uma entidade. Nesta impressão, define-se o peso W_i que é utilizado para calcular a reputação da entidade como sendo a somatória desses pesos multiplicada por uma função dependente do tempo para normalização.

Este modelo de reputação foi uma das inspirações para a elaboração do algoritmo baseado em confiança (RBC) que está sendo proposto nesta monografia. Ele funciona como o sistema de recomendação baseado em confiança explícita introduzido na seção 2.1.4, mas tendo o seu parâmetro de confiança calculado automaticamente com base nas avaliações das recomendações feitas pelos usuários, seguindo um modelo muito parecido ao de sistemas baseado em reputação.

Este algoritmo será denominado RBC nesta monografia e o seu detalhamento será feito na seção 3.2.

2.2 Web Social

2.2.1 O Que é Web Social

O conceito de Web Social está relacionado diretamente com o termo Web 2.0, criado em 2004 pela empresa O'Reilly Medial, o que designa o uso da Internet como plataforma para novos tipos de comunidades e serviços. Antes do advento da Web 2.0, o fluxo de informação era praticamente unidirecional, sendo que os dados eram disponibilizados pelo proprietário do site da Internet e apenas visualizado pelas pessoas que o freqüentavam. A troca de informações era muito baixa, dado que as pessoas não podiam comentar sobre o conteúdo a elas exposto, dando a sua opinião positiva ou negativa.

Com o surgimento da Web 2.0, a contribuição das pessoas tornou-se fundamental para a disponibilidade do conteúdo presente na Internet. O fluxo de informações vem se tornando bidirecional, ou seja, as pessoas visualizam um conteúdo presente em um site e podem comentar, alterar ou até mesmo adicionar novos dados.

Neste cenário, as pessoas se cadastram no site e criam perfis com as suas informações pessoais. Há também a possibilidade da criação de comunidades, com grande importância, pois o objetivo das pessoas que se cadastram em um site desse tipo é a de encontrar outras, amigas ou não, com os mesmos interesses. Isso facilita o seu engajamento e a criação de um conteúdo mais elaborado, já conhecido por todos no contexto da comunidade. As redes sociais se caracterizam por oferecer as funcionalidades de cadastro de perfis com informações pessoais, criação de comunidades para discussão de assuntos diversos e criação de vínculos de amizade entre os usuários.

2.2.2 Qualidade da Informação

Para a formação e atualização do seu conteúdo, as redes sociais precisam das informações vindas dos seus usuários. Quanto mais as pessoas contribuem, mais rica será a rede social [13]. A dependência dos usuários traz a necessidade de mostrar a eles o valor de suas contribuições. Uma rede social deve motivar os seus usuários a participarem ativamente com as suas opiniões ou fornecendo novas informações, mesmo sem receber em troca algum tipo de recompensa além da exposição das suas idéias. O desafio é mostrar aos novos usuários que ainda não exporam suficientemente as suas informações na rede, chamados de *coldstart users*, o motivo para eles contribuírem com o fluxo de informações.

Durante a formação de uma rede social, o princípio básico adotado é sempre o cadastro inicial de algumas pessoas influentes, para que estas depois possam enviar convites para seus amigos e conhecidos. Também há a opção de convidar amigos presentes em outras redes, o que torna mais fácil o processo de localização de pessoas conhecidas. Após isso, existem técnicas adotadas para motivar os usuários a contribuírem com dados. Segundo [13], uma das técnicas adotadas é mostrar aos usuários o que seus amigos estão fazendo na rede. Essa técnica tem como base o comportamento humano de primeiro observar para depois agir ao chegar em um novo local com pessoas já interagindo entre si. Sabendo o comportamento dos seus amigos, os novos usuários agirão de maneira semelhante [13].

Ainda em [13] há um estudo específico relacionado às ações de novos usuários em uma grande rede social, o FaceBook¹⁶. Foram utilizados dados de cerca de 140.000 novos usuários cadastrados na rede. Suas ações foram monitoradas por duas semanas e os resultados permitiram aos pesquisadores concluir que o nível de contribuição dos novos usuários depende principalmente do conteúdo compartilhado pelos seus amigos. Ao perceber que seus amigos estão expondo suas fotos, depoimentos e outras informações, o usuário tende a fazer o mesmo e contribuir mais na rede deixando de ser um *coldstart user*.

Mesmo fazendo com que as pessoas compartilhem informações, a qualidade destas ainda depende do propósito da rede. Algumas redes sociais visam apenas diversão, como o Orkut¹⁷ e o MySpace¹⁸, porém existem redes sociais voltadas para a criação de perfis profissionais, sendo o LinkedIn¹⁹ um exemplo conhecido. As informações contidas no Orkut e no MySpace não são necessariamente de alta confiabilidade, uma vez que muitas

¹⁶ www.facebook.com

¹⁷ www.orkut.com

¹⁸ www.myspace.com

¹⁹ www.linkedin.com

peessoas não utilizam sua identificação real. Já no LinkedIn, a maioria das pessoas entram com suas informações reais, pois o intuito da rede é criar e manter laços profissionais sendo a qualidade desses dados muito mais relevante.

2.3 Necessidade de Sistemas de Recomendação

A popularização de sites que dão oportunidade às pessoas de contribuírem com suas informações, tais como *weblogs*, *fotologs* e outros meios de compartilhamento de conteúdo digital, fez com que rapidamente a quantidade de conteúdo pessoal na Internet tivesse um crescimento considerado [14]. Com isso, encontrar algo relevante e pessoas que partilhassem os mesmos interesses tornou-se uma tarefa muito mais complicada. Os sistemas de recomendação são projetados para aliviar essa dificuldade. Porém, de acordo com [14], sistemas de recomendação baseados em um contexto social apresentam recomendações mais eficientes.

Um sistema de recomendação inserido em um contexto social pode se basear na similaridade de itens e pessoas, assim como foi abordado na seção 2.1. Em [14], um experimento foi realizado com 60 participantes que avaliaram recomendações de filmes feitas em uma rede social. As pessoas avaliavam recomendações feitas por conhecidos e desconhecidos para que se pudesse verificar qual dos parâmetros dentre a similaridade de perfis e familiaridade seria mais influente em uma recomendação. Os resultados mostraram que os participantes claramente preferiram as recomendações realizadas por pessoas que eles conheciam.

Capítulo 3

ESPECIFICAÇÃO DO PROJETO

O projeto consiste no desenvolvimento de um sistema de recomendação acoplado a uma rede social. As recomendações realizadas pelo sistema serão baseadas em similaridade de itens, em similaridade de perfis e na confiança implícita entre os usuários.

3.1 Visão Geral do Sistema

O sistema de recomendação utilizará a rede social para obter as relações de amizade entre usuários. Esta relação é estabelecida entre dois usuários após ambos a confirmarem através do envio de um convite de amizade e da aceitação deste.

Os usuários podem avaliar produtos (previamente cadastrados na base de dados) e receber recomendações de outras pessoas presentes na rede social. Tendo como base o comportamento dos usuários nestas atividades, o sistema será capaz de enviar novas recomendações de produtos relevantes ao usuário.

Os principais blocos do sistema podem ser vistos na Figura 3.1. A rede social é utilizada para o estabelecimento das relações de amizade, para a criação e visualização de avaliações dos produtos e para o envio de recomendações. O repositório é utilizado para armazenar os produtos cadastrados e as recomendações a serem enviadas. Já o sistema de recomendação tem o papel de analisar as informações contidas no repositório e gerar novas recomendações.

3.2 Descrição do Sistema

Através do sistema os usuários poderão indicar o interesse em produtos e realizar recomendações a outros usuários. Quando um usuário avaliar um produto recomendado por outro, o índice de confiança deste em relação ao outro é atualizado no sistema. Com base nas recomendações e nas avaliações o sistema irá inferir as seguintes informações:

- Similaridade entre perfis de usuários
- Similaridade entre produtos
- Grau de confiança entre usuários
- Recomendações de produtos mais relevantes para um determinado usuário

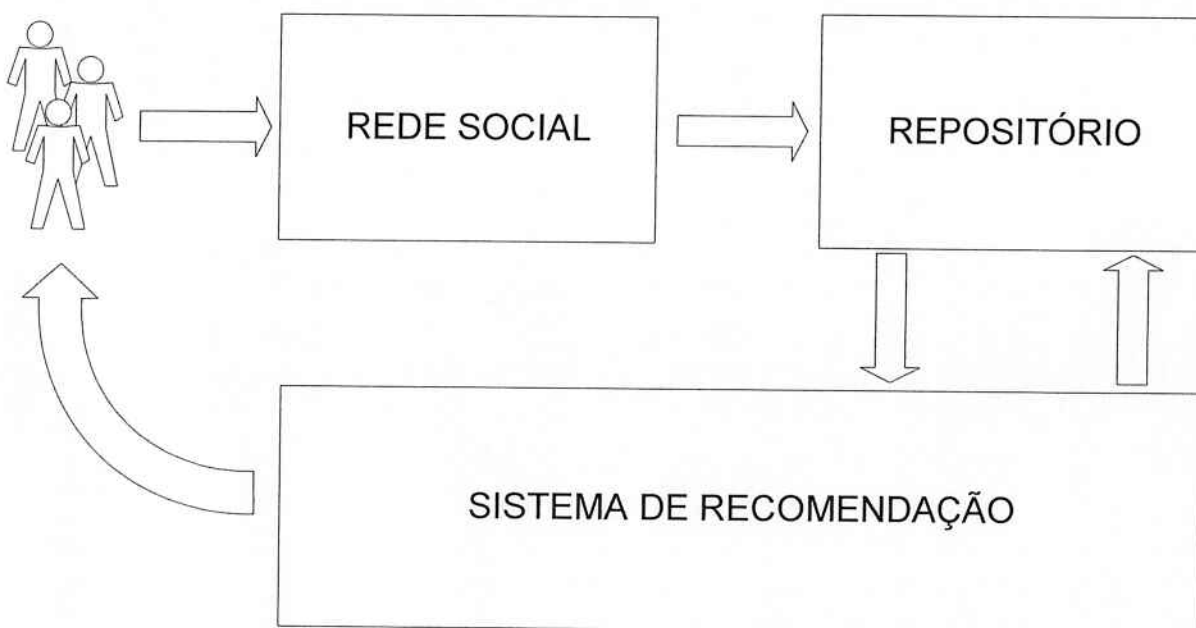


Figura 3.1: Diagrama de blocos do sistema

As recomendações geradas pelo sistema são baseadas nas avaliações de produtos feitas pelos usuários. A partir destas avaliações, o sistema calcula a similaridade entre usuários, as relações de confiança e as relações encontradas entre os produtos.

O usuário do sistema tem a opção de buscar os produtos já cadastrados através de uma ferramenta de busca incorporada à rede social. Além disso, os usuários podem recomendar os produtos para outros usuários presentes na rede. Os usuários são informados que devem sempre realizar boas recomendações. Uma boa recomendação é a indicação de um produto que o outro usuário provavelmente terá o máximo interesse.

Ao receber uma recomendação o usuário tem a opção de avaliar o produto e então o sistema atualiza as informações relativas aos seus interesses. As avaliações de produtos são feitas em uma escala de 1 a 5, onde 1 representa que o usuário não tem nenhum interesse no produto e 5 significa que o usuário tem muito interesse no produto. Estas informações são utilizadas para verificar a similaridade entre usuários, a similaridade entre itens e o índice de confiança.

Quando um usuário avalia um produto recomendado por outro, essa avaliação altera o grau de confiança do usuário que recomendou o produto em relação àquele que recebeu a recomendação. Caso a avaliação seja positiva, a confiança do receptor aumenta, porém, caso a avaliação seja negativa, significa que o usuário que recebeu a recomendação não a aceitou como relevante, diminuindo o grau de confiança.

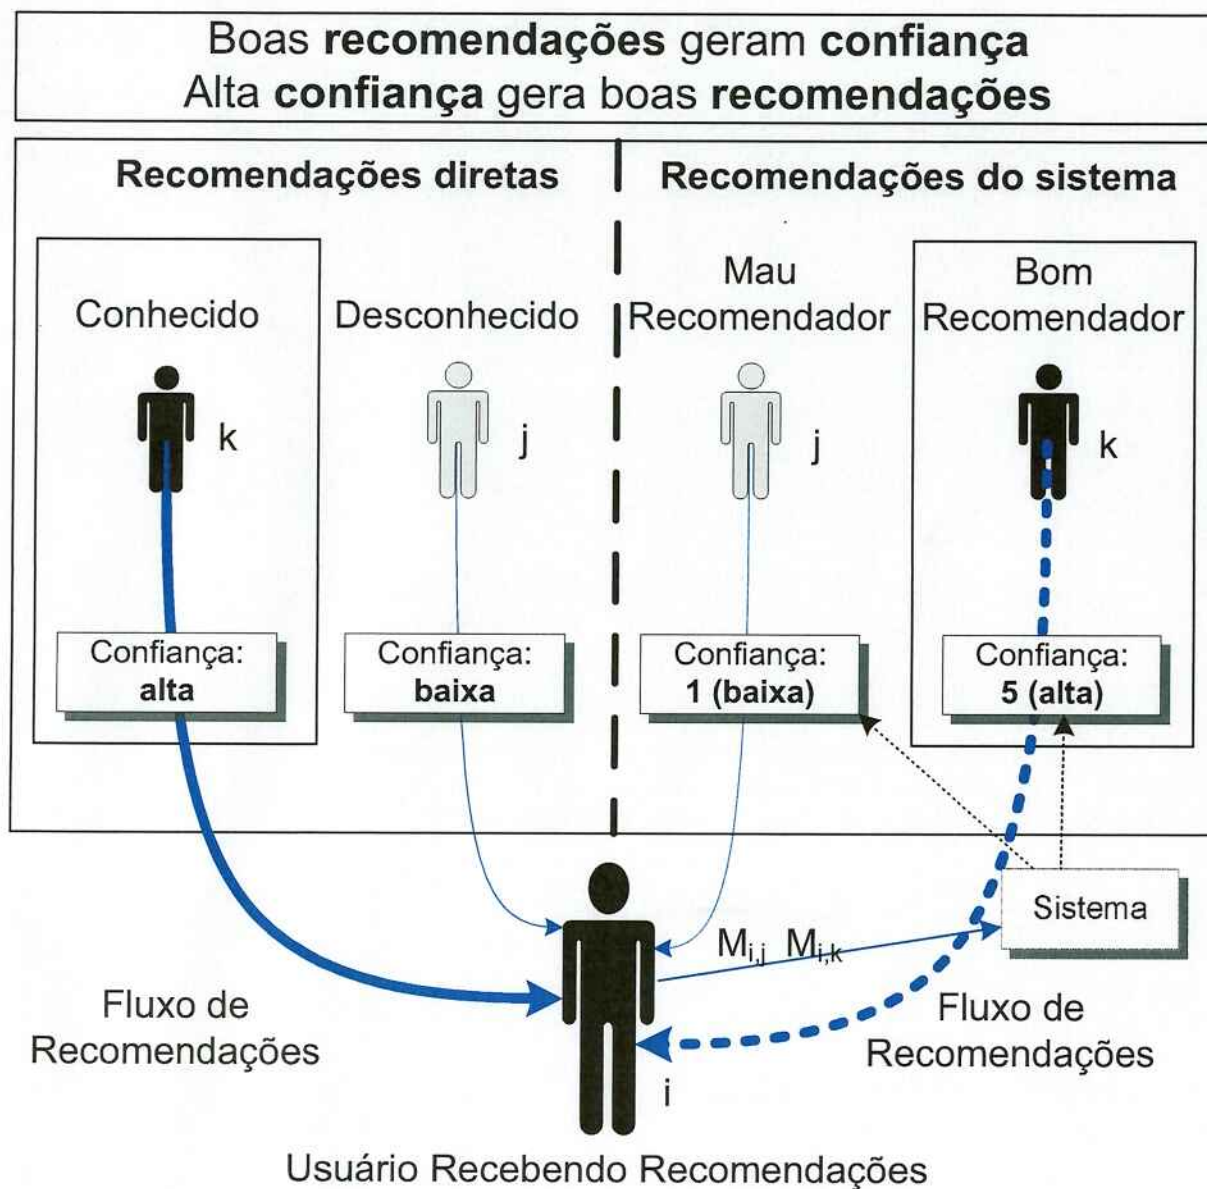


Figura 3.2: Diagrama ilustrando o parâmetro de confiança na rede

O parâmetro de confiança $C_{i,j}$, que representa a confiança que o usuário i tem no usuário j , é calculado de acordo com a Equação 3.1:

$$C_{i,j} = \frac{M_{i,j} - 3}{2} \quad (3.1)$$

onde

$$M_{i,j} = \frac{\sum_{i=0}^n R_{i,j}}{n} \quad (3.2)$$

e $M_{i,j}$ é a média das notas $R_{i,j}$ que o usuário i deu aos produtos recomendados pelo usuário j e n o número de recomendações que i recebeu de j . Para o parâmetro de confiança $C_{i,j}$ ficar normalizado na escala $[-1,1]$, assim como os parâmetros de similaridade entre perfis e itens, a Equação 3.1 é aplicada.

Desse modo, o parâmetro de confiança é a média das notas dadas aos produtos recomendados normalizada na escala $[-1,1]$. A Figura 3.2 ilustra as relações entre os usuários da rede social e os parâmetros de confiança calculados.

O algoritmo RBC leva em conta que as pessoas que fazem boas recomendações têm um alto grau de confiança do usuário que recebeu as indicações de produtos. No plano social, a hipótese é que o bom recomendador é uma pessoa conhecida, enquanto os desconhecidos são maus recomendadores. Assim, o bom recomendador possui um alto grau de confiança, permitindo ao sistema que o fluxo de recomendações entre pessoas confiáveis seja maior do que o entre as não confiáveis.

O sistema também recomenda produtos utilizando os algoritmos RBP e RBI, que também levam em conta as avaliações de produtos feitas pelos usuários no sistema. Com relação ao RBC, o RBP e o RBI utilizam todas as avaliações de produtos feitas na rede e o RBC utiliza apenas as avaliações de produtos recomendados ao usuário alvo.

Todas as informações sobre as avaliações são armazenadas no repositório para que o sistema de recomendação as consulte e seja capaz de realizar recomendações de outros produtos aos usuários. Esse é um dos propósitos do sistema de recomendação: mostrar ao usuário apenas informações relevantes. A Figura 3.3 apresenta os diagrama de blocos dos aspectos do sistema e a relação entre eles.

3.3 Funcionalidades Principais

Abaixo estão sumarizadas as principais funcionalidades do sistema acompanhadas das descrições em formato de *user stories* [15]:

- Envio de convite

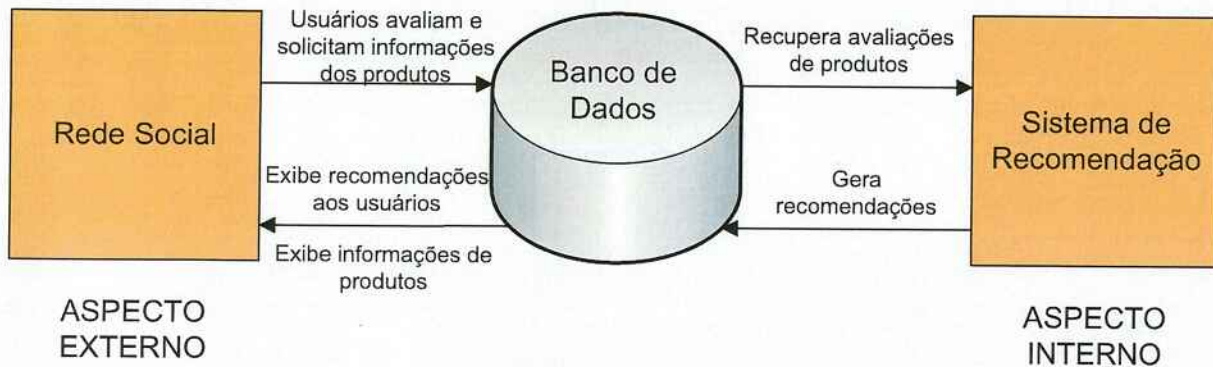


Figura 3.3: Aspectos funcionais do sistema

Como usuário, quero convidar outra pessoa a ingressar na rede social para que ela possa utilizar o sistema.

- Pedido de amizade

Como usuário, quero convidar outro usuário a estabelecer uma relação de amizade na rede para que eu possa acompanhar as suas atividades.

- Confirmação de amizade

Como usuário, quero confirmar ou rejeitar um pedido de amizade para que eu possa acompanhar as atividades dos meus amigos pelo sistema.

- Avaliação de produto

Como usuário, quero fazer a minha avaliação de produtos para que outros tenham conhecimento da minha opinião.

- Envio de recomendação de produto a outro usuário

Como recomendador, quero enviar uma recomendação de produto para outra pessoa presente no sistema para que ela conheça a minha opinião sobre este item.

- Recomendação de produtos

Como usuário, quero receber uma lista de produtos que eu provavelmente goste para que eu não precise filtrar os itens que me interessam.

- Visualização das avaliações dos usuários

Como usuário, quero estar ciente sobre as últimas avaliações dos meus amigos para que eu possa saber o que acontece no meu contexto social e conheça novos produtos.

3.4 Requisitos Não-Funcionais

Os principais requisitos não-funcionais do sistema são:

- Interface Web compatível as últimas versões dos *browsers* Internet Explorer, Mozilla Firefox e Safari.
- *Backend* compatível com servidores Linux.
- Tempo médio de resposta menor que 2 segundos para 10 usuários simultâneos quando executado em um servidor com processador Intel Core 2 Duo T7250 ou superior e 2 GB de memória RAM.

3.5 Implementação

A principal linguagem de programação utilizada no projeto foi Ruby, uma linguagem de script, com tipagem dinâmica, forte e implícita. Além disso, o Ruby permite uma abordagem multi-paradigma bem equilibrada entre os paradigmas orientado a objetos, funcional, imperativo e reflexivo.

O *framework* Web Ruby on Rails foi escolhido para implementação do projeto. O Rails permite a adição de novas funcionalidades de forma ágil, pois é baseado em uma arquitetura *Model-View-Controller* [16] (MVC) e segue os princípios *Convention over Configuration* [17] (CoC) e *Don't Repeat Yourself* [18] (DRY).

A linguagem Python também foi utilizada no projeto para algumas tarefas secundárias. Um script foi escrito nesta linguagem para fazer um *crawler* e o *parsing* de cerca de cento e vinte mil produtos do site Submarino¹ para preencher a base de dados de produtos.

O SQLite é uma biblioteca independente que implementa um banco de dados SQL transacional, sem a necessidade de configurações. Este foi o gerenciador de banco de dados escolhido para o projeto, pois ele atende aos requisitos de performance e facilita a geração de backups.

Visando permitir um padrão de usabilidade aceitável para o usuário comum, algumas interações no sistema são realizadas via AJAX (Asynchronous JavaScript And XML). Através dessa técnica a aplicação pode obter dados do servidor de forma assíncrona sem interferir na apresentação e no comportamento da página atual. Esse recurso foi utilizado para permitir que os usuários registrassem o interesse em produtos sem que a página fosse totalmente recarregada. Como o uso dessa técnica requer utilização de JavaScript

¹ www.submarino.com




Figura 3.4: Avaliação de produto via AJAX

no *browser* (cliente), e nem todos os *browsers* têm JavaScript habilitado, o sistema tolera essa deficiência do cliente e possibilita neste caso o acesso através de uma requisição síncrona com recarregamento total da página.

A Figura 3.4 apresenta o painel de avaliação de produto que utiliza a técnica de AJAX. Ao clicar em uma das estrelas, uma requisição é enviada ao servidor para o cadastro da avaliação e, em caso de sucesso, a resposta enviada de volta ao *browser* atualiza o estilo do elemento selecionado, indicando que a avaliação foi realizada.

O sistema conta com uma interface de administração na qual é possível enviar convites para novos usuários se integrarem à rede social. Quando um novo convite é gerado, automaticamente um *token* pseudo-aleatório lhe é associado. Esse *token* é enviado através de e-mail, permitindo o registro apenas do convidado associado ao convite. A autenticação do usuário é feita através de login com e-mail e senha. O *framework* escolhido para prover os mecanismos de autenticação foi o Warden², pois ele é adequado para oferecer poderosas opções de autenticação e pode ser utilizado em aplicações Rails através do Rack³.

A arquitetura cliente/servidor em três camadas, apresentada na Figura 3.5, foi adotada na implementação do projeto. Essa escolha possibilita a modificação ou substituição de uma das camadas sem afetar as demais. Além disso, a separação entre as camadas de aplicação e de dados facilita o balanceamento da carga do sistema. Por fim, as políticas de segurança aplicadas no servidor podem ser rigorosas e, mesmo assim, não incomodarem excessivamente os clientes.

² <http://github.com/hassox/warden>

³ <http://rack.rubyforge.org/>

Figura 3.5: *Arquitetura em três camadas*

Capítulo 4

ESPECIFICAÇÃO DO EXPERIMENTO

4.1 Descrição do Experimento

Foi realizado um experimento com 60 pessoas, que se cadastraram e formaram uma rede social disposta em 12 grupos de 5 amigos. O sistema de recomendação utiliza essa rede social para obter as informações de relações de amizade entre as pessoas. Neste contexto, um participante é considerado amigo do outro quando eles pertencem a um mesmo grupo de amigos. Também foi levado em conta que dois amigos se conhecem, mantêm contato frequente e que têm noção dos seus interesses mútuos.

Inicialmente 12 pessoas foram convidadas para participarem do experimento e cada uma delas tinha a tarefa de montar o seu próprio grupo, convidando 4 amigos seus. Os grupos de amigos foram definidos a partir do envio de um e-mail com um convite do participante já cadastrado no sistema a outra pessoa. Este e-mail possuía um endereço de cadastro onde foi possível a pessoa se cadastrar e automaticamente já fazer parte do grupo de amigos do participante que a convidou.

Os participantes receberam recomendações dos seus amigos e de outras pessoas presentes na rede. Além disso, as informações de avaliações de produtos por parte dos participantes foram utilizadas pelo sistema de recomendação para recomendar outros produtos a eles. Como já citado no capítulo 1, foram utilizados 3 tipos de algoritmos pelo sistema de recomendação:

- Baseado em similaridade entre perfis
- Baseado em similaridade de produtos
- Baseado em confiança

Inicialmente 12 pessoas foram convidadas a participar do experimento. Cada uma destas convidou outras 4 pessoas para formarem um grupo de amigos. Sendo assim, formaram-se 12 grupos de 5 amigos, totalizando 60 pessoas. Cada participante de um grupo de amigos concorda em ser definido como amigo de todos no grupo, ou seja, todas as pessoas pertencentes a um mesmo grupo de amigos se conhecem e se consideram amigas. Cada participante do experimento recebeu, leu e assinou uma cópia do Termo

de Consentimento Livre e Esclarecido (vide Apêndice B) concordando em participar do experimento.

Os participantes realizaram o cadastro informando os seguintes dados pessoais:

- Nome
- Sexo
- Faixa etária (18-25, 26-30, 31-40, +40)
- Foto


O experimento consistia em 6 etapas, onde os participantes deveriam executar tarefas descritas no próprio sistema. As cinco primeiras etapas do experimento serviram para montar a base de dados necessária para a realização da sexta e última etapa, a qual utilizaria a base para rodar os algoritmos de recomendação e compará-los ao término do experimento.

4.1.1 Primeira Etapa

Logo após a finalização do cadastro no sistema, a primeira etapa do experimento era iniciada. Ela consistia na avaliação de 20 produtos em comum a todos os participantes de todos os grupos. Esses produtos foram selecionados previamente, com o intuito de abranger os diferentes gostos de todos os participantes. Esta etapa foi necessária para que houvesse um *rating overlap* no sistema, ou seja, para que todos os participantes avaliassem um mesmo conjunto de produtos. Com isso, foi possível calcular a similaridade de perfis entre todos os participantes da rede. Além disso, com esta etapa, resolve-se o problema dos *coldstart users*, pois todos os participantes iniciam o uso do sistema ativamente.

Avaliar um produto significa dizer o quanto o participante considera aquele produto como relevante para si, ou seja, o quanto ele se interessa pelo produto. A avaliação é feita por meio da atribuição de uma nota de 1 a 5, sendo que 1 significa ausência de interesse e 5 representa muito interesse. Esse interesse não significa necessariamente uma atitude de compra. O objetivo dessa avaliação é saber realmente o interesse do participante, podendo representar cobiça ou curiosidade, além de admiração pelo produto. A interface de avaliação está apresentada na Figura 4.1.

Caso o participante não conhecesse o produto na hora de avaliá-lo, ou seja, não tivesse ouvido falar dele ou não tivesse conhecimento suficiente para reconhecê-lo, até o instante



Sun Tzu

Arte da Guerra: os Treze Capítulos Originais, A - Bolso

O maior tratado de guerra de todos os tempos em sua versão completa em português. A **Arte da Guerra** é sem dúvida a Bíblia da estratégia, sendo hoje utilizada amplamente no mundo dos negócios, conquistando pessoas e mercados. Não nos surpreende vê-la citada em filmes como *Wall Street* (Oliver Stone, 1990) e constantemente aplicada para solucionar os mais recentes conflitos do nosso dia-a-dia....

Seu interesse neste produto:

Pouco Interesse ☆☆☆☆☆ Muito Interesse

Figura 4.1: Apresentação de produto para avaliação do participante

em que ele lhe foi apresentado, ele deveria informar isso ao sistema por meio de uma opção disponibilizada após a avaliação de cada produto. Mesmo não conhecendo, o participante avaliava o produto de acordo com o seu grau de interesse. Neste caso, a avaliação deveria ser feita apenas com base na foto e descrição do produto.

4.1.2 Segunda Etapa

Ao finalizar a primeira etapa, automaticamente a segunda etapa era ativada. Esta visava conhecer os interesses particulares dos participantes. Para isso, foram disponibilizados vários produtos, separados nas diversas categorias, sendo que o participante deveria avaliar 10 produtos. As categorias escolhidas foram as seguintes:

- CDs
- DVDs e Blu Ray
- Livros
- Livros Importados
- Celulares e Telefonia Fixa
- Vinhos e Bebidas
- Relógios e Presentes

- Informática e Acessórios

Os dados dos produtos foram retirados do site da Submarino¹, sendo que apenas algumas categorias de livros, CDs e DVDs foram cadastradas no sistema e apenas os 60 produtos mais vendidos das outras categorias foram inseridos no cadastro.

Uma busca por nome foi implementada para que os participantes pudessem localizar um produto ao seu gosto e avaliá-lo. Nesta etapa, também estava disponível a opção de “Não conheço”, pois era possível o participante encontrar durante a busca um produto desconhecido que o agradasse. A interface de busca de produtos está ilustrada na Figura 4.2.

Esta etapa era necessária para que os participantes avaliassem outros produtos além daqueles da primeira etapa que garantem o *rating overlap*. Além dos produtos em comum, os sistemas de recomendação necessitam que as pessoas contribuam com informações individuais, pois um sistema de recomendação sempre indica produtos que não tenham sido avaliados pelo participante que receberá a recomendação. Desse modo, além das pessoas avaliarem produtos em comum, é necessário que elas avaliem diferentes produtos para que o sistema de recomendação tenha outros produtos a indicar.

4.1.3 Terceira Etapa

Assim que todos os participantes terminassem as duas primeiras etapas do experimento, a terceira etapa era iniciada. Enquanto isso não ocorresse, quem terminava a segunda etapa recebia a mensagem do sistema informando que a terceira etapa estava desabilitada. Esse sincronismo foi necessário, pois as etapas seguintes necessitavam das informações de avaliação de produtos de todas as pessoas.

Nesta terceira etapa, o participante deveria recomendar produtos às pessoas do seu grupo. Como todos os integrantes de um grupo eram amigos entre si, era esperado que as recomendações de produtos fossem fáceis de serem realizadas, porque normalmente as pessoas conhecem os gostos dos amigos. Por isso, cada participante deveria recomendar 5 produtos a cada amigo, ou seja, 20 produtos no total.

A Figura 4.3 apresenta a interface do participante no início da etapa 3.

A busca de produtos estava disponível nesta etapa, bem como as avaliações de todos os amigos contendo no total os 30 produtos que cada um avaliou nas duas primeiras etapas do experimento. Não era possível um participante recomendar um produto já avaliado pela pessoa que receberia a recomendação, assim como não era possível recomendar o mesmo produto mais de uma vez para a mesma pessoa. Mesmo assim, o participante


¹ <http://www.submarino.com>

[Home](#) | [user@email.com](#) | [Meu perfil](#) | [Sair](#)

Etapa 2 - Andamento 0/10

Buscar
 Categoria

Ordernar por: [nome](#) [popularidade](#)



Vários

[CD Master Trilhas: Cuca Legal](#)


Você não pode deixar de conferir *Master Trilhas*, a coleção fantástica que traz o melhor das trilhas sonoras de novelas marcantes na história da televisão brasileira. Nesta edição, os sucessos que embalaram a trama de "Cuca Legal". Uma ótima oportunidade para relembrar este clássico!

Artista: VÁRIOS **Ano:** 2006 **Procedência:** Nacional **Label:** Som Livre **ISSN:** 7891430056520

1. **Disco**

...

Seu interesse neste produto:
 Pouco Interesse ☆☆☆☆ Muito Interesse



[CD Barely Illegal](#)

Não deixe de conferir o EP *Barely Illegal*, do Wired Desire. No repertório, "No One Sleeps", "The Hard Stuff", "Damn Hard" e "Ride". Um álbum excelente que não pode ficar fora de sua coleção! **Artista:** WIRED DESIRE **Ano:** 2009 **Procedência:** Nacional **Label:** Mnf Brazil

1. **Disco**

Figura 4.2: Interface de busca de produtos

poderia receber duas recomendações de um mesmo produto, desde que elas fossem feitas por amigos diferentes. Neste caso o sistema armazenava as duas recomendações como distintas e mostrava apenas uma vez o produto para ser avaliado pela pessoa que recebeu a recomendação.

[Home](#) | [user@email.com](#) | [Meu perfil](#) | [Sair](#)

Etapas 3 - Andamento 0/20

Logado com sucesso.

- Olá, Adônis! Esta é a **terceira etapa** do nosso experimento de 6 etapas.
- **Abaixo estão listados os amigos do seu grupo. Você deverá recomendar 5 produtos a cada um deles.**
- Uma boa recomendação consiste em recomendar produtos que seus amigos tenham muito interesse e que não sejam óbvios a eles.
- Para realizar as recomendações para um amigo, **escolha um deles abaixo.**

Envio de recomendações

- Envie 5 recomendações para [Newton](#)
- Envie 5 recomendações para [Ciclano](#)
- Envie 5 recomendações para [Beltrano](#)
- Envie 5 recomendações para [Fulano](#)

Figura 4.3: *Envio de recomendações de produtos*

Esta etapa era necessária para que posteriormente fosse possível analisar a eficiência da recomendação de produtos realizadas por amigos: nossa hipótese é que tal tipo de recomendação deveria ser mais eficiente do que as recomendações realizadas por pessoas desconhecidas ou pelo sistema de recomendação [14].

4.1.4 Quarta Etapa

Depois de ter feito as 5 recomendações de produtos a cada amigo, o participante deveria recomendar alguns produtos a pessoas que não faziam parte do seu grupo, ou seja, pessoas desconhecidas. Ficava visível ao participante uma lista gerada pelo sistema contendo alguns desconhecidos. Tal lista foi gerada aleatoriamente em um aplicativo desenvolvido especialmente para este fim. Para cada pessoa na lista, o participante deveria recomendar apenas um produto. As avaliações de produtos realizadas por essas pessoas da lista ficavam disponíveis ao participante, sendo que ele deveria se basear apenas nestes dados e nos dados pessoais da pessoa para lhe recomendar um produto.

Com as recomendações realizadas por pessoas desconhecidas, foi possível comparar estas com aquelas feitas pelos amigos durante a terceira etapa do experimento. Foi necessário esperar que todos os participantes terminassem a terceira e quarta etapas para que o experimento desse continuidade, já que todas essas recomendações de produtos seriam utilizadas nas etapas seguintes.

4.1.5 Quinta Etapa

A quinta etapa tinha como propósito mostrar apenas as recomendações diretas, ou seja, aquelas que foram feitas tanto pelos amigos do participante, como pelas pessoas desconhecidas. Os produtos recomendados eram listados ao participante para que ele os avaliasse novamente de acordo com o seu grau de interesse, além de informar se os conhecia ou não.

Na listagem de recomendações, não ficava visível ao participante quem lhe recomendou o produto, para que a origem da recomendação não tivesse nenhuma influência na hora de demonstrar o seu nível de interesse no produto. Caso estivesse exposto que um amigo seu lhe recomendou o produto, o participante poderia avaliá-lo bem só por causa do laço de amizade que tem com o recomendador. Ou, no caso contrário, avaliar mal um produto só porque não conhece a pessoa que o recomendou. Não havendo esse tipo de influência, foi possível analisar as avaliações de produtos recomendados por amigos e desconhecidos de modo semelhante.

Para o sistema realizar as recomendações baseadas em confiança, era necessário que a terceira e quarta etapas fossem finalizadas por todos os participantes. Ao término da segunda etapa o sistema já poderia recomendar produtos, mas utilizando apenas os algoritmos baseados em perfil e em produto. A utilização desses algoritmos já era possível porque as avaliações dos 20 produtos da primeira etapa e a dos 10 da segunda já forneciam dados suficientes. Porém, como o algoritmo baseado em confiança necessita da avaliação de produtos recomendados diretamente por pessoas, foi decidido que todas as recomendações realizadas pelo sistema, a partir dos algoritmos baseados em perfil, produto e confiança, seriam realizadas ao término da quarta etapa. Com a avaliação dos produtos recomendados na terceira e quarta etapas os algoritmos baseados em perfil e em produto teriam mais dados para os seus cálculos.

Nenhum participante desistiu do experimento nesta etapa. No total, 51 participantes alcançaram a sexta e última etapa.

Etapas	Participantes que desistiram	Participantes que finalizaram
1	2	58
2	2	56
3	3	53
4	2	51
5	0	51
6	1	50

Tabela 4.1: Número de participantes durante as etapas do experimento

4.1.6 Sexta Etapa

A sexta etapa do experimento consistia na avaliação dos produtos recomendados pelo sistema aos participantes. Foram utilizados os 3 tipos de algoritmos para as recomendações, sendo que cada um deles originou 10 recomendações de produtos, totalizando 30 recomendações. Em alguns casos dois algoritmos diferentes recomendaram o mesmo produto. Quando isso ocorria, a recomendação era contabilizada normalmente para os dois algoritmos e o produto era mostrado apenas uma vez ao participante para ser avaliado.

Esta foi a etapa mais importante do experimento, pois é nela que se obteve os resultados das avaliações dos produtos recomendados com base na confiança. Além disso, houve também a avaliação dos produtos recomendados com base nos outros dois algoritmos, para que se pudesse analisar e comparar a eficiência dos três algoritmos utilizados no experimento.

Assim que os participantes terminavam as avaliações dos produtos, uma mensagem de agradecimento era mostrada e o experimento era finalizado.

Apenas um participante desistiu desta etapa final, totalizando 50 pessoas em um total de 60 a realizarem todas as etapas do experimento. A Tabela 4.1 mostra o número de participantes que realizaram as diferentes etapas do experimento e o número de participantes que desistiram do experimento durante as mesmas.

Capítulo 5

ANÁLISES E RESULTADOS

5.1 Introdução

Para efetuar a análise dos resultados do experimento, inicialmente foram elaborados gráficos e tabelas com os valores obtidos da base de dados. Os seguintes dados foram considerados para a análise:

- Grupos de usuários

Utilizado para avaliar os laços de amizade entre os participantes cadastrados no experimento. São 12 grupos no total, sendo que cada um deles possui no máximo 5 pessoas.

- Recomendações enviadas por amigos

Informações dos produtos que foram recomendados na etapa 3 do experimento, onde os participantes deveriam recomendar 5 produtos a cada amigo presente no seu grupo. Cada participante possui no máximo 20 recomendações, sendo que devido à desistência de participantes do seu grupo, alguns possuem apenas 15 recomendações.

- Recomendações enviadas por desconhecidos

Informações dos produtos que foram recomendados na etapa 4 do experimento, onde os participantes deveriam recomendar 1 produto a alguns participantes de diferentes grupos, considerados desconhecidos. Cada participante possui no máximo 10 recomendações realizadas por desconhecidos, sendo que alguns, devido à desistência de participantes no experimento, possuem menos de 10 recomendações.

- Recomendações realizadas pelo sistema

Todas as recomendações que o sistema realizou para os participantes. Contém a informação de qual participante recebeu a recomendação e qual foi o produto recomendado.

- Avaliação prevista do produto pelo sistema

Ao recomendar um produto a um participante, o sistema calcula uma nota prevista para o mesmo. Essas informações foram armazenadas e consideradas durante a análise dos dados do experimento.

- Avaliações dos produtos

Todas as avaliações de produtos no sistema. Contém os produtos avaliados na duas primeiras etapas do experimento, quando os participantes avaliaram 20 produtos em comum e 10 produtos de seu interesse, e as avaliações de produtos recomendados tanto pelos participantes como pelo sistema. Lembrando que a escala de avaliação dos produtos é de 1 a 5, sendo 1 o participante não ter interesse e 5 o participante ter muito interesse naquele produto.

- Algoritmo utilizado para a recomendação

Dentre as recomendações realizadas pelo sistema, foi retirada da base de dados a informação de qual algoritmo foi utilizado para gerar a recomendação.

De posse dos dados, foram feitas as seguintes análises:

- Análise Comparativa dos Algoritmos de Recomendação
- Análise de Rejeição das Recomendações
- Taxa de Serendipidade
- Análise do Algoritmo Baseado em Confiança

Cada análise será discutida nas seções a seguir.

5.2 Análise Comparativa dos Algoritmos de Recomendação

Nesta seção, serão comparados os resultados dos três algoritmos de recomendação e as recomendações diretas feitas tanto por amigos quanto por desconhecidos.

A Figura 5.1 compara a média da nota prevista com a nota média real dada pelos participantes do sistema. A Tabela 5.1 contém os dados utilizados para a construção do gráfico. Nota-se que o algoritmos RBC e RBP deram nota 5 para todos os produtos recomendados, resultando em uma grande diferença em relação à avaliação real. O RBI consegue fazer uma previsão bem próxima da real, mostrando que o seu modelo das avaliações é bastante preciso. Para as recomendações diretas, foi considerado que uma pessoa ao




Figura 5.1: Nota média das avaliações realizadas comparadas com a nota média prevista pelos algoritmos

Tipo de recomendação	Nota Média	Nota Média Prevista
RBI	2.96	3.70
Direta	3.46	5.00
RBC	2.70	5.00
RBP	2.37	5.00

Tabela 5.1: Nota média das avaliações realizadas comparadas com a nota média prevista pelos algoritmos

Tipo de recomendação	Erro Médio Absoluto
Direta	1.54
RBC	2.30
RBI	1.26
RBP	2.63

Tabela 5.2: Erro médio absoluto (MAE) das recomendações




Figura 5.2: Erro médio absoluto (MAE) das recomendações

Tipo de recomendação	Média	Desvio-Padrão
Direta	3.46	1.41
RBC	2.70	1.48
RBI	2.96	1.41
RBP	2.37	1.38

Tabela 5.3: Notas por tipo de recomendação

recomendar espera que a recomendação seja avaliada com nota máxima, resultando em uma nota prevista 5.

Na Figura 5.2, é mostrada a comparação do Erro Médio Absoluto (MAE)¹ para os diferentes tipos de recomendação. Os dados utilizados estão na Tabela 5.2. Esta medida é utilizada para comparar a acurácia de diferentes sistemas de recomendação. Verifica-se que o algoritmo RBI obteve o melhor resultado, seguido pelas recomendações diretas, RBC e RBP.

As notas médias dadas pelos participantes estão discriminadas por algoritmos de recomendação e pelas recomendações diretas, como mostra a Figura 5.3. Os dados utilizados para a elaboração do gráficos estão na Tabela 5.3. As recomendações que resultaram em

¹ Do inglês Mean Average Error




Figura 5.3: Notas por tipo de recomendação

Tipo de recomendação	Média	Desvio-Padrão
Amigos	3.51	1.41
Desconhecidos	3.36	1.40

Tabela 5.4: Notas das recomendações diretas

uma média de notas maior foram as diretas, seguidas das realizadas com o algoritmo RBI, RBC e RBP.

As notas médias dadas por recomendações diretas foram separadas entre as realizadas por amigos e as feitas por desconhecidos, como ilustra a Figura 5.4. Os dados utilizados para a construção do gráfico está na Tabela 5.4. Verifica-se que a média de notas dadas por recomendações realizadas por amigos foi ligeiramente maior que as notas dadas a produtos indicados por desconhecidos.

5.3 Análise de Rejeição das Recomendações

Nesta seção, serão analisadas a taxa de rejeição das recomendações realizadas pelos algoritmos RBI, RBP e RBC, além das recomendações diretas. Para isso, foram definidas classes de avaliações. As avaliações com notas 1 e 2 são da classe de *Rejeição*, as com

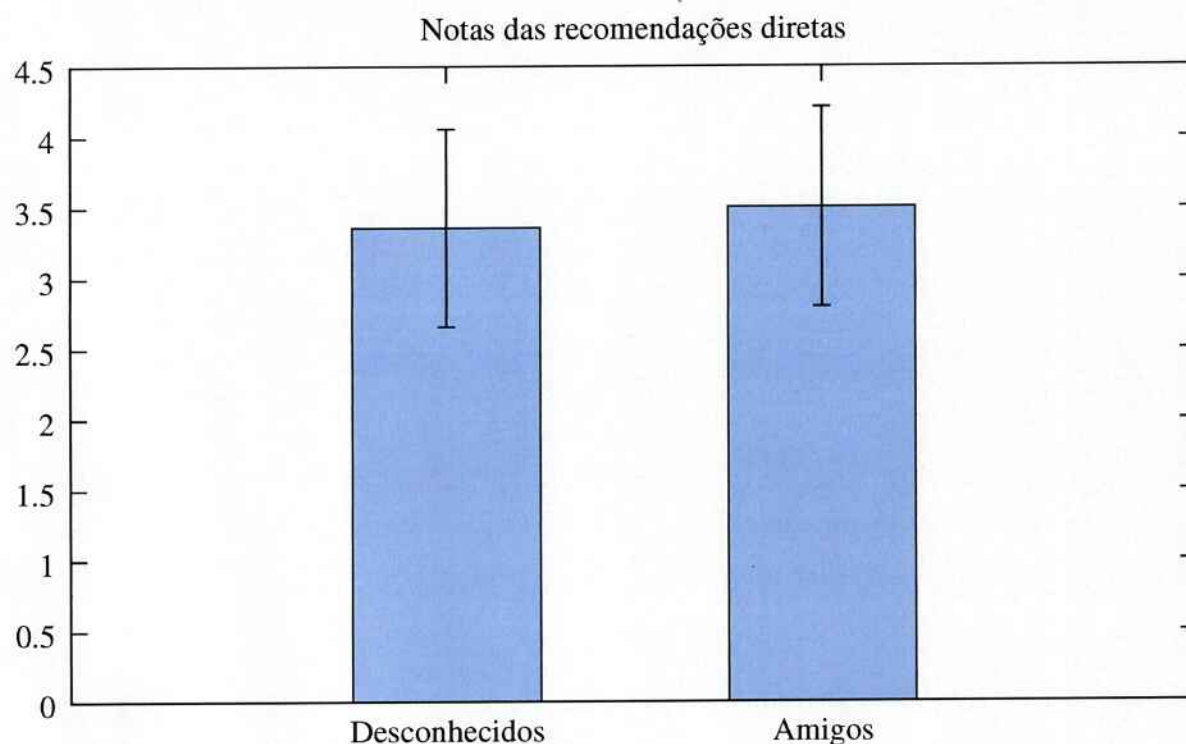


Figura 5.4: Notas das recomendações diretas

Tipo de recomendação	Rejeição	Indiferente	Aceitação
Direta	26%	19%	54%
RBC	48%	16%	32%
RBI	38%	22%	36%
RBP	58%	17%	22%

Tabela 5.5: Porcentagem das notas em cada faixa comparadas por tipo de recomendação

nota 3 são da classe *Indiferente* e as com notas 4 e 5 são da classe *Aceitação*. A classe *Rejeição* denota as recomendação que não foram aceitas e a classe *Aceitação* denota as recomendações que foram aceitas. Na classe *Indiferente*, estão as recomendações que tiveram avaliações neutras (nota 3).

Podemos verificar pela Figura 5.5 que as recomendações diretas representaram uma maior porcentagem de notas na classe de *Aceitação*, seguida das recomendações feitas pelo algoritmo RBI, RBC e, por fim, RBP. Os dados utilizados para a elaboração do gráfico constam na Tabela 5.5.




Figura 5.5: Porcentagem das notas em cada faixa comparadas por tipo de recomendação




Figura 5.6: Taxa de serendipidade por tipo de recomendação

Tipo de recomendação	Taxa de Serendipidade
Direta	22%
RBC	12%
RBI	13%
RBP	9%

Tabela 5.6: Taxa de serendipidade por tipo de recomendação

5.4 Taxa de Serendipidade

Serendipidade significa o usuário ter aceito a recomendação, ou seja, ter dado uma nota 4 ou 5 ao produto e não o conhecer. A taxa de serendipidade foi calculada com base no número de recomendações de produtos desconhecidos aceitas sobre o total de produtos recomendados em cada tipo de algoritmo, considerando também as recomendações diretas. A Figura 5.6 mostra a taxa de serendipidade para os tipos de recomendação, sendo que os dados utilizados para elaborar o gráfico estão na Tabela 5.6.

Verificamos que as recomendações diretas resultaram em um alto grau de serendipidade, se comparado com os graus dos tipos de recomendações que as seguiram: RBI, RBC e RBP.




Figura 5.7: Taxa de serendipidade comparando amigos e desconhecidos

Tipo de recomendação	Taxa de Serendipidade
Amigos	23%
Desconhecidos	20%

Tabela 5.7: Taxa de serendipidade comparando amigos e desconhecidos

A Figura 5.7 compara a taxa de serendipidade entre as recomendações diretas realizadas por amigos e por desconhecidos. A Tabela 5.7 contém os dados utilizados para elaborar o gráfico. Podemos ver que as recomendações realizadas pelos amigos resultaram em uma taxa de serendipidade ligeiramente maior que as recomendações realizadas por desconhecidos.

5.5 Análise do Algoritmo Baseado em Confiança

Com os dados apresentados na seções anteriores, podemos verificar que o algoritmo de recomendação baseado em confiança (RBC) produziu, em alguns casos, resultados relativamente melhores do que o algoritmo RBP.

Na análise de desvio da nota prevista, o RBC não foi tão eficiente quanto as recomendações diretas e o algoritmo RBI, porém mostrou resultados melhores que o RBP.

Verificando a média de notas dadas, o RBC teve resultado intermediário com relação aos outros dois algoritmos, sendo que as recomendações diretas apresentaram a melhor eficiência. Isso ocorreu principalmente pelo fato dos desconhecidos terem recomendado quase tão bem como os amigos, como mostra a Figura 5.4.

Quanto à taxa de serendipidade, o RBC manteve-se na média dos outros algoritmos, sendo que as recomendações diretas foram disparadamente mais eficientes.

De acordo com os dados, o RBC conseguiu recomendar melhor que o RBP. O RBC utiliza menos informações que o RBP, limitando-se aos usuários que realizaram recomendações ao usuário alvo, para recomendar e mesmo assim mostrou-se melhor nos resultados do experimento.

5.6 Testes de Hipótese

Um dos objetivos do experimento foi testar certas hipóteses que, ao serem confirmadas, fornecem uma base mais sólida para a construção de sistemas de recomendação efetivos.

A seguir cada hipótese será analisada. As hipóteses nulas (H_0) são todas iguais, elas consideram que as duas diferentes distribuições pouco diferem, tendo, por exemplo, a mesma média, mediana ou algum critério equivalente que depende exatamente do teste de hipótese utilizado. Para mais informações, consultar a seção apêndice A, onde estão listados os testes utilizados e os resultados numéricos dos mesmos.

TH1: Os Amigos Recomendam Melhor do que os Desconhecidos

A hipótese nula foi rejeitada com um nível de significância de 10%, confirmando esta hipótese quando também se considera que a média das recomendações dos amigos é maior do que as dos desconhecidos, conforme pode ser visto na Figura 5.4.

TH2: A Recomendação Baseada em Confiança é Melhor do que a Baseada em Similaridade de Perfil dos Usuários

A hipótese nula foi rejeitada com um nível de significância de 0.5%, confirmando a hipótese de que o algoritmo apresentado nesta monografia (RBC) tem um desempenho superior ao algoritmo de similaridade de perfil (RBP), que é um dos mais utilizados na filtragem social. As Figuras 5.5 e 5.3 mostram a melhor aceitação da RBC em relação a RBP.



Figura 5.8: Resultado dos testes de hipótese

TH3: As Recomendações Diretas são Melhores do que as Baseadas em Confiança

A hipótese nula foi rejeitada com um nível de significância de 0.5%, confirmando que as recomendações feitas diretamente pelas pessoas possuem uma aceitação muito maior do que o algoritmo apresentado neste trabalho, como pode ser visto nas Figuras 5.5 e 5.3.

TH4: As Recomendações Baseadas em Similaridade de Itens são Melhores do que as Baseadas em Confiança

A hipótese nula foi rejeitada com um nível de significância de 0.5%, confirmando, como pode ser visto nas Figuras 5.5 e 5.3, que a RBI é melhor aceita do que a RBC.

Tais testes de hipótese são mostrados na Figura 5.8.

Requisição Web	Média	Desvio Padrão	Min.	Max.
ProductsController#index.html [GET]	16.90s	29.02s	0.00s	5m06s
ProductsController#rate.html [POST]	2.09s	1.24s	0.80s	32.16s
ProductsController#unknown.html [POST]	1.26s	0.54s	0.85s	2.42s
ProductsController#show.html [GET]	1.18s	1.21s	0.00s	8.52s

Tabela 5.8: *Tempo de resposta das requisições ao banco de dados antes da otimização*

Requisição Web	Média	Desvio Padrão	Min.	Max.
ProductsController#index.html [GET]	1.28s	3.51s	0.00s	57.42s
ProductsController#rate.html [POST]	0.13s	0.77s	0.00s	21.05s
ProductsController#unknown.html [POST]	0.02s	0.10s	0.00s	2.66s
ProductsController#show.html [GET]	0.02s	0.12s	0.00s	1.99s

Tabela 5.9: *Tempo de resposta das requisições ao banco de dados após a otimização*

5.7 Análise de Desempenho

Durante a realização do experimento foram evidenciados problemas de desempenho que prejudicavam a experiência dos participantes. Sendo assim, surgiu a necessidade de realizar uma análise de desempenho para encontrar os gargalos do sistema e modificá-los de modo a reduzir o tempo de resposta a um nível aceitável pelo usuário.

Algumas requisições ao servidor de aplicação foram identificadas como gargalo de desempenho do sistema, como pode se observar na Tabela 5.8. Ao analisar estas requisições, foi possível verificar que os principais fatores responsáveis pela degradação do desempenho estavam relacionados ao tempo e quantidade das requisições ao banco de dados. As consultas SQL na tabela de produtos, com cerca de cento e vinte mil registros, foram as principais responsáveis pelo excesso no tempo de resposta. Esses problemas de desempenho foram corrigidos através da redução do número de requisições ao banco de dados e pela paginação dos resultados. Os tempos de resposta das requisições observados após a otimização estão apresentados na Tabela 5.9.

Para completar a análise do desempenho do sistema, a Tabela 5.10 apresenta as requisições bloqueantes, isto é, aquelas com duração total maior do que um segundo. Os dados apresentados na Tabela 5.10 são referentes apenas as requisições feitas após a otimização até o término do experimento.

Requisição Web	Ocorrências	Porcentagem
UserRecommendationsController#new.html [GET]	1596	65.2%
ProductsController#index.html [GET]	315	12.9%
AdminController#index.html [GET]	167	6.8%
ProductsController#rate.html [POST]	165	6.7%
HomeController#index.html [GET]	128	5.2%
UserRecommendationsController#create.html [POST]	38	1.6%
RecommendationGuidesController#index.html [GET]	11	0.4%
InvitationsController#create.html [POST]	8	0.3%
ProductsController#unknown.html [POST]	8	0.3%
RatingsController#index.html [GET]	7	0.3%
SessionsController#create.html [POST]	4	0.2%
UsersController#new.html [GET]	1	0.0%
ProductsController#show.html [GET]	1	0.0%

Tabela 5.10: *Requisições bloqueantes*

Capítulo 6

CONSIDERAÇÕES FINAIS

6.1 Conclusão

O projeto obteve como resultado um sistema de recomendação acoplado a uma rede social que consegue utilizar 3 diferentes tipos de algoritmos para recomendar. Desse modo, considerando-se que isto havia sido proposto inicialmente, o trabalho foi finalizado corretamente.

Na avaliação de resultados realizada, a comparação dos algoritmos foi feita por testes de hipótese com índice de significância de 10%, porque as médias de avaliações realizadas por amigos e desconhecidos foram muito próximas. Nos outros testes, a significância foi de 0,5%.

Um dos pontos que deve ser levado em conta com relação às recomendações realizadas por amigos e desconhecidos é que talvez os integrantes de um mesmo grupo não possuíssem um grau efetivo de amizade. Isso ocorre porque durante a fase de formação de grupos, alguns deles tiveram dificuldades em conseguir 5 amigos entre si, fazendo com que alguns integrantes apenas se conhecessem. Com isso, nem todos os presentes no grupo teriam noção completa dos interesses dos outros. Em uma aplicação do mundo real, isso provavelmente não seria um problema, porque as pessoas não seriam obrigadas a formar grupos de no mínimo 5 amigos. Além disso, mesmo que em seu grupo houvesse pessoas desconhecidas, não haveria a necessidade compulsória de enviar recomendações a todas as pessoas do seu grupo. Assim, as pessoas seriam livres para interagir somente com as pessoas de sua escolha, melhorando as suas recomendações.

A procura por produtos durante a realização do experimento foi uma das deficiências encontradas no sistema. Mesmo com uma base de dados com mais de 120 mil produtos, a busca implementada teve que ser simples, devido às restrições técnicas relacionadas ao desempenho da aplicação. A funcionalidade de busca de produtos no sistema foi considerada inadequada, pois procurava apenas por produtos que tivessem no nome o termo procurado de forma exata. Isto dificultou a localização de determinados produtos por alguns participantes. Assim, mesmo que uma pessoa quisesse recomendar um bom produto a outra, se ela não o encontrasse, recomendaria outro produto de menor interesse para o participante que recebesse a recomendação.

Além disso, alguns tipos de recomendação podem ter indicado produtos óbvios aos participantes. Durante a realização do experimento, os participantes eram avisados na fase de recomendação para não enviarem recomendações de produtos óbvios aos outros participantes, ou seja, produtos diretamente relacionados aos produtos já avaliados pelo participante alvo. Por exemplo, a base de produtos possuía CDs e DVDs. Enquanto um participante avaliava um CD de música de uma banda, outro participante acabava lhe recomendando um DVD da mesma banda, sendo óbvio que tal recomendação seria bem avaliada. Isso foi observado a partir de comentários realizados pelos participantes que já haviam terminado o experimento. Apenas alguns participantes se manifestaram sobre as suas dificuldades e problemas encontrados durante a realização do experimento. Esse contato foi feito informalmente por vontade dos próprios participantes, evidenciando a falta de um questionário pós-teste para recolher informações qualitativas sobre a realização do experimento. Seria muito interessante se esse tipo de questionário fosse aplicado a todos os participantes que tivessem concluído o experimento. Desse modo, as conclusões feitas sobre o trabalho seriam enriquecidas e ficariam mais amplas, englobando as opiniões de todos os participantes e não apenas as daqueles que entraram em contato por vontade própria.

A realização do projeto alcançou o seu objetivo de recomendar produtos com alto índice de relevância aos usuários. Com os resultados adquiridos a partir do experimento, ficou claro que o algoritmo de recomendação baseado em confiança (RBC) possui eficiência melhor do que o algoritmo RBP. O algoritmo RBI apresentou os melhores resultados dentre os tipos de recomendação realizados pelo sistema. Uma possível explicação é que tal algoritmo realiza uma análise global das recomendações e monta um modelo completo dos produtos. O sistema desenvolvido no projeto alcançou por completo os seus requisitos funcionais e não-funcionais.

6.2 Trabalhos Futuros

Nesta seção, serão descritos possíveis trabalhos futuros relacionados ao que foi realizado neste projeto. Alguns deles não puderam ser implementados devido às restrições de tempo ou por mudança no escopo do projeto.

6.2.1 Web Semântica

A World Wide Web é um sistema de documentos em hipermídia que são interligados e possivelmente executados na Internet. A maioria do conteúdo disponível na Web

atualmente é projetado para a leitura por seres humanos. A utilização de programas de computador para interpretação desse conteúdo é complexa, devido à baixa flexibilidade dos programas em relação aos humanos. Se por um lado os aplicativos são menos flexíveis que os seres humanos para interpretação de textos, por outro eles são capazes de desenvolver e analisar estruturas de dados complexas. A Web Semântica baseia-se nessa virtude do software.

Segundo Berners-Lee [19], a Web Semântica não é uma Web separada, mas um extensão da atual, na qual a informação é disponibilizada com sentido bem definido, aprimorando a capacidade de cooperação entre pessoas e computadores. Os documentos nesta extensão da Web são convenientes para utilização tanto por humanos como por programas.

Da mesma forma que os humanos buscam informações em bases de dados descentralizadas na Web, com a adoção da Web Semântica agentes computacionais poderão fazer o mesmo. Essa descentralização de documentos permite que inconsistências ocorram, porém possibilita um rápido crescimento no volume de dados.

A W3C realiza trabalhos para aprimorar, entender e padronizar a Web. Com o apoio de uma equipe especializada do consórcio, tecnologias para representação estrutural e semântica dos recursos na Web foram desenvolvidas, resultando em um conjunto de especificações para a Web Semântica. Atualmente este conjunto é basicamente composto pelo Resource Description Framework (RDF), a linguagem RDF Schema e a Web Ontology Language (OWL).

Os mecanismos de busca atualmente utilizados na Web são capazes de listar os sites que contenham os termos desejados, bem como ordená-los de acordo com critérios de relevância. Considerando as dificuldades impostas à interpretação do conteúdo pelos computadores, fica a cargo do usuário a tarefa de identificar quais dos sites obtidos são coerentes com as expectativas de contexto e necessidade.

Ciente disso, o grupo tinha proposto inicialmente um sistema de recomendação baseado em confiança com padrões da Web semântica. Todas as informações contidas no repositório seriam documentos semanticamente estruturados em padrões abertos. Com isso, todas as informações sobre avaliações e recomendações de produtos, além de perfis de usuários, estariam disponíveis para importação por outros sistemas que entendem a linguagem adotada nesses documentos. Desse modo, a filtragem e localização de produtos mais relevantes aos usuários ganharia a poderosa ferramenta do processamento computacional.

6.2.2 Confiança Dependente do Tempo

Em [12], o modelo de reputação proposto é baseado no cálculo do parâmetro de reputação a partir da somatória dos pesos de impressões que o usuário tem de determinada entidade. Porém, o artigo levanta um ponto importante e crucial no modelo: a reputação é dependente do tempo. Impressões antigas não podem ser consideradas com o mesmo peso das mais recentes. Para isso, os autores propuseram a utilização de uma função dependente do tempo tal como a Equação 6.1.

$$R'(IDB_a) = \sum_{t_i \in IDB_a} \rho(t, t_i) \times W_i \quad (6.1)$$

onde $R'(IDB_a)$ significa a reputação no tempo t que o agente a tem da impressão IDB Impressions Database, os pesos das impressões são os W_i , que são multiplicados por $\rho(t, t_i)$ e somados para todas as impressões t_i que o agente tem. A função $\rho(t, t_i)$ é uma função dependente do tempo, como visto na Equação 6.2.

$$\rho(t, t_i) = \frac{f(t_i, t)}{\sum_{t_j \in IDB_a} f(t_j, t)} \quad (6.2)$$

A função $f(t_i, t)$ dá valores próximos de t , podendo ser a função $f(t_i, t) = \frac{t_i}{t}$. Com isso, impressões antigas não têm o mesmo peso que impressões mais recentes.

Considerando o sistema proposto, o cálculo da confiança entre dois usuários poderia levar em conta o tempo em que as avaliações dos produtos recomendados foram feitas. Assim, o usuário pode avaliar negativamente um produto sem conhecê-lo, apenas demonstrando o seu baixo interesse nele. Após alguns meses, o usuário pode vir a conhecer o produto e passar a ter interesse no mesmo. Deste modo, a sua avaliação antiga não estaria condizente com o seu gosto atual.

O grupo não realizou a implementação desse modelo de confiança devido às restrições de tempo para a realização do experimento.

6.2.3 Feedback das Recomendações

O conteúdo de uma rede social é tão bom quanto a qualidade da informação compartilhada pelos seus usuários. Novos usuários muitas vezes não entendem o valor dessa contribuição e entram em uma rede apenas para observar os outros e não inserir nenhuma informação ou opinião. Por isso, a motivação para que novos entrantes ajudem na elaboração do conteúdo da rede social é muito importante e um dos meios para que isso ocorra é o *feedback* que o usuário ganha ao contribuir com algo [13].

Desse modo, quando um usuário compartilha alguma informação ele quer saber o que os outros presentes na rede pensaram da sua informação. Esse *feedback* motiva os usuários a compartilharem cada vez mais suas informações e opiniões e, com isso, aumentar o conteúdo presente na rede.

A proposta de trabalho futuro envolve a adição de *feedbacks* aos usuários que avaliam ou recomendem produtos na rede social. O sistema pode mostrar quais amigos do usuário avaliaram o mesmo produto ou simplesmente mostrar a avaliação que uma pessoa deu a um produto recomendado pelo usuário. De acordo com [13], essa informação de retorno que o sistema fornece a um usuário que contribui na rede motiva o mesmo a continuar compartilhando informações.

Esses mecanismos de *feedback* não foram implementados no sistema utilizado no experimento, para que os participantes não tivessem nenhuma influência na hora de avaliar ou recomendar os produtos. Caso o participante recebesse informações de retorno do sistema com relação às suas ações no experimento, ele poderia tentar mudar a sua estratégia de recomendação ou avaliação de produtos e, desse modo, não se comportar na sua maneira natural de agir.

6.2.4 Estudo dos Testes de Sensibilidade

A escolha dos valores adotados na realização do experimento prático não levou em consideração nenhum estudo de testes de sensibilidade. Neste trabalho não foi considerada a influência que a quantidade de itens avaliados ou o número de recomendações realizadas teria no resultado final.

De acordo com ??, um usuário deixa de ser um *cold-start user* quando ele executa pelo menos 5 ações no sistema. A primeira etapa do experimento tinha como objetivo fazer com que nenhum participante fosse um *cold-start user*, por isso, era necessário que eles avaliassem mais de 5 produtos. Como a avaliação de produtos era uma tarefa muito simples, consistindo apenas na atribuição de uma nota e na resposta da questão sobre o conhecimento prévio do produto, foi decidido que os participantes deveriam avaliar 20 produtos, porque não consumiria muito tempo e ultrapassaria o limite de 5 produtos que definem um *cold-start user* em um sistema.

O número de recomendações realizadas para amigos foi maior do que as feitas para desconhecidos porque foi considerado que recomendar um produto a um amigo é mais fácil, uma vez que um amigo já conhece os interesses do outro, do que recomendar um produto a alguém desconhecido. Por isso, os participantes deveriam recomendar 5 pro-

duto a cada amigo, enquanto era necessário recomendar apenas um produto para os desconhecidos.

Os testes de sensibilidade podem evidenciar outros valores que tornariam os dados mais confiáveis e o experimento mais simples ou complicado de se realizar.

Referências Bibliográficas

- [1] WEBER, L. *Marketing to the social web: how digital customer communities build your business*. [S.l.]: Wiley, 2007. 5 p.
- [2] FOWLER, M.; BECK, K. *Refactoring: improving the design of existing code*. [S.l.]: Addison-Wesley Professional, 1999.
- [3] GOLDBERG, D. et al. Using collaborative filtering to weave an information tapestry. *Commun. ACM*, ACM, New York, NY, USA, v. 35, n. 12, p. 61–70, 1992. ISSN 0001-0782.
- [4] RESNICK, P.; VARIAN, H. R. Recommender systems. *Commun. ACM*, ACM, New York, NY, USA, v. 40, n. 3, p. 56–58, 1997. ISSN 0001-0782.
- [5] HERLOCKER, J. L. et al. Evaluating collaborative filtering recommender systems. *ACM Trans. Inf. Syst.*, ACM, New York, NY, USA, v. 22, n. 1, p. 5–53, 2004. ISSN 1046-8188.
- [6] BALABANOVIĆ, M.; SHOHAM, Y. Fab: content-based, collaborative recommendation. *Commun. ACM*, ACM, New York, NY, USA, v. 40, n. 3, p. 66–72, 1997. ISSN 0001-0782.
- [7] MALONE, T. W. et al. Intelligent information-sharing systems. *Commun. ACM*, ACM, New York, NY, USA, v. 30, n. 5, p. 390–402, 1987. ISSN 0001-0782.
- [8] HILL, W. et al. Recommending evaluating choices in a virtual community of use. In: *CHI '95: Proceedings of the SIGCHI conference on Human factors in computing systems*. New York, NY, USA: ACM Press/Addison-Wesley Publishing Co., 1995. p. 194–201. ISBN 0-201-84705-1.
- [9] BREESE, J. S.; HECKERMAN, D.; KADIE, C. Empirical analysis of predictive algorithms for collaborative filtering. In: *Proceedings of the Fourteenth Conference on Uncertainty in Artificial Intelligence (UAI-98)*. San Francisco: Morgan Kaufmann, 1998. p. 43–52.
- [10] MASSA, P.; AVESANI, P. Trust-aware recommender systems. In: *RecSys '07: Proceedings of the 2007 ACM conference on Recommender systems*. New York, NY, USA: ACM, 2007. p. 17–24. ISBN 978-1-59593-730-8.
- [11] SARWAR, B. et al. Item-based collaborative filtering recommendation algorithms. In: *WWW '01: Proceedings of the 10th international conference on World Wide Web*. New York, NY, USA: ACM, 2001. p. 285–295. ISBN 1-58113-348-0.

- [12] SABATER, J.; SIERRA, C. REGRET: reputation in gregarious societies. In: ACM NEW YORK, NY, USA. *Proceedings of the fifth international conference on Autonomous agents*. [S.l.], 2001. p. 194–195.
- [13] BURKE, M.; MARLOW, C.; LENTO, T. Feed me: motivating newcomer contribution in social network sites. In: ACM NEW YORK, NY, USA. *Proceedings of the 27th international conference on Human factors in computing systems*. [S.l.], 2009. p. 945–954.
- [14] BONHARD, P.; SASSE, M.; HARRIES, C. "The devil you know knows best": how online recommendations can benefit from social networking. In: BRITISH COMPUTER SOCIETY SWINTON, UK, UK. *Proceedings of the 21st British CHI Group Annual Conference on HCI 2007: People and Computers XXI: HCI... but not as we know it-Volume 1*. [S.l.], 2007. p. 77–86.
- [15] BECK, K.; FOWLER, M. *Planning Extreme Programming*. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 2000. ISBN 0201710919.
- [16] BURBECK, S. *Applications Programming in Smalltalk-80: How to use Model-View-Controller (MVC)*. [S.l.]: Softsmarts, Inc., 1992.
- [17] RUBY, S.; THOMAS, D.; HANSSON, D. *Agile Web Development with Rails*. Pragmatic Bookshelf, 2009.
- [18] HUNT, A.; THOMAS, D. Don't Repeat Yourself. *The Pragmatic Programmer*.
- [19] BEMERS-LEE, T.; HENDLER, J.; LASSILA, O. The semantic web. *Scientific American*, v. 284, n. 5, p. 34–43, 2001.

Apêndice A

Resultados dos Testes de Hipótese

Os resultados abaixo mostram os valores que validam as hipóteses apresentadas na monografia. A hipótese H0 foi de que as duas distribuições eram semelhantes, sendo que os detalhes do enunciado da hipótese de cada teste dependem do tipo de teste em questão.

Os seguintes testes foram utilizados:

- T-Student ¹
- Mann-Whitney rank test ²
- Wilcoxon rank-sum test ³
- Kruskal-Wallis H-test ⁴

Estes testes foram escolhidos pois conseguem diferenciar duas distribuições e dizer se uma delas é significativamente diferente da outra em relação à média, mediana ou a outros parâmetros. Inicialmente apenas o T-Student seria utilizado, que é um teste paramétrico e necessita que a distribuição seja normal. Como não foi possível provar que a distribuição era normal, escolheu-se testes não-paramétricos que não possuíam este ou outros pré-requisitos que pudessem invalidar o teste.

Nota-se que todas as hipóteses H0 foram rejeitadas com um nível de significância de 10%, resultando na aceitação das hipóteses H1.

Os cálculos foram feitos utilizando o pacote para aplicações científicas SciPy ⁵.

¹ http://en.wikipedia.org/wiki/Student%27s_t-test

² http://en.wikipedia.org/wiki/Mann%E2%80%93Whitney_U_test

³ http://en.wikipedia.org/wiki/Mann-Whitney-Wilcoxon_test

⁴ http://en.wikipedia.org/wiki/Kruskal%E2%80%93Wallis_one-way_analysis_of_variance

⁵ <http://www.scipy.org/>

Tipo do teste	Valor da estatística	<i>p</i>
T-Student (t)	1.8483967257	0.0647589406833
Mann-Whitney rank test (u)	200627.5	0.0482826622258
Wilcoxon rank-sum test (z)	1.94675892865	0.0515636430578
Kruskal-Wallis H-test (H)	4.01357666489	0.0451353055176

Tabela A.1: TH1: Amigos recomendam melhor do que Desconhecidos (H1)

Tipo do teste	Valor da estatística	<i>p</i>
T-Student (t)	-10.0118428583	0.0
Mann-Whitney rank test (u)	242654.0	0.0
Wilcoxon rank-sum test (z)	-9.31352135363	0.0
Kruskal-Wallis H-test (H)	90.9919336849	1.44258997389e-21

Tabela A.2: TH2: Recomendações Diretas são melhores aceitas que RBC (H1)

Tipo do teste	Valor da estatística	<i>p</i>
T-Student (t)	3.69171586374	0.000234932528179
Mann-Whitney rank test (u)	107016.0	0.000473211777461
Wilcoxon rank-sum test (z)	3.44234121161	0.000576702325041
Kruskal-Wallis H-test (H)	12.5985026565	0.000386055903711

Tabela A.3: TH3: RBC é melhor aceito que RBP (H1)

Tipo do teste	Valor da estatística	<i>p</i>
T-Student (t)	-2.82659786947	0.00479944619232
Mann-Whitney rank test (u)	109738.5	0.00412473541347
Wilcoxon rank-sum test (z)	-2.83708585456	0.0045527367927
Kruskal-Wallis H-test (H)	8.41106668483	0.00372943777944

Tabela A.4: TH4: RBI é melhor que aceito que RBC (H1)

Apêndice B

Termo de Consentimento Livre e Esclarecido (TCLE)



Universidade de São Paulo
Escola Politécnica de Engenharia
Departamento de Computação e Sistemas Digitais

Convidamos o (a) Sr(a). para participar do experimento "Dionísio: um sistema de recomendação baseado em confiança", que tem como objetivo colher dados de avaliações de produtos através de sistemas de recomendação que utilizam redes sociais na Internet.

Sistemas de Recomendação sugerem às pessoas itens que elas possam gostar, baseados no comportamento prévio delas fazendo suposições sobre o tipo de produtos em que elas estão interessadas. Atualmente a Internet conta com uma quantidade de informação muito grande. A vantagem do uso de sistemas de recomendação para as pessoas é a facilidade de encontrar a informação, sem ter a árdua tarefa de procurá-la. Estamos estudando uma nova forma de se recomendar produtos para as pessoas com base em parâmetros de confiança extraídos de redes sociais. Denominamos esse novo sistema de recomendação como sistemas de recomendação baseados em confiança.

Pedimos a sua participação no experimento porque há a necessidade da utilização do sistema por pessoas, com informações reais, para que possamos verificar a eficiência do nosso sistema de recomendação e compará-lo com os já existentes. Dois dos algoritmos existentes que também serão utilizados no experimento levam em conta a similaridade de produtos e a similaridade entre os perfis das pessoas.

O experimento iniciará com um cadastro solicitando as informações pessoais básicas: nome, sexo, faixa etária e foto. Tais dados serão utilizados apenas para exposição no experimento. Caso não seja da sua vontade exibir a sua foto, qualquer outro arquivo de imagem que não contenha conteúdo ofensivo aos outros participantes poderá ser utilizado. Além disso, na etapa de cadastro você poderá criar o seu login e senha para acesso. Você será

inserido em um grupo contendo seus 4 amigos que também participam do experimento. O sistema contém informações de produtos extraídos do site www.submarino.com.

Após o cadastro você deverá avaliar 30 produtos, 20 escolhidos pelo sistema e 10 a seu gosto, em uma escala de 1 (não tenho interesse neste produto) a 5 (tenho muito interesse neste produto). Esta avaliação não significa necessariamente um interesse de compra do produto, ou se você já o possui ou não. Nós queremos apenas saber se este produto lhe é interessante.

Caso não o conheça, haverá a opção "Não conheço" disponível. Porém na avaliação você deverá informar se o produto lhe despertou o interesse ou não. O objetivo dessa etapa é obter informações sobre os seus interesses em relação a produtos. O sistema de recomendação precisa dessas informações para indicar produtos que provavelmente irão lhe interessar.

Depois será solicitado que você faça recomendações de produtos a seus amigos e a pessoas presentes na rede que não fazem parte da sua equipe. Após todos os participantes terminarem esta etapa, serão mostradas recomendações de produtos feitas a você tanto por outros participantes quanto pelo sistema. Você também deverá avaliar esses produtos.

Lembre-se que não estamos avaliando você e sim o sistema de recomendação. Todos os dados inseridos no sistema serão analisados apenas estatisticamente. Apenas um número de identificação gerado aleatoriamente pelo sistema estará relacionado aos seus dados. Não será possível aos pesquisadores identificá-lo a partir dos dados das avaliações de produtos.

Guardaremos seus dados por pelo menos 2 (dois) anos.

Você poderá pedir informações sobre a pesquisa a qualquer momento, durante e após a sua participação. Os endereços e telefones de contato com os pesquisadores da Escola Politécnica estão no fim desta carta.

Finalmente, ressaltamos que sua participação é voluntária e que você não irá receber nenhuma remuneração ou prêmio pela sua participação.

Se você concordar em participar, solicitamos a assinatura no termo em anexo.

Agradecemos pela sua atenção!

Atenciosamente,

Jaime Simão Sichman

Coordenador da pesquisa

Para esclarecimento de dúvidas:

Allan Douglas R. de Oliveira

E-mail: allandouglas@gmail.com

Leonardo Nicacio Bessa

E-mail: leobessa@gmail.com

Thiago Rodrigues Andrade

E-mail: thiago.rodrigues.andrade@gmail.com

Jaime Simão Sichman

Escola Politécnica da Universidade de São Paulo

Avenida Professor Luciano Gualberto, travessa 3, n. 158

05508-900 – São Paulo – SP

Tel.: (11) 3091-5397

E-mail: jaime.sichman@poli.usp.br

Lucia Filgueiras

Escola Politécnica da Universidade de São Paulo

Avenida Professor Luciano Gualberto, travessa 3, n. 158

05508-900 – São Paulo – SP

Tel.: (11) 3091-5200

E-mail: lucia.filgueiras@poli.usp.br

TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO

Eu _____, RG _____

declaro que concordo em participar do experimento "Dionísio: um sistema de recomendação baseado em confiança".

Fui informado(a) sobre os detalhes da pesquisa conforme a carta anexa.

Eu entendo que os dados que eu inserir no sistema estarão disponíveis ao término do experimento sem nenhuma referência ao meu nome ou fotografia, sendo relacionado apenas a um número de identificação gerado aleatoriamente pelo sistema.

Entendo que posso desistir de participar das atividades quando quiser.

Entendo que meu nome verdadeiro ou fotografia não vão aparecer nos relatórios e trabalhos publicados sobre a pesquisa.

Entendo que não vou nenhum tipo de remuneração por participar desta pesquisa.

Declaro que, após convenientemente esclarecido pelo pesquisador e tendo entendido o que me foi explicado, consinto em participar do presente experimento.

Assinatura do pesquisador

Assinatura do participante

Nome do pesquisador

Data

Apêndice C

Instruções Fornecidas aos Participantes

Este apêndice apresenta todas as instruções fornecidas aos participantes do experimento. As instruções estão organizadas de acordo com a ordem que foram apresentadas, ou seja, de acordo com a etapa na qual estavam presentes.

Etapa 1

- Olá, <nome do usuário>! Esta é a **primeira etapa** do nosso experimento de 6 etapas. Abaixo estão listados 20 produtos que você deverá avaliar de acordo com o seu interesse neles. Ressaltamos que este interesse não é apenas um interesse de compra do produto, mas se você acha o produto interessante ou não.
- Não ignore as mensagens de popup. Elas lhe questionam se você já ouviu falar do produto avaliado.
- Após avaliar todos os 20 produtos, a etapa 2 será carregada automaticamente. Para sua facilidade, um contador de quantos produtos já foram avaliados encontra-se no topo dessa página.

Etapa 2

- Olá, <nome do usuário>! Esta é a **segunda etapa** do nosso experimento de 6 etapas. Abaixo está disponível uma busca de produtos cadastrados no sistema.
- **Você deverá procurar 10 produtos ao seu gosto e avaliá-los na mesma forma da etapa 1**, ou seja, de acordo com o seu nível de interesse neles.
- Busque os produtos por nome e opcionalmente também por categoria
- **Após avaliar todos os 10 produtos ao seu gosto, a etapa 3 será carregada automaticamente.** Para sua facilidade, um contador de quantos produtos já foram avaliados encontra-se no topo dessa página.

Etapa 3

- Olá, <nome do usuário>! Esta é a **terceira etapa** do nosso experimento de 6 etapas.
- **Abaixo estão listados os amigos do seu grupo. Você deverá recomendar 5 produtos a cada um deles.**
- Uma boa recomendação consiste em recomendar produtos que seus amigos tenham muito interesse e que não sejam óbvios a eles.
- Para realizar as recomendações para um amigo, **escolha um deles abaixo.**

Etapa 4

- Olá, <nome do usuário>! Esta é a **quarta etapa** do nosso experimento de 6 etapas.
- Abaixo estão listadas algumas pessoas cadastradas no sistema que não fazem parte do seu grupo.
- **Você deverá recomendar um produto a cada um deles.**
- Uma boa recomendação consiste em recomendar produtos que as pessoas tenham muito interesse e que não sejam óbvios a eles.
- Para realizar a recomendação a uma pessoa, escolha uma delas abaixo.

Etapa 5

- Olá, <nome do usuário>! Esta é a **quinta etapa** do nosso experimento de 6 etapas.
- Abaixo estão listados produtos recomendados a você.
- Não esqueça de informar se você conhece ou não o produto

Etapa 6

- Olá, <nome do usuário>! Esta é a **última etapa** do nosso experimento. Abaixo estão listados produtos recomendados a você. Na lista há recomendações realizadas pelo sistema e também tanto por pessoas do seu grupo quanto por outras de outros grupos. Você deverá avaliar estes produtos de acordo com o seu grau de interesse, assim como fez nas primeiras etapas deste experimento.