

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
INSTITUTO DE INFORMÁTICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO

ALESSANDRO DA SILVEIRA DIAS

**Aumentando a Acurácia de Predição de Avaliação  
de Sistemas de Recomendação de Vídeo  
com o Uso de Pontos de Interesse**

Dissertação apresentada como requisito parcial  
para a obtenção do grau de Mestre em Ciência  
da Computação

Prof. Dr. Leandro Krug Wives  
Orientador

Prof. Dr. Valter Roesler  
Coorientador

Porto Alegre, fevereiro de 2013.

## CIP – CATALOGAÇÃO NA PUBLICAÇÃO

Dias, Alessandro da Silveira

Aumentando a Acurácia de Predição de Avaliação de Sistemas de Recomendação de Vídeo com o Uso de Pontos de Interesse / Alessandro da Silveira Dias. – Porto Alegre: PPGC da UFRGS, 2013.

79 f.:il.

Orientador: Leandro Krug Wives; Coorientador: Valter Roesler.

Dissertação (mestrado) – Universidade Federal do Rio Grande do Sul. Programa de Pós-Graduação em Computação. Porto Alegre, BR – RS, 2013.

1.Sistema de Recomendação de Vídeo. 2.Pontos de Interesse  
3.Acurácia de Predição de Avaliação em Recomendação. I. Wives, Leandro Krug. II. Roesler, Valter. III. Título.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Reitor: Prof. Carlos Alexandre Netto

Vice-Reitor: Prof. Rui Vicente Oppermann

Pró-Reitor de Pós-Graduação: Prof. Aldo Bolten Lucion

Diretor do Instituto de Informática: Prof. Luis da Cunha Lamb

Coordenador do PPGC: Prof. Luigi Carro

Bibliotecária-Chefe do Instituto de Informática: Beatriz Regina Bastos Haro

## Agradecimentos

Agradeço a minha **Família** por me apoiar em todas as escolhas que eu fiz na vida. À minha **Mãe** e ao meu **Pai** a minha eterna gratidão.

Especial agradecimento ao meu orientador Prof. Dr. **Leandro Krug Wives** e ao meu coorientador Prof. Dr. **Valter Roesler** pela orientação, dedicação, crítica e incentivo.

Agradecimentos ao **Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq** pelo apoio à minha pesquisa, o que resultou no presente trabalho.

Agradecimentos à **Secretaria de Desenvolvimento Tecnológico - SEDETEC** da Universidade Federal do Rio Grande do Sul pelo apoio nas áreas de registro de software e patenteamento.

Agradeço a todos que de certa forma colaboraram para a realização deste trabalho.

# SUMÁRIO

<b>LISTA DE ABREVIATURAS E SIGLAS</b> .....	<b>6</b>
<b>LISTA DE FIGURAS</b> .....	<b>7</b>
<b>LISTA DE TABELAS</b> .....	<b>8</b>
<b>RESUMO</b> .....	<b>9</b>
<b>ABSTRACT</b> .....	<b>10</b>
<b>1 INTRODUÇÃO</b> .....	<b>11</b>
1.1 Motivação.....	12
1.2 Objetivos .....	13
1.3 Hipótese.....	13
1.4 Contribuições.....	13
1.5 Organização do Texto .....	14
<b>2 FUNDAMENTAÇÃO TEÓRICA</b> .....	<b>15</b>
2.1 Introdução.....	15
2.2 Importância e Principais Aplicações.....	16
2.3 Formalização de Recomendação .....	16
2.4 Grau de Personalização .....	17
2.5 Perfil de Usuário.....	17
2.6 Técnicas de Recomendação .....	18
2.7 Recomendação baseada em Filtragem Colaborativa a partir de Correlação .....	20
2.8 Exemplos de Sistemas de Recomendação.....	22
2.9 Uma nova Geração de Sistemas de Recomendação .....	26

<b>3</b>	<b>TRABALHOS RELACIONADOS .....</b>	<b>27</b>
3.1	Abordagens relacionadas para melhorar sistemas de recomendação de vídeo.....	27
3.2	Abordagens relacionadas para melhorar sistemas de recomendação de vídeo com o uso de pontos de interesse .....	32
<b>4</b>	<b>A ABORDAGEM PROPOSTA .....</b>	<b>38</b>
4.1	Exemplo Introdutório .....	38
4.2	Definição Formal de Domínio.....	40
4.3	Similaridade entre Usuários Baseada em Pontos de Interesse .....	41
4.4	Aumentado a Acurácia de Predição de Avaliação de um Sistema de Recomendação com POI .....	42
4.5	Marcando POI .....	43
4.6	Comparação da Abordagem Proposta com Outras Abordagens .....	44
<b>5</b>	<b>O AMBIENTE IMPLEMENTADO .....</b>	<b>45</b>
5.1	Tela Inicial .....	46
5.2	Cadastro de Usuário.....	47
5.3	Galeria de Vídeos.....	47
5.4	Tela de Vídeo .....	48
5.5	Sistema de Recomendação Desenvolvido .....	51
5.6	Função de Utilidade Baseada em Pontos de Interesse.....	54
<b>6</b>	<b>AVALIAÇÃO EXPERIMENTAL .....</b>	<b>56</b>
6.1	Preparação dos Experimentos.....	56
6.2	Protocolo Experimental .....	57
6.3	Experimentos Realizados.....	60
6.4	Artefatos dos Experimentos.....	66
<b>7</b>	<b>CONCLUSÕES .....</b>	<b>67</b>
7.1	Trabalhos Futuros.....	68
	<b>REFERÊNCIAS.....</b>	<b>71</b>
	<b>APÊNDICE A – A MODELAGEM DO AMBIENTE IMPLEMENTADO .....</b>	<b>76</b>

## LISTA DE ABREVIATURAS E SIGLAS

AJAX	<i>Asynchronous JavaScript and XML</i>
API	<i>Application Programming Interface</i>
DVD	<i>Digital Versatile Disc</i>
CD	<i>Compact Disc</i>
HTML	<i>HyperText Markup Language</i>
IDE	<i>Integrated Development Environment</i>
IHC	Interação Humano-Computador
MVC	<i>Model View Controller</i>
POI	<i>Point of Interest</i>
PLN	Processamento de Linguagem Natural
PVR	<i>Personal Video Recorder</i>
RMSE	<i>Root Mean Square Error</i>
UFRGS	Universidade Federal do Rio Grande do Sul
URL	<i>Uniform Resource Locator</i>
VOD	<i>Video On Demand</i>
YRN	<i>YouTube Recommender Network</i>

## LISTA DE FIGURAS

Figura 2.1: Exemplo de recomendação baseada em conteúdo no site da Amazon .....	23
Figura 2.2: Recomendação de filme no site da Netflix .....	23
Figura 2.3: Tela inicial do Entree.....	24
Figura 2.4: Tela de recomendação de restaurante .....	25
Figura 2.5: Interface do Pandora.....	25
Figura 3.1: O mecanismo de busca automatizada e recomendação do CurioView.....	29
Figura 3.2: Tela do CurioView sendo executado num browser Web.....	29
Figura 3.3: YRN dos dados utilizados na apresentação da proposta.....	31
Figura 3.4: Um subgráfico da YRN .....	32
Figura 3.5: Uma visão parcial da sala virtual do CollaboraTV .....	34
Figura 3.6: Um conjunto discreto de pontos de interesse utilizados para forma um perfil de interesse.....	34
Figura 3.7: Demarcação de cenas interessantes para um usuário em um vídeo .....	36
Figura 3.8: Cenas de um "pré cursor" gerado para recomendação de vídeo a um usuário .....	36
Figura 4.1: POI marcados por um usuário em um vídeo.....	38
Figura 4.2: POI de usuários e suas intersecções mostrando interesses em comum. ....	39
Figura 4.3: POI de usuários em diferentes vídeos.....	40
Figura 4.4: Modelo de um componente de filtragem colaborativa pura sob ação da função de utilidade baseada em pontos de interesse .....	42
Figura 5.1: Arquitetura de referência do protótipo.....	45
Figura 5.2: Tela inicial do protótipo.....	47
Figura 5.3. Tela de cadastro de usuário.....	48
Figura 5.4: Tela de galeria de vídeos .....	49
Figura 5.5: Tela de visualização de vídeo .....	49
Figura 5.6: Abordagem de marcação de pontos de interesse através de botões.....	50
Figura 5.7: Abordagem de marcação de pontos de interesse através de cursores em <i>slider</i> .....	50
Figura 5.8: Diagrama de componentes do sistema de recomendação do protótipo .....	51
Figura 5.9: Processo de predição pelo componente de filtragem baseada em conteúdo.....	53
Figura 6.1: Um exemplo de partição de dataset histórico de avaliações de vídeo separado para treino e teste de modelo sendo utilizando para predição de avaliações .....	59
Figura 6.2: Erro do sistema à medida que varia o tamanho mínimo da vizinhança.....	61
Figura 6.3: Erro do sistema sem e com o uso da função de utilidade baseada em pontos de interesse.....	63
Figura 6.4: Erro do sistema em cada uma das 3 turmas isoladamente. ....	64
Figura 6.5: Erro do sistema à medida que o <i>dataset</i> cresceu. ....	64

## LISTA DE TABELAS

Tabela 2.1: Técnicas utilizadas em sistemas de recomendação .....	20
Tabela 4.1: Limiares propostos para a função de utilidade e regras para definição de seus valores .....	41
Tabela 5.1: Exemplos de valores aceitáveis para os limiares propostos para a função de utilidade .....	54
Tabela 6.1: Separação randômica do dataset em dados para ajuste de parâmetros e dados para treinamento e teste de modelo de predição .....	60
Tabela 6.2. Valores de parâmetros da função de utilidade acompanhados de seus valores de erro RMSE .....	61



## RESUMO

A cada dia aumenta o número de vídeos disponíveis no mundo. Por exemplo, há uma vasta quantidade de sites de vídeos disponíveis na Web e serviços de Vídeo Sob Demanda além de dispositivos que fazem a gravação de vídeos automaticamente, conhecidos como *Personal Video Recorders*, 24 horas por dia. Isso pode ocasionar um problema ao usuário: a sobrecarga de conteúdo em formato de vídeo. Uma das maneiras de se tratar tal problema consiste no uso de sistemas de recomendação, os quais filtram o conteúdo com o objetivo de entregar o que for mais interessante ao usuário. A abordagem típica utilizada pelos sistemas atuais consiste em um sistema de recomendação híbrido, i.e., que utiliza tanto filtragem baseada em conteúdo quanto filtragem colaborativa, minimizando os problemas que tais abordagens possuem individualmente. Adicionalmente, com o objetivo de melhorar a recomendação ou de criar novas formas de recomendação, têm sido apresentadas novas abordagens, tais como sistemas de recomendação utilizando dados de redes sociais, computação afetiva, *tags*, entre outros. Este trabalho tem como objetivo apresentar uma abordagem inovadora, a qual utiliza pontos de interesse em vídeo de usuários (ou seja, os segmentos dos vídeos que eles mais gostam ou que mais se interessam) para melhorar a acurácia de predição de sistemas de recomendação de vídeo que utilizam filtragem colaborativa baseados na abordagem usuário-usuário. Na abordagem proposta, os usuários participam de forma mais ativa e mais interativa ao marcarem seus pontos de interesse. Para avaliação de tal abordagem proposta foi realizada uma avaliação experimental em termos de acurácia de predição de avaliação; pela qual constatou-se que houve melhora na predição de avaliação do sistema de recomendação. Tal melhora está diretamente relacionada com o nível de participação das pessoas na marcação de pontos de interesse.

**Palavras-Chave:** Sistema de Recomendação de Vídeo, Sistema de Recomendação, Pontos de Interesse.

# Enhancing the Predictions Accuracy of POI Video Recommender Systems

## ABSTRACT

Every day the number of videos available in the world increases. For example, there is a vast amount of video sites available on the Web, Video On Demand services, as well as devices that records videos automatically, known as Personal Video Recorders, 24 hours a day. It may create a problem for the user: the overload of content in video format. One of the ways to treat such problem is the use of recommender systems, which filter the content in order to deliver what is most interesting to the user. The typical approach is to present a hybrid recommender system, i.e., that uses both content-based filtering and collaborative filtering, minimizing the problems that these approaches have individually. Additionally, in order to improve the recommendation or to create new approaches of recommendation, has been given new approaches such as systems using data from social networks, affective computing, tags, etc. This paper aims to present an innovative approach, which uses points of interest (POI) in video of users (i.e., video segments best liked or most interested by them) to augment the prediction accuracy of video recommender systems with collaborative filtering based in the user-user approach. In the proposed approach, users participate more actively and more interactively to mark their points of interest. To evaluate this proposed approach an experimental evaluation was performed in terms of accuracy of ratings predictions; in which it was verified that there was an improvement in ratings prediction accuracy of the recommendation system. This improvement is directly related to the level of participation of people in marking points of interest.

**Keywords:** Video Recommender System, Recommender System, Points of Interest.

# 1 INTRODUÇÃO

A cada dia aumenta o número de vídeos disponíveis no mundo. Por exemplo, há uma vasta quantidade de sites de vídeos disponíveis na Web (p.ex., youtube.com, dailymotion.com, metacafe.com, vimeo.com, etc.) e serviços de VOD (*Video On Demand*) (p.ex., HBO Go<sup>1</sup>, Telecine Play<sup>2</sup>, Netflix<sup>3</sup>, etc.), além de dispositivos que fazem a gravação de vídeos automaticamente, conhecidos como PVR (*Personal Video Recorders*), 24 horas por dia.

Por exemplo, o site líder em compartilhamento de vídeo *online*, o YouTube, permite às pessoas fazerem facilmente *upload* e compartilhamento de vídeo através de sites, dispositivos móveis e e-mails. As pessoas globalmente assistem centenas de milhões de vídeos por dia no YouTube e fazem *upload* de centenas de milhares de vídeos. Em 2010, diariamente foram adicionadas 48 horas de vídeo ao site a cada minuto (GOOGLE, 2011).

Isso pode ocasionar um problema ao usuário: a sobrecarga de conteúdo em formato de vídeo. Uma das maneiras de se tratar tal problema consiste no uso de sistemas de recomendação, os quais filtram o conteúdo com o objetivo de entregar o que for mais interessante ao usuário.

A abordagem típica utilizada pelos sistemas atuais consiste em um sistema de recomendação híbrido, i.e., que utiliza tanto filtragem baseada em conteúdo<sup>4</sup> quanto colaborativa<sup>5</sup>, minimizando os problemas que tais abordagens possuem individualmente. Adicionalmente, com o objetivo de melhorar a recomendação, têm sido apresentadas novas abordagens, tais como a utilização de informações de contexto (NAUDET, 2008), de informações emocionais do usuário (OLIVEIRA, 2011), de informações de redes sociais (STEWART, 2009), anotações de conteúdo com *tags* (PARK, 2011), entre outras. Essas novas abordagens buscam criar novas formas de recomendação ou estender a abordagem típica a fim de apoiar tipos mais complexos de sistemas de recomendação.

Na área de recomendação de vídeo, recentemente, têm sido apresentadas algumas pesquisas com base em anotação de pontos de interesse em vídeo. Através da anotação

---

<sup>1</sup> <http://www.hbogo.com.br/>.

<sup>2</sup> <http://telecineplay.com.br/>.

<sup>3</sup> <https://www.netflix.com/>.

<sup>4</sup> Pela filtragem baseada em conteúdo, ao usuário são recomendados itens que foram escolhidos por outros usuários, semelhantes a ele, no passado (BALABANOVIC; SHOHAM, 1997).

<sup>5</sup> Pela filtragem colaborativa, ao usuário são recomendados itens que outras pessoas com gostos semelhantes aos dele preferiram ou gostaram no passado (BALABANOVIC; SHOHAM, 1997).

de pontos de interesse o usuário pode marcar pontos no vídeo que são mais interessantes para ele. Tal abordagem não tem sido muito explorada; durante a pesquisa que originou este trabalho foram encontrados apenas dois trabalhos que abordam o uso de pontos de interesse em sistemas de recomendação de vídeo. Esses trabalhos são apresentados e analisados neste trabalho. O primeiro deles, Nathan et al. (2008), apenas sugere como pontos de interesse poderiam ser utilizados para trazer melhorias a sistemas de recomendação, o segundo, Chakoo; Gupta; Hiremath (2008), utiliza de fato pontos de interesse, porém para montar uma "recomendação visual de vídeo" adicional, após a recomendação típica de vídeo já ter sido gerada.

Nesse contexto, este trabalho apresenta uma abordagem inovadora para aumentar a acurácia de predição de avaliação de sistemas de recomendação de vídeo com o uso de pontos de interesse. Tal abordagem leva em conta que o usuário tende a gostar mais de determinados segmentos de vídeo do que do restante. Esses segmentos, chamados de Pontos de Interesse (POI - *Points of Interest*), são utilizados para encontrar usuários com interesses similares ou gosto em comum em relação a vídeo. Quando um par de usuários tem uma quantidade de intersecções de pontos de interesse acima de certo limiar em um vídeo e esse padrão se repete em um conjunto de vídeos considera-se que esses usuários são similares. O grau dessa similaridade é calculado por uma função de utilidade<sup>6</sup> que se baseia nessas intersecções de pontos de interesse. Tal função é utilizada para melhorar a acurácia de predição de avaliação de sistemas de recomendação que utilizam filtragem colaborativa baseando-se numa abordagem usuário-usuário<sup>7</sup>; e pode ser utilizada tanto em sistemas novos como em sistemas existentes e em operação, e em diferentes ambientes com recomendação, tais como, sites de vídeo, sistemas VOD e PVR.

Para avaliar tal proposta, foi desenvolvido um protótipo e com a ajuda dele foi realizada uma avaliação experimental em termos de acurácia de predição de avaliação; pela qual se constatou que houve melhora no sistema de recomendação. Tal melhora está diretamente relacionada com o nível de participação das pessoas na marcação de pontos de interesse. Vantagens e limitações da proposta foram encontradas e são apresentadas no capítulo de conclusão deste trabalho.

O protótipo utilizado na avaliação experimental deste trabalho encontra-se em fase de registro de software e recebeu o nome *PredilectUs POI Video Recommender*. Pretende-se patentear o processo desenvolvido para aumentar a acurácia de predição de avaliação de sistemas de recomendação de vídeo com o uso de pontos de interesse. Tal processo será documentalmente especificado com base em trechos de texto deste trabalho.

## 1.1 Motivação

Conforme citado previamente, existem poucos trabalhos na área de recomendação de vídeo que abordam o uso de pontos de interesse. Porém, nenhum deles foca na

---

<sup>6</sup> Uma função de utilidade pode ser generalizada como uma função matemática que faz o mapeamento entre um conjunto de entrada e um conjunto de saída de forma a selecionar o melhor elemento do conjunto de saída a partir de um ou mais elementos do conjunto de entrada e cujo objetivo é trazer maximização de resultados ou otimização a o que faz uso de tal função.

<sup>7</sup> A ideia principal na abordagem usuário-usuário é computar predições de recomendação utilizando a similaridade entre usuários. Existe outra abordagem, a abordagem item-item, na qual a ideia principal é computar predições de recomendações utilizando a similaridade entre itens (JANNACH et al., 2010).

recomendação típica, ou seja, na recomendação de itens, que neste caso são vídeos. Logo, a principal motivação deste trabalho é o desenvolvimento de uma abordagem que utilize de fato pontos de interesse para aumentar a acurácia de predição de avaliação de sistemas de recomendação típica de vídeo.

## 1.2 Objetivos

O objetivo principal deste trabalho é verificar se pontos de interesse podem ser utilizados para melhorar a acurácia de predição de avaliação de sistemas de recomendação de vídeo.

Os objetivos secundários consistem em verificar se pontos de interesse podem ser utilizados para encontrar usuários similares, ou seja, com interesses em comum ou gosto similar em relação a vídeo, e a partir disso criar um mecanismo de recomendação de vídeo que faça uso de pontos de interesse e cuja acurácia de predição de avaliação seja maior do que a acurácia de predição de avaliação de sistemas existentes.

## 1.3 Hipótese

Os pontos de interesse de um usuário em um vídeo podem ter intersecções com os pontos de interesse de outro usuário ou de outros usuários. Quando o número de intersecções dentro de um único vídeo exceder certo limiar, e isso se repetir em vários vídeos, suspeita-se que esses usuários têm interesses similares ou gosto em comum em relação a vídeos. Diante dessa possibilidade, a seguinte hipótese foi lançada e validada neste trabalho: "pontos de interesse podem ser utilizados para encontrar pessoas similares, ou seja, que possuem interesses similares ou gosto em comum em relação a vídeos; e essa similaridade pode ser utilizada para aumentar a acurácia de predição de avaliação de um sistema de recomendação de vídeo".

## 1.4 Contribuições

Este trabalho mostra que é possível aumentar a acurácia de predição de sistemas de recomendação de vídeo que utilizam filtragem colaborativa a partir da abordagem usuário-usuário com o uso de pontos de interesse. Tal aumento foi avaliado experimentalmente em termos de acurácia de predição de avaliação, ou seja, avaliar a acurácia do sistema ao predizer a avaliação do usuário, e constatou-se que houve melhora no sistema de recomendação.

Para realizar esse aumento de acurácia de predição de avaliação é apresentada uma abordagem que utiliza como base uma função de utilidade baseada em pontos de interesse. Essa função de utilidade é definida formalmente e a especificação de sua interface permite que possa ser implementada utilizando-se diferentes técnicas. Este trabalho apresenta e utiliza uma técnica e sugere outras três.

Além disso, é apresentada a definição formal de domínio que descreve o ambiente de um sistema de recomendação de vídeo com predição de acurácia aumentada com o uso de pontos de interesse e como utilizar tal função de utilidade na filtragem colaborativa. Tal definição permite que a função de utilidade seja utilizada tanto em sistemas novos quanto em sistemas existentes e em operação, e em diferentes ambientes com recomendação, tais como, sites de vídeo, sistemas VOD e PVR.

Para a marcação de pontos de interesse são propostas duas abordagens, e apresentadas as vantagens e desvantagens de cada uma, o que ajuda na hora de escolher uma abordagem de marcação para utilização.

Os artefatos desenvolvidos durante este trabalho (protocolo experimental, dois catálogos de vídeo - montados com o uso de um *crawler*, protótipo e *dataset* histórico - montado a partir do uso do protótipo por voluntários durante o experimento) serão disponibilizados para pesquisas futuras, assim que questões de licenciamento de software tiverem sido definidas.

## **1.5 Organização do Texto**

Este trabalho está organizado da seguinte forma. O Capítulo 2 apresenta a fundamentação teórica de sistemas de recomendação e apresenta exemplos desses sistemas. O Capítulo 3 apresenta trabalhos existentes relacionados a este trabalho. O Capítulo 4 apresenta a abordagem proposta para aumentar a acurácia de predição de avaliação de sistemas de recomendação de vídeo que utilizam filtragem colaborativa com o uso de pontos de interesse. O Capítulo 5 apresenta o protótipo implementado para validação da abordagem proposta. O Capítulo 6 apresenta a avaliação experimental da abordagem proposta. Por fim, no Capítulo 7 são apresentadas as considerações finais, sendo também discutidos aspectos relacionados à sua continuidade.

## 2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta conceitos relacionados com sistemas de recomendação e exemplos de como tais sistemas são utilizados.

### 2.1 Introdução

A informação tornou-se disponível de maneira rápida, barata e disseminada com a evolução da informática e das telecomunicações (DELGADO; FILHO, 2003). Nesse contexto, as pessoas se deparam, muitas vezes, com um excesso de informação e com uma diversidade muito grande de opções. Muitas vezes um indivíduo possui pouca ou quase nenhuma experiência pessoal para realizar escolhas entre as várias alternativas que lhe são apresentadas. A questão relevante neste momento refere-se a como proceder nesses casos. Para minimizar as dúvidas e necessidades que se tem frente à escolha entre alternativas, geralmente confia-se nas recomendações que são passadas por outras pessoas, as quais podem chegar de forma direta (boca-a-boca) (MAES; SHARDANAND, 1995) ou por cartas de recomendação, opiniões de especialistas, sites e jornais com boa reputação, entre outros.

Com objetivo de ajudar as pessoas a lidar com a sobrecarga de informação foi criado no início dos anos 1990 o sistema Tapestry, o primeiro sistema de filtragem colaborativa de informação (GOLDBERG; OKI; TERRY, 1992). Seus proponentes criaram a expressão “Filtragem Colaborativa” visando designar um tipo de sistema específico no qual a filtragem da informação era realizada com o auxílio humano, ou seja, através da colaboração entre os grupos interessados. Vários pesquisadores acabaram adotando essa terminologia para denominar qualquer tipo de sistema com esse objetivo, subsequentemente. Resnick et al. (1994) defenderam o termo “sistemas de recomendação” como terminologia mais genérica do que “filtragem colaborativa”, já que sistemas de recomendação podem existir sem nenhuma colaboração entre as pessoas. Depois, Resnick; Varian (1997) ampliam o termo Sistema de Recomendação para descrever qualquer sistema que produza recomendações individualizadas como produto ou que tem o efeito de orientar o usuário de forma personalizada para itens interessantes ou úteis em um grande espaço de opções possíveis.

Atualmente, com a proliferação do comércio eletrônico na Internet, os sistemas de recomendação transformaram-se em uma poderosa ferramenta de negócio (conforme pode ser observado na próxima seção), que, além de aumentar a capacidade do consumidor em superar a sobrecarga de informação (opções de produtos à venda), sugere itens de interesse aumentando, assim, o volume de negócios.

## 2.2 Importância e Principais Aplicações

Os sistemas de recomendação são amplamente estudados e aplicados na academia e na indústria. Exemplos de tais aplicações incluem recomendações de livros, CDs e outros produtos na Amazon<sup>8</sup>, filmes, no MovieLens<sup>9</sup>, notícias, no Google News<sup>10</sup>, atrações turísticas (ARDISSONO, 2003), restaurantes (BURKE, 2002), músicas (YOOSHIL, 2008), publicações científicas, no Bibsonomy<sup>11</sup>, e páginas da Web (LIEBERMAN; FRY; WEITZMAN, 2001). As empresas desses sistemas na indústria, e muitas outras, incorporaram aspectos de recomendação para incrementar o volume de negócios.

Segundo Adamavicius; Tuzhilin (2005), a área de pesquisa de sistemas de recomendação é de extremo interesse, pois é uma área de “problemas ricos”, e pela abundância de aplicações práticas em que pode ser encaixada, ajudando os usuários em ambiente de sobrecarga de informação e provendo recomendações, muitas vezes, personalizadas.

## 2.3 Formalização de Recomendação

Adamavicius; Tuzhilin (2005) apresentam a formalização de recomendação, como segue:

Formalmente, recomendação pode ser formulada como segue: seja  $C$  o conjunto de todos os usuários, e seja  $S$  o conjunto de todos os possíveis itens que podem ser recomendados, tais como livros, filmes, restaurantes. O espaço  $S$  de possíveis itens pode ser muito amplo, que vai de centenas de milhares ou mesmo milhões de itens em algumas aplicações, tais como as de recomendações de livros e CDs. Da mesma forma, o espaço de usuários pode ser também muito amplo, milhões em alguns casos. Seja  $u$  a função utilidade que mede o quão útil é um determinado item  $s$  para um determinado usuário  $c$ , i.e.,  $u: C \times S \rightarrow R$ , onde  $R$  é um conjunto totalmente ordenado (por exemplo, números inteiros não negativos ou números reais dentro de certo intervalo). Então, para cada usuário  $c \in C$ , procura-se um item  $s' \in S$  que maximiza a utilidade ao usuário. Mais formalmente:

$$\forall c \in C, s'_c = \arg \max_{s \in S} u(c, s)$$

Em sistemas de recomendação, a utilidade de um item é geralmente representada por uma avaliação que indica o quanto um determinado usuário gosta de um item (por exemplo, John Doe deu ao filme "Harry Potter" a nota 7, numa faixa de 0 a 10). A função de utilidade  $u$  pode ser uma função arbitrária. Ao especificar uma função de utilidade, pode-se usar vários métodos e várias heurísticas, como o vizinho mais próximo, árvores de decisão, métodos *spline*, funções de base radial, regressões, redes neurais e métodos de aprendizagem relacional.

Cada elemento do espaço de usuários  $C$  pode ser definido através de um "perfil" que inclui várias características do usuário, como a sua idade, sexo, estado civil, renda, etc. No caso mais simples, o "perfil" pode conter um único elemento como ID do usuário. Da mesma forma, cada item do espaço  $S$  pode ser definido por um conjunto de características. Por exemplo, em uma

---

<sup>8</sup> <http://www.amazon.com/>.

<sup>9</sup> <http://www.movielens.com/>.

<sup>10</sup> <http://news.google.com/>.

<sup>11</sup> <http://www.bibsonomy.org/>.



aplicação de recomendação de filmes, na qual  $S$  é a coleção de filmes, cada filme pode ser representado não apenas pelo seu ID, mas também pelo seu título, gênero, diretor, ano de lançamento, atores principais, etc.

O problema central dos sistemas de recomendação reside no fato da função de utilidade  $u$  geralmente não ser definida em todo o espaço  $C \times S$ , mas apenas em um subconjunto desse. Isso significa que  $u$  precisa ser extrapolado para todo o espaço  $C \times S$ . Geralmente, em sistemas de recomendação, a utilidade é definida através de avaliações, e essas são definidas apenas nos itens previamente avaliados pelos usuários. Desse modo, o algoritmo de recomendação deve ser capaz de estimar (predizer) as avaliações não realizadas para os pares de usuário-item e de fazer recomendações apropriadas baseadas nessas predições.

A extrapolação de avaliações conhecidas para avaliações inexistentes é geralmente feita por: 1) especificação de heurísticas que definem a função de utilidade e validam empiricamente sua performance, e 2) pelas estimativas da função de utilidade através da otimização de algum critério de performance como o erro médio quadrado. Um a vez que as avaliações desconhecidas são estimadas, o sistema de recomendação seleciona aquelas com maiores avaliações para serem recomendadas, de acordo com (1). Alternativamente, podem ser recomendados os  $N$  melhores itens ao usuário, ou um conjunto de usuários a um item.

A predição de avaliações de itens ainda não avaliados pode ser feita de diferentes formas, utilizando métodos de aprendizado de máquina, teorias de aproximação e vários tipos de heurística (ADAMAVICIUS; TUZHILIN, 2005, p. 735, tradução nossa).

## 2.4 Grau de Personalização

Sistemas de recomendação podem produzir recomendações considerando diferentes graus de personalização. O grau de personalização engloba vários fatores, incluindo tanto a acurácia e a utilidade das recomendações. Como a personalização tem várias dimensões, Schafer (2001) especifica três graus comuns de personalização:

- Não personalizado: nesse grau de personalização os sistemas de recomendação apresentam as mesmas recomendações para todos os usuários. Por exemplo, muitos sistemas de recomendação de sites de comércio eletrônico não personalizados apresentam as recomendações baseadas em "os top  $N$  produtos", os quais são escolhidos por especialistas previamente ou a partir da computação de média de avaliações;
- Personalização efêmera: nesse caso, os sistemas de recomendação utilizam as informações correntes, transitórias, do usuário para personalizar a recomendação. Por exemplo, muitos sistemas de recomendação de sites de comércio eletrônico com personalização efêmera ao apresentarem o "carrinho de compras" mostram recomendações de produtos "recentemente vistos" pelo usuário, e elas mudam a cada compra;
- Personalização persistente: nesse grau de personalização os sistemas de recomendação utilizam as informações do perfil do usuário armazenadas no sistema.

## 2.5 Perfil de Usuário

Um perfil é um registro em banco de dados que inclui características do usuário, tais como idade, sexo, estado civil, renda, entre outros.

O perfil de usuário pode ser montado e mantido com base em duas formas de coleta de dados:

- Coleta explícita: o usuário informa manualmente informações sobre si ou sobre suas preferências e interesses. Isso geralmente é feito através de formulários apresentados a ele antes de iniciar o uso da aplicação;
- Coleta implícita: são coletados dados sobre o usuário de forma automática, muitas vezes sem o seu conhecimento, enquanto ele utiliza o sistema.

Dependendo do objetivo de negócio, uma aplicação pode utilizar somente uma dessas formas de coleta de dados, ou usar as duas em conjunto.

Barth (2010) apresenta os principais aspectos que devem ser considerados na criação e manutenção de perfis de usuário. Tais aspectos são:

- a técnica de representação utilizada para armazenar o perfil de usuário, que pode ser, por exemplo, baseada em histórico de navegação do usuário (LINDEN; SMITH; YORK, 2003);
- a técnica de criação de perfil de usuário, que pode ser, por exemplo, a criação de perfil de usuário de forma manual, solicitando ao usuário que informe dados sobre si através de formulários;
- a técnica de aprendizado de perfil de usuário, que pode ser, por exemplo, baseada na organização de usuários similares em grupos;
- a forma de realimentação que representa os interesses do usuário, que pode ser, por exemplo, através de realimentação implícita, pela qual o sistema automaticamente infere as preferências do usuário através do monitoramento de suas ações;
- a técnica de adaptação de perfil de usuário, que pode ser, por exemplo, de forma manual, pela qual o usuário pode mudar o seu perfil quando for de seu interesse.

Relacionado à coleta de informações, duas grandes questões são discutidas na literatura: 1) questão dos perfis dinâmicos, já que as características, preferências e interesses do usuário podem mudar no tempo e no espaço; e 2) questão da privacidade, já que os dados e/ou hábitos e comportamento do usuário são registrados na aplicação e podem ser utilizados de forma indevida por pessoas maliciosas. Mais informações sobre essas duas grandes questões podem ser obtidas em Barth (2010) e Ramakrishnan et al. (2001), respectivamente.

## **2.6 Técnicas de Recomendação**

Os sistemas de recomendação são geralmente classificados dentre as seguintes categorias, baseando-se no modo como são feitos (BALABANOVIC; SHOHAM, 1997):

- Recomendações baseadas em conteúdo: ao usuário são recomendados itens que foram escolhidos por outros usuários, semelhantes a ele, no passado;
- Recomendações baseadas em filtragem colaborativa: ao usuário são recomendados itens que outras pessoas com gostos semelhantes aos dele preferiram ou gostaram no passado;
- Abordagens híbridas: combinam o método baseado em conteúdo e o baseado em filtragem colaborativa.

A recomendação baseada em conteúdo e a recomendação baseada filtragem colaborativa apresentam alguns problemas inerentes:

- Problemas em filtragem baseada em conteúdo:
  - Usuário Novo: se o usuário é novo, ele não tem passado, logo não é possível computar uma recomendação baseada em suas escolhas do passado;
  - Superespecialização: se um usuário costuma avaliar itens com as mesmas características o sistema sempre recomenda itens semelhantes aos já avaliados; assim, o usuário nunca é surpreendido com recomendações diferentes;
  - Análise limitada pelo contexto: está relacionado às características (atributos) dos itens, as quais são utilizadas para diferenciá-los. As características são informadas manualmente ou coletadas automaticamente, o que pode ser mais difícil, pois alguns itens são objetos complexos. E, ainda, se existem itens com características idênticas, não há como diferenciá-los.
  
- Problemas em filtragem colaborativa:
  - Item Novo: se um item é novo, ele não foi avaliado por nenhum outro usuário, logo não pode ser utilizado na computação da recomendação;
  - Usuário Novo: se um usuário é novo, ele não avaliou nenhum item, logo não pode ser utilizado na localização de usuários semelhantes;
  - Esparsividade: usuários tendem a avaliar poucos (os registros das avaliações são esparsos nas tabelas de dados), o que traz dificuldades para localizar usuários semelhantes ou itens semelhantes, dependendo da abordagem de recomendação colaborativa. É através das avaliações que se computa o grau de semelhança entre usuários ou entre itens;
  - Ovelha Negra: assim é como são chamados aqueles usuários com gostos raros. Devido a isso, é difícil localizar usuários com preferências similares.

Por outro lado, esses métodos de filtragem têm as seguintes vantagens:

- a filtragem baseada em conteúdo não depende da avaliação feita por outros usuários, logo não há problemas em recomendar itens novos ao usuário, itens pouco avaliados ou itens para usuários com preferências raras;
- a filtragem colaborativa contorna o problema da superespecialização e da análise limitada pelo contexto.

Devido a isso, a abordagem típica utilizada é a utilização das duas formas de recomendação citadas numa abordagem híbrida. Assim se aproveita as vantagens de ambos os métodos, e consegue-se contornar os problemas que ambos apresentam quando utilizados individualmente.

Além disso, as técnicas de recomendação utilizam vários conceitos de outras áreas como Estatística, Inteligência Artificial, Mineração de Dados e Engenharia de Software.

A Tabela 2.1 mostra alguns dos conceitos utilizados. Para obter mais informações, sugere-se ao leitor consultar o trabalho de Adomavicius; Tuzhilin (2005).

Tabela 2.1: Técnicas utilizadas em sistemas de recomendação

<i>Abordagens de Recomendação</i>	<i>Técnicas de Recomendação</i>	
	<i>Baseada em Heurística</i>	<i>Baseada em Modelo</i>
Filtragem Baseada em Conteúdo	Técnicas comumente utilizadas: <ul style="list-style-type: none"> <li>• Recuperação de Informação;</li> <li>• <i>Clustering</i>.</li> </ul>	Técnicas comumente utilizadas: <ul style="list-style-type: none"> <li>• Classificação Bayesiana;</li> <li>• <i>Clustering</i>;</li> <li>• Árvores de Decisão;</li> <li>• Redes Neurais.</li> </ul>
Filtragem Colaborativa	Técnicas comumente utilizadas: <ul style="list-style-type: none"> <li>• <i>Nearest neighbor</i> (correlação);</li> <li>• <i>Clustering</i>;</li> <li>• <i>Graph theory</i>.</li> </ul>	Técnicas comumente utilizadas: <ul style="list-style-type: none"> <li>• Classificação Bayesiana;</li> <li>• <i>Clustering</i>;</li> <li>• Árvores de Decisão;</li> <li>• Regressão Linear;</li> <li>• Modelos probabilísticos.</li> </ul>
Filtragem Híbrida	Combinação de Baseado em Conteúdo com Filtragem Colaborativa: <ul style="list-style-type: none"> <li>• Combinação linear de avaliações;</li> <li>• Vários esquemas de votação;</li> <li>• Incorporação de um componente como parte da heurística de outro.</li> </ul>	Combinação de Baseado em Conteúdo com Filtragem Colaborativa: <ul style="list-style-type: none"> <li>• Incorporação de um componente como parte do modelo de outro;</li> <li>• Construção de um modelo unificado.</li> </ul>

Fonte: adaptado de (ADOMAVICIUS; TUZHILIN, 2005).

Outros autores (op.cit.) informam que existem mais tipos de classificação:

- Filtragem Demográfica: a filtragem utiliza a descrição de um indivíduo para aprender o relacionamento entre um item em particular e o tipo de indivíduo que poderia vir a se interessar (MONTANER, 2003);
- Filtragem Baseada em Conhecimento: a recomendação dos itens é feita baseada nas inferências das preferências do usuário e suas necessidades através de conhecimento estruturado de forma funcional (BURKE, 2002);
- Filtragem Baseada em Utilidade: a recomendação é realizada considerando a utilidade dos itens para um determinado usuário (BURKE, 2002).

## 2.7 Recomendação baseada em Filtragem Colaborativa a partir de Correlação

Conforme apresentado na seção anterior, uma das técnicas utilizadas em recomendação baseada em filtragem colaborativa é a técnica de vizinho mais próximo

(*Nearest neighbor*), que utiliza correlação. Essa correlação pode se basear em uma abordagem usuário-usuário ou em uma abordagem item-item.

A ideia principal na abordagem usuário-usuário é computar predições de recomendação utilizando a similaridade entre usuários. Por outro lado, a ideia principal na abordagem item-item é computar predições de recomendações utilizando a similaridade entre itens. Em ambos os casos o cálculo de similaridade utiliza como base as avaliações de usuários sobre itens.

A correlação baseada na abordagem usuário-usuário é apresentada nos tópicos a seguir. Ela tem sido aplicada com sucesso em vários domínios. Em outros, onde é possível fazer pré-processamento *offline* de dados para haver tempo de resposta menor do sistema, a abordagem item-item tem tido mais sucesso (JANNACH et al., 2010).

### 2.7.1 Correlação Usuário-Usuário

A ideia principal da abordagem de recomendação colaborativa é explorar a informação sobre o comportamento passado ou a opinião de uma comunidade de usuários para predição de quais itens o usuário corrente do sistema vai provavelmente gostar ou estar interessado (JANNACH et al., 2010).

A abordagem de recomendação colaborativa, dita pura, utiliza como entrada uma matriz usuário  $\times$  item, que contém avaliações de usuários sobre itens, e tipicamente produz como tipo de saída: ou uma "predição numérica", indicando com que grau o usuário ativo (foco da recomendação) vai gostar ou não de um item; ou uma "lista de  $n$  itens recomendados", a qual não contém os itens já avaliados pelo usuário (JANNACH et al., 2010).

As avaliações devem ser numéricas, por exemplo, usando uma abordagem de escala de 1 a 5, ou uma abordagem binária com 0 e 1. Para os usuários as opções de avaliação não precisam necessariamente ser apresentadas na forma numérica. Por exemplo, avaliações de 1 a 5 podem corresponder às opções "Muito Ruim", "Ruim", "Indiferente", "Bom" e "Muito Bom" ou podem ser representadas por cinco estrelas; avaliações binárias podem corresponder às opções "Gostei" e "Não Gostei".

A computação de recomendação com predição numérica pode ser dividida em três passos: (a) cálculo da similaridade entre o usuário ativo e os outros usuários existentes, (b) construção de vizinhança, e (c) computação da predição baseada na média ponderada das avaliações dos usuários da vizinhança sobre o item alvo (JANNACH et al., 2010).

Para o primeiro passo, tipicamente se utiliza como métrica<sup>12</sup> o coeficiente de correlação de Pearson, o qual é apresentado na Equação 1.1.

$$sim(a, b) = \frac{\sum_{p \in P} (r_{a,p} - \bar{r}_a)(r_{b,p} - \bar{r}_b)}{\sqrt{\sum_{p \in P} (r_{a,p} - \bar{r}_a)^2} \sqrt{\sum_{p \in P} (r_{b,p} - \bar{r}_b)^2}} \quad (1.1)$$

<sup>12</sup> Para o cálculo de similaridade entre usuários existem outras métricas além do coeficiente de correlação de Pearson que podem ser utilizadas, tais como similaridade do cosseno, coeficiente de correlação de Spearman e diferença média quadrática. Dentre essas, de acordo com Herlocker et al. (1999), o coeficiente de correlação de Pearson é a melhor métrica para a abordagem usuário-usuário.

onde  $sim(a,b)$  é a similaridade entre os usuários  $a$  e  $b$  e corresponde a um valor Real no intervalo  $[-1,+1]$ ;  $P$  é um conjunto de itens e  $p$  é um item desse conjunto;  $r_{i,j}$  é a avaliação do usuário  $i$  ao item  $j$ ; e  $\bar{r}_i$  é avaliação média do usuário  $i$ .

No passo de construção de vizinhança são selecionados os vizinhos com correlação positiva, ou seja, no intervalo  $(0,+1]$ , com o usuário ativo.

Finalmente, para computar uma predição aritmética para um item, a média ponderada de todas as avaliações dos usuários da vizinhança é computada utilizando a equação 1.2.

$$pred(a,p) = \bar{r}_a + \frac{\sum_{b \in N} sim(a,b) * (r_{b,p} - \bar{r}_b)}{\sum_{b \in N} sim(a,b)} \quad (1.2)$$

onde  $pred(a,p)$  é a predição de avaliação que o usuário ativo  $a$  dará ao item  $p$ ;  $\bar{r}_b$  é a avaliação média do usuário  $b$ ; e  $b$  é um usuário pertencente à vizinhança construída  $N$ .

## 2.8 Exemplos de Sistemas de Recomendação

A seguir são apresentados alguns sistemas reais que utilizam recomendação.

### 2.8.1 Amazon.com

A Amazon é uma empresa de comércio eletrônico situada nos Estados Unidos. De acordo com Borges; Oliveira (2010), seu sistema utiliza os dois tipos de coleta de informação citados anteriormente: explícita (o sistema conta com áreas para que os usuários possam interagir com o sistema na forma de *feedback* direto, onde os clientes podem realizar avaliações sobre os produtos), e implícita (o site analisa as interações do usuário com o site como páginas visitadas, últimos produtos visitados, itens do carrinho de compras, histórico de compras e busca por palavras-chave). Adicionalmente, são coletados dados da comunidade, tais como produtos mais populares, avaliações e comentários de outros usuários sobre vários produtos, entre outros. A partir de todos esses dados são feitas recomendações ao cliente. Este último, na maioria das vezes, consegue achar mais facilmente o que procura, e recebe sugestões de outros produtos.

A Figura 2.1 mostra uma parte da página de um livro à venda. No detalhe, são apresentadas recomendações de outros livros através da técnica de recomendação baseada em conteúdo.

### 2.8.2 Netflix.com

Netflix é uma empresa norte americana cujo negócio é o aluguel de filmes e séries em DVD ou sob demanda pela Internet. No Brasil, ela entrou em operação em setembro de 2011. O site recomenda filmes baseando-se em avaliações de usuário, crítica de avaliadores e de usuários, e lista de filmes mais populares. A Figura 2.2 mostra um exemplo de recomendação no site da Netflix.

A avaliação de filmes é feita utilizando-se uma escala de cinco estrelas. O usuário pode indicar explicitamente se está ou não interessado em um filme.



Figura 2.1: Exemplo de recomendação baseada em conteúdo no site da Amazon.



Figura 2.2: Recomendação de filme no site da Netflix.

### 2.8.3 Entree

O *Entree* é um sistema de recomendação de restaurantes que combina filtragem colaborativa com filtragem baseada em conhecimento (BURKE, 2002).

Para receber recomendações, o usuário deve selecionar características que correspondam ao seu interesse, tais como, tipo de cozinha, faixa de preço, estilo; ou solicitar que o sistema indique um restaurante semelhante a outro que ele já conhece. A Figura 2.3 mostra a tela inicial do *Entree*.

Ao receber a recomendação o usuário interage com o sistema, podendo “criticar” a sugestão selecionando uma opção que refine seu interesse. Por exemplo, pode solicitar um restaurante que seja mais barato que o recomendado ou um mais tranquilo. Suas interações são tomadas como avaliações implícitas influenciando as próximas recomendações. A Figura 2.4 mostra a tela de recomendação de restaurante.

The image shows the initial interface of the Entree Chicago website. It features a logo at the top with a silver dome and a city skyline. Below the logo, there are two sections for user input. The first section, titled "I would like to eat at a restaurant that has:", contains five dropdown menus for "Cuisine", "Price", "Style", "Atmosphere", and "Occasion". The second section, titled "I would like to eat at a restaurant just like:", contains a text input field with "Chinois on Main" and a dropdown menu with "Los Angeles". At the bottom, there are two buttons: "New Query" and "Submit", both featuring a silver dome icon.

Figura 2.3: Tela inicial do *Entree*.

Fonte: (BURKE, 2002).

#### 2.8.4 Pandora

O Pandora<sup>13</sup> é um dos sistemas de recomendação de música mais populares da Internet. Esse sistema se baseia nas características das músicas, as quais são cadastradas manualmente por especialistas em música, para oferecer recomendações através de filtragem baseada em conteúdo. Seu banco de dados é composto por mais de 500.000 músicas, abrangendo mais de 20.000 artistas. Aproximadamente quatro milhões de usuários criam suas rádios personalizadas e recebem recomendações com base em suas escolhas (GOMES, 2007). Atualmente está sendo disponibilizado somente em alguns países.

<sup>13</sup> <http://www.pandora.com/>.



**Entree Results**

The Los Angeles restaurant you chose is:

<b>Chinois On Main</b>	
2709 Main St. (bet. Rose Ave. & Ocean Park Blvd.), Santa Monica, 310-392-9025	
Pacific New Wave	\$30-\$50
Extraordinary Decor, Extraordinary Service, Near-perfect Food, Hip Place To Be, On the Beach, Great for People Watching, Parties and Occasions, Weekend Brunch, Weekend Lunch, Fabulous Wine Lists	

We recommend:

<b>Yoshi's Cafe</b>	
3257 N. Halsted St. (Belmont Ave.), Chicago, 312-248-6160	
Asian, Japanese, French (New)	\$30-\$50
Extraordinary Decor, Extraordinary Service, Near-perfect Food, Need To Dress, Prix Fixe Menus, Quiet for Conversation, Very Busy - Reservations a Must, Romantic, Good Out of Town Business, Fabulous Wine Lists, Game, Parking/Valet	

*less \$\$    nicer    cuisine*  
*traditional    creative    livelier    quieter*

*For other suggestions, select:*

<a href="#">Yoshi's Cafe</a>	<a href="#">302 West</a>	<a href="#">Lulu's</a>
<a href="#">Penny's Noodle Shop</a>	<a href="#">Arun's</a>	<a href="#">Trio</a>
<a href="#">Emilio's Tapas Bar &amp; Restaurant</a>	<a href="#">Nick's Fishmarket</a>	<a href="#">Bossa Nova</a>
<a href="#">Emilio's Granada</a>		

Figura 2.4: Tela de recomendação de restaurante.

Fonte: (BURKE, 2002).

Para começar a receber recomendações, basta que o usuário busque por uma música ou um artista. Com essa informação, o sistema cria uma estação que irá explorar canções e artistas que tenham características musicais similares ao que foi escolhido. A partir disso, o usuário pode avaliar cada música recomendada como sendo ou não do seu agrado. As avaliações são, então, utilizadas para aprimorar as recomendações.

A Figura 2.5 mostra a interface do Pandora. A música recomendada é "Aquele Abraço", de Gilberto Gil. A qualquer momento o usuário pode questionar porque determinada música foi recomendada e o sistema informa as características que o levaram a recomendá-la.



Figura 2.5: Interface do Pandora.

## 2.9 Uma nova Geração de Sistemas de Recomendação

As técnicas de recomendação apresentadas previamente (recomendação baseada em conteúdo, recomendação baseada em filtragem colaborativa e abordagens híbridas) têm sido utilizadas com sucesso em muitos sistemas, tais como, sistemas contendo recomendação de livros, de CDs, de notícias, entre outros, tanto na academia quanto na indústria, desde meados dos anos 1990. Porém as técnicas base têm certas limitações, apresentadas previamente (Superespecialização, Usuário Novo, e Análise Limitada pelo Contexto, na recomendação baseada em conteúdo; e Esparsividade, Item Novo, Usuário Novo, Ovelha Negra, na recomendação baseada em filtragem colaborativa) e que podem ser contornadas com a utilização das abordagens híbridas. Além disso, segundo Adomavicius; Tuzhilin (2005), a fim de proporcionar melhores recomendações e para ser capaz de utilizar recomendação em sistemas mais complexos, tais como, sistemas que fazem recomendações turísticas ou que fazem recomendação de certos tipos de serviços financeiros, a maior parte das técnicas de recomendação precisa ser estendida. Por exemplo, Adomavicius; Sankaranarayanan; Sen; Tuzhilin (2005) estenderam um simples sistema de recomendação de filmes, que utilizava como base a filtragem colaborativa, com a utilização de informações contextuais, tais como, "quando", "onde" e "com quem" um filme é visto, e mostraram que a recomendação resultante pode ser superior à recomendação gerada pela típica filtragem colaborativa. Muitos sistemas, incluindo vários sistemas comerciais, tais como os descritos acima, são sem dúvida mais complexos do que um simples sistema de recomendação de filmes, e exigem que a recomendação leve em conta mais fatores. Portanto, a necessidade de desenvolver técnicas de recomendação mais avançadas tem sido pressionada por estes tipos de sistemas. Tais sistemas impulsionam uma nova geração de sistemas de recomendação. Nesta nova geração questões antigas ressurgem e ganham mais atenção, tais como escalabilidade, privacidade, robustez, adaptabilidade, entre outras, e surgem novas questões, específicas de cada domínio.

No próximo capítulo são apresentados trabalhos relacionados com este presente trabalho. Alguns destes utilizam a abordagem tradicional, apoiada nas técnicas de recomendação base, outros buscam estender as técnicas de recomendação base a fim de apoiar tipos mais complexos de sistemas de recomendação.

### 3 TRABALHOS RELACIONADOS

Muitos trabalhos na área de recomendação de vídeo utilizam abordagens baseada em filtragem baseada em conteúdo ou em filtragem colaborativa, principalmente trabalhos que combinam essas abordagens em métodos de recomendação híbrida, tais como Lekakos; Caravelas (2006), Melville et al. (2001), Spiegel (2009), Smyth; Cotter (2000), entre outros. Esses métodos quando utilizados individualmente serão denominados "puros" no decorrer deste trabalho. Todos esses trabalhos estão relacionados com esta pesquisa, pois esta utiliza métodos puros de recomendação e porque os utiliza de forma híbrida.

Adicionalmente, novas abordagens vêm sendo apresentadas para trazer melhorias a sistemas de recomendação de vídeo, conforme discutido previamente, tais como a utilização de informações de contexto (NAUDET, 2008), de informações emocionais do usuário (OLIVEIRA, 2011), de informações de redes sociais (STEWART, 2009), anotações de conteúdo com *tags* (PARK, 2011), entre outras. Muitas simplesmente criam novas formas de recomendação e outras são extensões das abordagens puras a fim de apoiar tipos mais complexos de sistemas de recomendação.

Além disso, uma abordagem pouco utilizada para trazer melhorias a sistemas de recomendação de vídeo é o uso de pontos de interesse. De acordo com Chakoo et al. (2008), os sistemas de recomendação de vídeo atuais não exploram o fato dos usuários gostarem mais de determinados segmentos de um vídeo já vistos no passado, que correspondem a pontos de interesse, do que o resto do vídeo.

Nas próximas seções são apresentadas, inicialmente, algumas das novas abordagens que vêm sendo apresentadas para trazer melhorias a sistemas de recomendação de vídeo ou simplesmente para criar novas formas de recomendação, e que estão relacionadas com este trabalho. Em seguida são apresentados dois trabalhos encontrados na literatura, até a data de realização desta pesquisa, que abordam o uso de pontos de interesse em sistemas de recomendação de vídeo. Esses são considerados o estado da arte dessa área de pesquisa.

#### 3.1 Abordagens relacionadas para melhorar sistemas de recomendação de vídeo

A seguir são apresentados três trabalhos existentes que apresentam abordagens para melhorar sistemas de recomendação de vídeo e que estão relacionados com esta pesquisa. A apresentação foi organizada de maneira a apresentar cada sistema e após cada apresentação indicar como ele está relacionado com este trabalho.

### 3.1.1 Sistema *CurioView*: recomendações de vídeo relacionadas ao conteúdo que está sendo assistido na TV

Neste trabalho, Sumiyosh et al. (2010) apresentam uma nova maneira de ver TV, *CurioView*, que utiliza metadados e tecnologia de recuperação de informação para satisfazer as curiosidades do telespectador através da recomendação de outros programas de TV, de vídeo sob demanda e de vídeo da Internet, todos relacionados ao conteúdo que ele está assistindo na TV. Eles propõem ainda uma arquitetura que pode ser aplicada de forma flexível, não apenas à TV, mas também a computadores e a dispositivos móveis.

Os autores citam que as principais alternativas utilizadas para ajudar o usuário a contornar o problema da sobrecarga de conteúdo são a disponibilização de mecanismos de busca ao usuário e a incorporação de sistemas de recomendação. Segundo eles, na primeira, isso pode ser difícil de ser realizado se a TV não possui facilidades para tal fim. Nesse contexto, os autores propõem uma abordagem baseada em busca automatizada, onde o próprio sistema realiza buscas e, então, gera as recomendações.

Tal abordagem pressupõe que o conteúdo que o telespectador está assistindo reflete os seus interesses em determinado ponto do tempo; então os metadados associados a esse conteúdo e ao segmento corrente em exibição desse conteúdo podem ser utilizados para buscar, baseando-se em filtragem baseada em conteúdo, mais conteúdo relacionado. Com base nisso, verifica-se que tal abordagem se baseia em personalização efêmera.

Os autores propõem um modelo de sistema composto por quatro elementos (sistema de apresentação de conteúdo relacionado, sistema de recuperação de informação, servidor de metadados e servidor de conteúdo) e definem as especificações de cada componente e de suas interfaces de conexão.

Basicamente, o sistema de apresentação tem um exibidor de conteúdo e funções de interface de usuário. Quando o usuário visualiza o conteúdo, a posição de reprodução (tempo decorrido desde o início do conteúdo) e um identificador interno, que identifica o conteúdo, são enviados para o sistema de recuperação de informação. Esse sistema utiliza essas informações para recuperar metadados do conteúdo (e do segmento corrente) para realizar a busca automatizada, e então responde enviando de volta informações de conteúdo relacionado na forma de recomendações para serem apresentadas para o telespectador. As recomendações são geradas tendo-se como base os metadados do conteúdo inteiro e os metadados do segmento corrente do conteúdo. O conteúdo relacionado fica armazenado em um servidor de conteúdo. Esse processo é ilustrado na Figura 3.1.

Os autores construíram um protótipo de sistema para demonstrar um exemplo específico dos conceitos do *CurioView*. Para simular um programa de TV foi utilizado o vídeo de um jogo de beisebol. Nesse protótipo foram implementadas duas interfaces do sistema de apresentação, uma em TV e outra na forma de site de vídeos. O sistema de recuperação de informação implementado contém algumas formas de recuperação de informação: duas baseadas em Processamento de Linguagem Natural (PLN), e uma forma baseada em processamento de vídeo. A primeira das formas baseadas em PLN é utilizada para recuperar vídeos similares a partir da análise de texto, por exemplo, do guia de programação de TV, de *closed captions* e da programação de sites relacionados ao conteúdo. A segunda das formas baseadas em PLN é utilizada para recuperar cenas no jogo a partir da análise dos comentários do narrador do jogo. A forma baseada em

processamento de vídeo é utilizada para localização de cenas semelhantes à cena em exibição. A Figura 3.2 mostra a interface do sistema de apresentação no formato de site de vídeos; no centro está o vídeo sendo assistido e ao seu redor é disponibilizado conteúdo adicional recomendado.

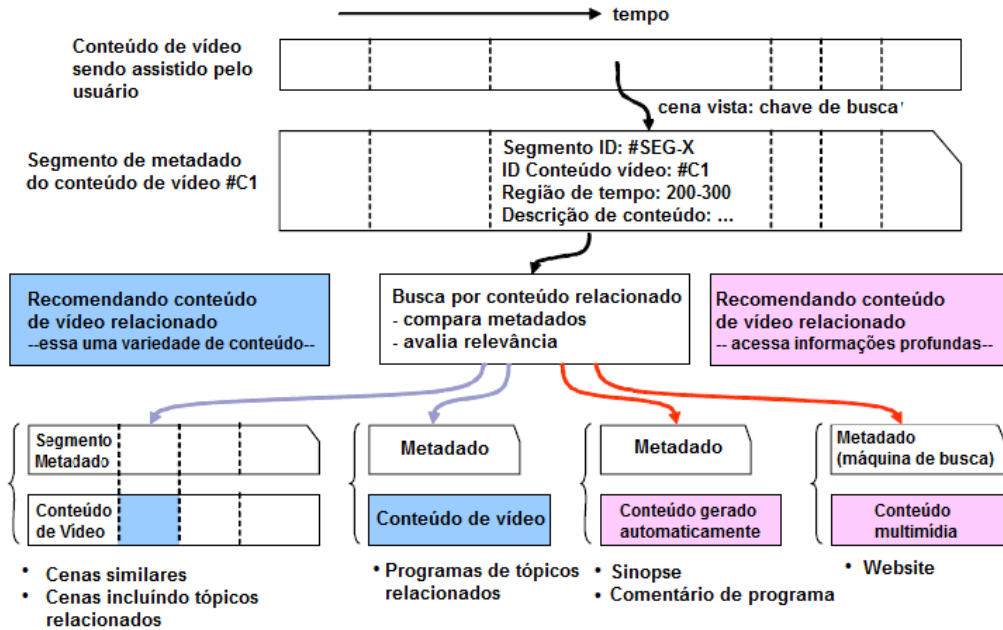


Figura 3.1: O mecanismo de busca automatizada e recomendação do *CurioView*.

Fonte: adaptado de (SUMIYOSH et al., 2010).

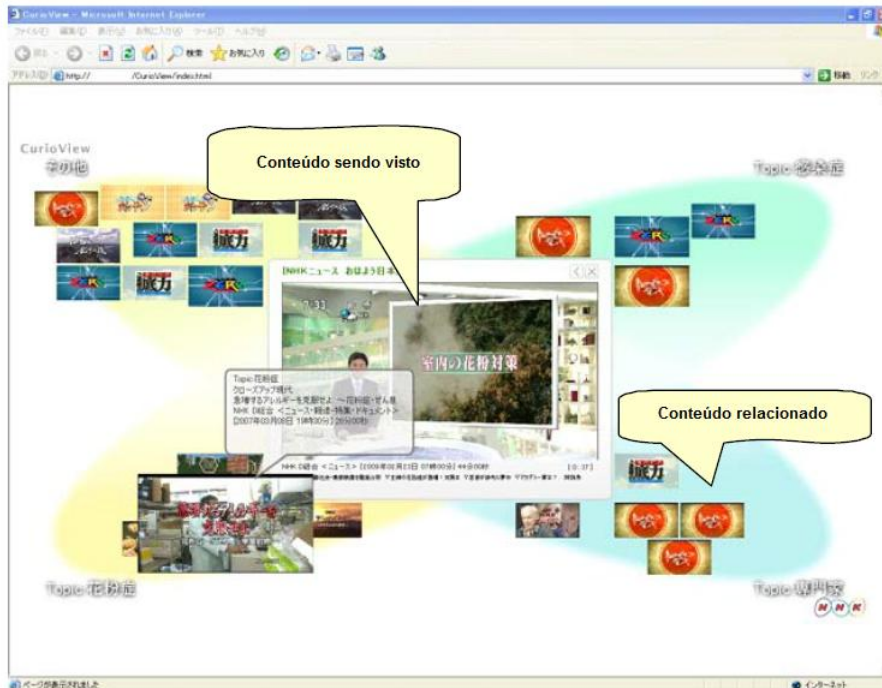


Figura 3.2: Tela do *CurioView* sendo executado num browser Web.

Fonte: adaptado de (SUMIYOSH et al., 2010).

Os autores não realizaram nenhuma avaliação experimental da abordagem proposta. Foram realizados apenas alguns testes funcionais básicos no protótipo, com os quais foi demonstrado que o sistema de recuperação proposto pôde ser utilizado em sistemas de apresentação diferentes (que nesse caso foram TV e site de vídeo). Foi constatado um problema: o alto tempo de resposta das requisições de recuperação de informação.

O trabalho de Sumiyosh et al. (2010) pressupõe que o que o usuário está assistindo (o conteúdo todo e o último segmento do conteúdo) é implicitamente o que lhe interessa, e esse interesse é utilizado na geração de recomendações. Esse trabalho está relacionado com esta pesquisa pelo fato de que nesta os pontos de interesse, que também são segmentos de vídeo - porém marcados explicitamente pelo usuário como interessantes para ele, também são utilizados na geração de recomendações.

### 3.1.2 Um Sistema de Recomendação para o YouTube baseado em Rede de Comentários

Qin; Menezes; Silaghi (2010) propõem uma abordagem para criar um ranking de vídeos a partir da informação extraída de uma rede social formada por usuários que escrevem comentários sobre vídeos do YouTube.

Os autores definem essa rede, chamada de Rede de Recomendação do YouTube (*YouTube Recommender Network* - YRN), da seguinte forma: o relacionamento entre os vídeos é feito com base nos comentários deixados neles. Os nós dessa rede representam os vídeos e uma aresta é estabelecida entre dois nós se um mesmo usuário faz comentários nos dois nós (vídeos). Cada aresta tem um peso, que reflete o grau de relacionamento entre dois nós; quanto maior o peso, mais relacionados estão os nós.

Com o objetivo de recomendar vídeos aos usuários, os autores propõem uma maneira de quantificar a importância de um nó na YRN: atribui-se a cada nó um valor de utilidade que é calculado com base na posição dos nós na rede.

Na apresentação da abordagem proposta para construir a YRN foi feito um *crawler* que visitou, através da API<sup>14</sup> do YouTube, cada vídeo e coletou o identificador de vídeo, ID, e os usuários que deixaram comentários nele. Seguindo a abordagem proposta, para montar a rede, cada ID de vídeo corresponde a um nó. Se um usuário deixou comentários em dois vídeos então existe uma aresta entre esses nós. As arestas recebem um peso referente ao número de comentários em comum entre os dois nós. Por exemplo, se seis usuários deixaram comentários nos vídeos A e B, então o peso da aresta entre A e B é seis. A Figura 3.3 mostra a YRN apresentada pelos autores ao descreverem sua abordagem.

Após construir a rede os autores aplicaram sobre ela métricas de rede que são úteis em sistemas de recomendação: Grau de Distribuição, Comprimento Médio de Caminho, Coeficiente de *Clustering* e Identificação de Comunidade. Através da análise do Grau de Distribuição eles constataram que a rede montada não é uma rede randômica, é uma rede Complexa. Através da análise do Comprimento Médio de Caminho e do Coeficiente de *Clustering* os autores constataram que a YRN é uma rede "pequeno mundo", o que é importante, porque diz que a partir de um dado vídeo muitos outros vídeos podem ser alcançados e, portanto, pode ser utilizada num sistema de recomendação. Através da análise da Identificação de Comunidades os autores constataram que a YRN possui muitas comunidades. No contexto de sistemas de

<sup>14</sup> <https://developers.google.com/youtube/>.

recomendação, a estrutura da comunidade pode ajudar o sistema a restringir as recomendações dentro de determinadas categorias dadas pelas comunidades.




Figura 3.3: YRN dos dados utilizados na apresentação da proposta.

Fonte: (QIN; MENEZES; SILAGHI, 2010).

Para utilizar a YRN como parte de um sistema de recomendação, os autores definem uma abordagem para calcular o valor de utilidade para cada nó (vídeo), que capta a importância do vídeo na rede. Nessa abordagem foca-se primeiramente em *hubs*, que são os nós com alto grau de conectividade, o que corresponde a um grande valor de utilidade. Talvez seja por isso que a rede criada com todos os vídeos do YouTube, que são mais de 120 milhões de acordo com Google (2011), possui poucos nós quando apresentada na Figura 3.3.

Em seguida os autores ranquearam os vídeos por ordem decrescente do valor de utilidade e compararam com os rankings populares de vídeos do YouTube: "Os mais comentados", "Os mais vistos", "Os mais bem avaliados", "Os mais favoritos". Os resultados mostraram que a abordagem proposta não é igual a outras formas de ranqueamento de vídeo já utilizadas no YouTube. Porém verificou-se uma tendência de "Os vídeos mais bem avaliados" serem "Os mais comentados", conseqüentemente, os com maior valor de utilidade.

Com o uso do valor de utilidade os autores propõem duas abordagens de recomendação:

- **Recomendação Global:** recomenda-se vídeos baseando-se no seu ranking, calculado pelo valor de utilidade. Por exemplo, quando um usuário acessa a página inicial do site são mostrados os  $n$  vídeos com maior valor de utilidade;
- **Recomendação Local:** recomenda-se vídeos relacionados ao vídeo que está sendo visualizado pelo usuário. Essa relação é a relação de adjacência dos nós na YRN, ou seja, os vídeos recomendados são os vídeos dos nós adjacentes ao vídeo que está sendo assistido. A Figura 3.4 mostra o nó (central) correspondente a um vídeo, os nós adjacentes a ele, e o peso das arestas. Os vídeos recomendados são os vídeos dos nós adjacentes ao vídeo que está sendo assistido. Como pode haver vários nós adjacentes, pode ser criado um ranking de vídeos com base no peso de cada aresta. Por exemplo,







viver separados geograficamente. O estudo contou com análise de questionários pré e pós utilização do sistema e análise de *logs* do sistema.

Nos tópicos a seguir apresenta-se um resumo do sistema, detalhando-se a parte relativa aos pontos de interesse.

### 3.2.1.1 Descrição do Sistema CollaboraTV

O CollaboraTV foi projetado para suportar telespectadores síncronos e assíncronos em uma interface unificada. Como resultado o sistema permite a comunicação dentro e entre esses dois modos de visualização, proporcionando um alto nível de interação em potencial.

Enquanto o usuário assiste ao programa de TV ele pode anexar alguns tipos de anotação ao fluxo de transmissão da mídia no correspondente índice temporal. Quando outros usuários atingirem esse ponto enquanto assistem ao programa, um comportamento do sistema relativo ao tipo de anotação é exibido na tela por alguns segundos.

A característica mais proeminente da interface de usuário do CollaboraTV é a “sala virtual” (Figura 3.5). Uma série de avatares<sup>15</sup> é usada para visualizar e representar telespectadores atuais (síncronos) e do o passado (assíncronos). O efeito de um cinema, onde as pessoas estão sentadas, é utilizado logo abaixo da tela de apresentação da mídia. Cada avatar tem o nome e uma posição de assento estático durante todo o programa. Nos que estão assistindo de forma síncrona, ou seja, ao vivo, é adicionado uma indicação desse fato abaixo do nome do avatar.

Além de encarnar espectadores simultâneos e teletemporais, a sala virtual é usada como canal de comunicação principal. Os autores propõem o uso de três tipos de notações. As anotações do tipo *comentários de texto*, ligados temporalmente, são mostradas em “bolhas” de discurso acima do avatar do usuário que fez o comentário, de forma análoga à vista em histórias de quadrinhos. O segundo tipo de anotação é o *ponto de interesse*. Os avatares podem fazer gestos de positivo e de negativo com o dedo polegar. Esses correspondem a pontos positivos e negativos, respectivamente, gerados pelo usuário. Por exemplo, numa cena excitante que o usuário goste ele pode colocar um ponto de interesse positivo. O terceiro e último tipo de anotação são as *expressões*. As anotações do tipo expressão selecionadas pelos telespectadores são vistas como animações dos avatares. Por exemplo, quando um usuário seleciona “feliz”, seu avatar gira a cabeça revelando um sorriso em seu rosto. A Figura 3.5 apresenta um exemplo de como cada tipo de anotação é apresentado na sala virtual.

As anotações de pontos de interesse, embora sejam utilizadas principalmente para fins de comunicação, a sua localização, frequência e conteúdo podem ser aproveitados para outros fins. Com estes pontos podem ser criados Perfis de Interesse de usuário, interpolando-se o nível de interesse contínuo a partir de uma série de pontos de interesse. Uma curva que representa o grau de interesse pode ser plotada, como mostra a Figura 3.6. A distribuição de pontos pode ser interpretada como uma distribuição gaussiana; aglomerações de pontos positivos elevam a amplitude positiva da curva, aglomerações de pontos negativos elevam a amplitude negativa da curva.

---

<sup>15</sup> Em Realidade Virtual, um avatar é um "cibercorpo" inteiramente digital, uma figura gráfica de complexidade variada que empresta sua vida simulada para o transporte identificatório de cibernautas para dentro dos mundos paralelos do ciberespaço (SANTAELLA, 2003).



Figura 3.5: Uma visão parcial da sala virtual do CollaboraTV.

Fonte: adaptado de (NATHAN et al., 2008).

Segundo os autores esses dados que mostram o nível de interesse do telespectador oscilando entre positivo e negativo ao longo do período de um programa de TV podem ser interessantes para diversos fins.




Figura 3.6: Um conjunto discreto de pontos de interesse utilizados para forma um perfil de interesse.

Fonte: adaptado de (NATHAN et al., 2008).

### 3.2.1.2 Resultados do CollaboraTV e Trabalhos Futuros

Através do estudo de Natham et al. (ibidem) foi demonstrado que o CollaboraTV pode ajudar as pessoas a voltar a ver televisão em grupo, mesmo estando geograficamente separadas. Para isso, o CollaboraTV permite às pessoas interagirem em situações síncronas, assíncronas e mistas de visualização de TV.

Nathan et al. (2008) apresentam algumas propostas de trabalhos futuros. Duas delas são relativas a pontos de interesse, e são listadas a seguir.

#### a) Uso de Perfis de Interesse

Perfis de interesse podem ser utilizados de várias formas. Uma aplicação está relacionada à busca em mídia. Perfis de interesse podem ser montados não apenas por usuário mas também por comunidade de usuários. Um perfil de interesse desse tipo pode ser utilizado para avançar na mídia, acessando os momentos onde ocorreram várias avaliações positivas pela comunidade. Isso, por exemplo, poderia ser utilizado para acessar os momentos mais importantes de um jogo de futebol. Outra aplicação seria a montagem automática de programas de TV a partir de cenas de outros programas que receberam muitas avaliações positivas pela comunidade de usuários.

## b) Uso das anotações de usuário em sistemas de recomendação

Nos questionários pós-experimento realizados pelos autores (op.cit.) foram feitas algumas perguntas relativas à recomendação. Os resultados indicam que 64% dos usuários estariam dispostos a compartilhar suas anotações com um sistema de recomendação para poder receber recomendações para o seu perfil; e 57% estariam confortáveis com o compartilhamento de suas anotações com o objetivo de fornecer recomendações para outros usuários de outros sistemas. Com base nisso os autores sugerem que com o uso das anotações de usuário propostas (pontos de interesse, comentários de texto e expressões) poderiam ser exploradas técnicas de recomendação. Segundo eles, por exemplo, o uso implícito de *feedback* do usuário na forma de anotações poderia ser utilizado como substituto às avaliações explícitas de usuário, o que diminuiria o problema da esparsividade inerente em sistemas baseados em filtragem colaborativa.

O trabalho de Nathan et al. (2008) está relacionado com a presente pesquisa pelo fato de que os autores sugerem que pontos de interesse podem ser utilizados em sistemas de recomendação e pela forma de marcação de pontos de interesse à linha de tempo de vídeo.

### 3.2.2 Sistema de Recomendação de Vídeo baseado em Visibilidade Personalidade de Conteúdo

Os atuais sistemas de recomendação de vídeo baseados em filtragem colaborativa implementam um modelo limitado de visibilidade de conteúdo de vídeo. A maioria deles não provê uma pré-visualização de vídeo ao usuário e focam em algoritmos para fazer previsões e na acurácia das recomendações geradas. Há sistemas que focam na visibilidade de conteúdo, mas de forma limitada. Os sistemas de recomendação não exploram o fato dos usuários gostarem mais de determinados segmentos de vídeo já vistos do que o resto. A extração desses segmentos pode enriquecer a experiência do usuário e trazer melhorias à sistemas de recomendação. (CHAKOO; GUPTA; HIREMATH, 2008).

Baseado nisso, Chakoo; Gupta; Hiremath (2008) propõem uma abordagem para implementar a "visualização personalizada de conteúdo" em sistemas de recomendação de vídeo. A visualização de conteúdo é tão importante quanto as técnicas de recomendação de vídeo, e traz, de fato, segundo os autores, um impacto positivo na usabilidade e na performance desses sistemas.

#### 3.2.2.1 A Abordagem de Chakoo, Gupta e Hiremath

Uma vez gerada a recomendação, os autores propõem uma abordagem visual adicional de recomendação. Nela gera-se um "pré cursor" (como os próprios autores denominam) do vídeo recomendado e esse é apresentado ao usuário. Esse "pré cursor" é um vídeo com  $t$  minutos que mostra trechos de cenas do vídeo marcadas previamente pelo próprio usuário. Assim se fornece uma "visibilidade de conteúdo personalizada" ao usuário.

A Figura 3.7 apresenta a seleção (recomendação) de cenas feitas por um usuário ao longo da linha do tempo de um vídeo. As recomendações do usuário têm a ordem  $R_1, R_2, \dots, R_n$ . Como um vídeo pode ser visto diversas vezes, o usuário pode fazer diversas recomendações de cenas (marcadas como interessantes para ele). O usuário deve ainda atribuir pesos às suas recomendações. As cenas mais antigas têm peso menor (ou igual

ao da anterior), e as mais novas têm um peso maior. Esse peso é utilizado para montar o "pré cursor" do vídeo em questão. Os pesos, segundo os autores, são ideais para modelar o comportamento dinâmico do gosto pessoal do usuário, que pode mudar ao longo do tempo.

Na abordagem descrita, gera-se o "pré cursor" pela interseção dos segmentos marcados pelo usuário no vídeo, levando-se em conta o peso associado aos segmentos. Existe uma função de geração de vídeo que gera os  $t$  minutos de vídeo do "pré cursor" que é visto pelo usuário para um item multimídia particular recomendado. A Figura 3.8 mostra as cenas de um "pré cursor" gerado a um usuário.

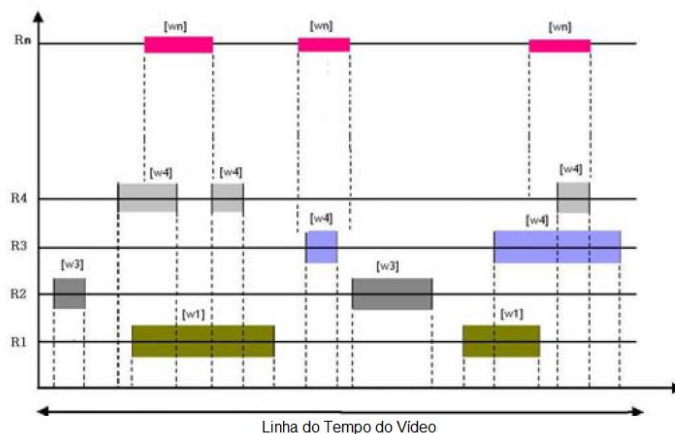


Figura 3.7: Demarcação de cenas interessantes para um usuário em um vídeo.

Fonte: adaptado de (CHAKOO; GUPTA; HIREMATH, 2008).

Chakoo; Gupta; Hiremath (2008) não realizam nenhum tipo de avaliação experimental da abordagem apresentada. Segundo eles essa abordagem mostra que é possível melhorar um sistema de recomendação de vídeo não apenas focando em algoritmos de recomendação e na acurácia das recomendações geradas, mas também adicionando visualização de conteúdo; e que essa visualização é personalizada e reflete o gosto do usuário. Porém, a abordagem típica é recomendar itens novos ao usuário e não recomendar itens já vistos por ele. Assim, tal abordagem, conforme explicam os próprios autores, é limitada a certos domínios. Por exemplo, ela poderia ser aplicada em um ambiente onde usuário pode, necessita ou está interessado em assistir, diversas vezes, um mesmo vídeo, ou em um ambiente onde exista um PVR, no qual o usuário tenha sua coleção de vídeos.



Figura 3.8: Cenas de um "pré cursor" gerado para recomendação de vídeo a um usuário. (CHAKOO; GUPTA; HIREMATH, 2008)

Esse trabalho está relacionado com esta pesquisa pelos seguintes fatos: (a) por considerar pontos de interesse do usuário em vídeo como segmentos de vídeo; (b) pela forma como são relacionados os segmentos de interesse do usuário à linha de tempo do vídeo; e (c) pelo processo de marcação de segmentos de interesse. A abordagem

proposta por Chakoo; Gupta; Hiremath (2008) espera que o usuário primeiro veja o vídeo para só depois marcar seus segmentos de interesse. Essa se encaixa em uma das possíveis abordagens de marcação de pontos de interesse apresentadas nesta pesquisa (marcação de pontos de interesse delimitando-se início e fim de pontos de interesse - realizada tanto após assistir ao vídeo como em quanto assiste ao vídeo), a qual é apresentada mais adiante.

## 4 A ABORDAGEM PROPOSTA

Natan et al. (2008) e Chakoo; Gupta; Hiremath (2008) mostraram que a interatividade e a colaboração de usuários pode ser utilizada para melhorar um sistema de recomendação. O primeiro apenas sugere que pontos de interesse positivos ou negativos marcados pelo usuário na posição corrente da linha de tempo do vídeo, ou seja, enquanto ele assiste ao vídeo, poderiam ser utilizados em recomendação. O segundo apresenta, de fato, uma abordagem que permite ao usuário marcar segmentos de interesse em vídeo após ter assistido o vídeo e utiliza esses segmentos como base para gerar uma "recomendação visual de conteúdo" adicional, após a recomendação típica já ter sido realizada. Essa marcação também tem como referencial a linha de tempo do vídeo.

Baseando-se no fato de que os usuários se interessam mais, ou tendem a gostar mais, de determinados segmentos do vídeo do que do resto, este trabalho apresenta uma abordagem que utiliza esses segmentos de interesse para aumentar a acurácia de predição de avaliação de sistemas de recomendação de vídeo, tanto novos quanto existentes e em operação. Tais segmentos de interesse são chamados no decorrer deste trabalho de Pontos de Interesse, ou, simplesmente, POI (*Points of Interest*), e têm, também, como referencial, a linha de tempo de vídeo.

### 4.1 Exemplo Introdutório

A Figura 4.1 exemplifica os POI marcados por um usuário em um vídeo. Nela, o primeiro foi marcado de 34 até 61 segundos em relação à linha de tempo do vídeo; o segundo de 161 até 180 segundos; e o terceiro de 302 até 331 segundos.




Figura 4.1: POI marcados por um usuário em um vídeo.

O POI de um usuário em um vídeo pode ter intersecção com o POI de outro usuário ou de outros usuários. Quando o número de intersecções dentro de um único vídeo exceder certo limiar, e isso se repetir em vários vídeos, suspeita-se que esses usuários têm interesses similares ou gosto em comum em relação a vídeos. Diante dessa possibilidade, a seguinte hipótese é lançada: "pontos de interesse podem ser utilizados para encontrar pessoas similares, ou seja, que possuem interesses similares ou gosto em

comum em relação a vídeos; e essa similaridade pode ser utilizada para aumentar a acurácia de predição de avaliação de um sistema de recomendação de vídeo". Um dos objetivos deste trabalho foi verificar se essa proposição era verdadeira.

A Figura 4.2 mostra como os POI de diferentes usuários podem ser dispostos ao longo de uma linha de tempo. Nesse exemplo, apresenta-se quatro usuários,  $u_1$ ,  $u_2$ ,  $u_3$  e  $u_4$ , e seus respectivos pontos de interesse marcados em um vídeo. Os pontos de interesse de alguns usuários têm intersecção com os pontos de interesse de outros usuários. Quando esse número de intersecções está acima de certo limiar, considera-se que esses usuários são similares. Porém, para se ter mais certeza sobre essa similaridade, esta análise deve ser estendida para diferentes vídeos, também considerando uma certa quantidade de vídeos.

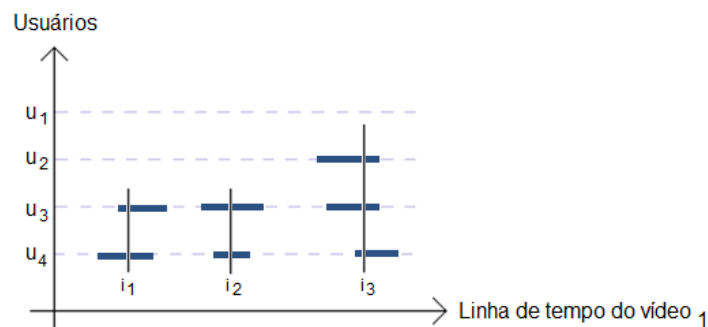


Figura 4.2: POI de usuários e suas intersecções mostrando interesses em comum.

A Figura 4.3 apresenta essa análise estendida para um conjunto de vídeos. Nessa figura, observa-se que os usuários  $u_2$  e  $u_4$  são os mais similares no grupo de usuários caso se considere que os valores de limiares sejam: ter no mínimo 3 vídeos com pelo menos 2 intersecções ( $i_m$ ) de POIs em cada vídeo ( $videon_n$ ).

O tamanho da intersecção também deve ser considerado um limiar; pois se o tamanho for pequeno pode ter havido uma intersecção eventual do início de um ponto de interesse de um usuário com o fim de um ponto de interesse de outro. Além disso, considera-se que quanto maior o tamanho da intersecção mais interesses similares ou gostos em comum em relação a vídeos têm os usuários.

É possível também que usuários não tenham marcado nenhum ponto de interesse no vídeo ou não tenham nunca assistido ao vídeo. É possível também que ao reassistir um vídeo os usuários possam marcar novos pontos de interesse ou excluir pontos de interesse antigos. Isso permite a evolução de perfis de usuário ao longo do tempo, já que esses são dinâmicos.

Mais formalmente, o cálculo da similaridade entre usuários baseada em pontos de interesse e a definição formal de domínio que descreve o ambiente de um sistema de recomendação de vídeo com acurácia de predição de avaliação aumentada através do uso de pontos de interesse são apresentados nas próximas seções.

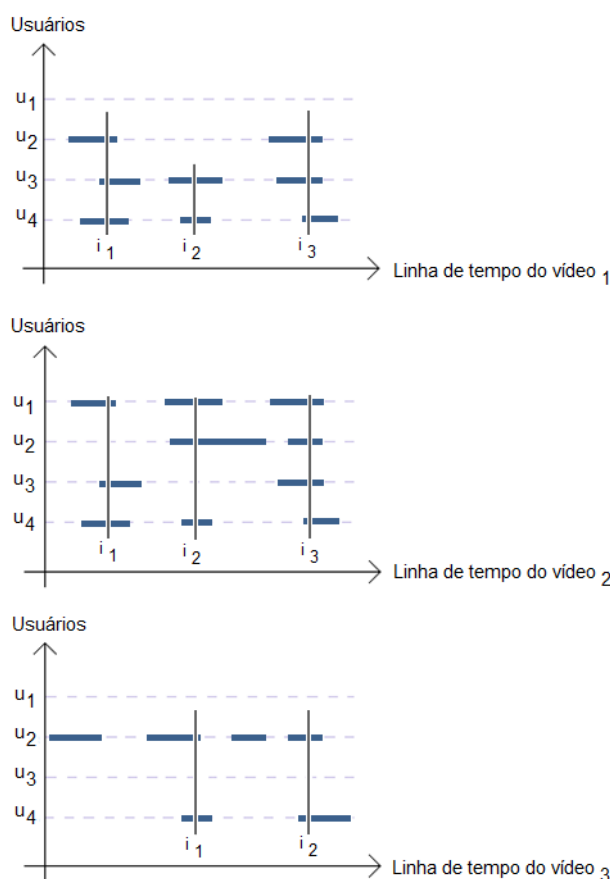


Figura 4.3: POI de usuários em diferentes vídeos.

## 4.2 Definição Formal de Domínio

O ambiente de um sistema de recomendação de vídeo com acurácia de predição de avaliação é aumentada através do uso de pontos de interesse é composto por:

- um conjunto  $U = \{u_1, u_2, u_3, \dots, u_n\}$  de indivíduos (usuários do sistema);
- um conjunto  $V = \{v_1, v_2, v_3, \dots, v_n\}$  de itens (vídeos);
- um conjunto de pontos de interesse  $POI$ ; sendo que cada ponto de interesse de um usuário  $u$  em um vídeo  $v$  ( $POI_{uv}$ ) corresponde a um segmento marcado pelo usuário  $u$  no vídeo  $v$ , tendo como referência a linha de tempo desse vídeo, e é delimitado pelo início ( $x$ ) e pelo final ( $y$ ) do segmento que representa o ponto de interesse, ambos em segundos, conforme define a propriedade de elementos de conjunto abaixo:

$$POI_{uv} = [x, y] \mid x, y \in \mathbb{N} \text{ e } x < y$$

- uma função de utilidade  $sim^{POI}(u_b, u_o)$ , que computa o grau de similaridade  $s$  entre um par de usuários a partir de seus pontos de interesse, a qual é formalmente definida na seção 4.3. Ao utilizar essa função em um sistema de recomendação, o usuário base ( $u_b$ ) é o usuário ativo, foco da recomendação.



O perfil de um usuário ( $P$ ), que geralmente é composto por nome, e-mail, dados demográficos (idade, sexo, cidade, país, etc.) e avaliações de itens pelo usuário, pode ser estendido a partir do conjunto de seus POIs:

$$P_u = \{POI_{uv_1}, POI_{uv_2}, \dots, POI_{uv_n}\}$$

### 4.3 Similaridade entre Usuários Baseada em Pontos de Interesse

Para calcular a similaridade entre um par de usuários com base em pontos de interesse é proposta uma função de utilidade. Uma função de utilidade pode ser generalizada como uma função matemática que faz o mapeamento entre um conjunto de entrada e um conjunto de saída de forma a selecionar o melhor elemento do conjunto de saída a partir de um ou mais elementos do conjunto de entrada e cujo objetivo é trazer maximização de resultados ou otimização a o que faz uso de tal função.

Nesse trabalho tal função utiliza as intersecções de pontos de interesse sobre vídeo de um par de usuários  $(u_b, u_o) \in U$  para calcular um valor Real  $s$ , no intervalo  $[0, 1]$ , que corresponde ao grau de similaridade entre o par de usuários, conforme definido abaixo.

$$u: U \times U \rightarrow s \mid s \in \mathbb{R} \text{ e } s \in [0,1]$$

Quando o valor  $s$  é 0, o par de usuários não tem interesses similares ou gosto em comum em relação a vídeo, quando o valor é 1, o par de usuários tem o maior grau possível de similaridade. No decorrer deste trabalho, a função de utilidade será denotada como  $sim^{POI}(u_b, u_o)$ , onde  $u_b$  é o usuário *base* da comparação e  $u_o$  é o *outro* usuário a ser comparado com o usuário *base*.

Além disso, a função de utilidade deve levar em conta os valores de limiares propostos para calcular o valor  $s$  a ser retornado. Para esse cálculo podem ser empregadas diferentes abordagens. Neste trabalho propõe-se que esse valor seja a razão entre o "número total de intersecções de pontos de interesse nos vídeos assistidos pelo par de usuários" e o "número total de pontos de interesse em vídeos assistidos pelo usuário *base*", cujo valor está presente no intervalo  $[0,1]$ . Como o valor da similaridade é uma razão, a função de utilidade é uma função bijetora e, sendo assim, o valor  $s$  de  $sim^{POI}(u_b, u_o)$  pode ser igual ou diferente do valor  $s$  de  $sim^{POI}(u_o, u_b)$ . Outras abordagens de cálculo do valor  $s$  são descritas no Capítulo 8. Propõe-se também que os limiares propostos recebam os identificadores e regras para valores aceitáveis apresentados na Tabela 4.1. Tais regras garantem que se tenha um conjunto de vídeos onde ocorra no mínimo uma intersecção de tamanho aceitável de pontos de interesse. Quanto maiores os valores de limiares, mais rígida é a busca por usuários similares, logo, mais acurada é a similaridade entre o par de usuários.

Tabela 4.1: Limiares propostos para a função de utilidade e regras para definição de seus valores

Identificador	Descrição	Regras de Valores Aceitáveis
T	tamanho mínimo de intersecção de pontos de interesse (tamanho aceitável de intersecção)	$T \in \mathbb{N}$ e $T > 0$
N	quantidade mínima de intersecções de pontos de interesse de tamanho aceitável T por vídeo	$N \in \mathbb{N}$ e $N \geq 1$
M	quantidade mínima de vídeos onde ocorrem N intersecções de tamanho aceitável T	$M \in \mathbb{N}$ e $M \geq 2$

#### 4.4 Aumentado a Acurácia de Predição de Avaliação de um Sistema de Recomendação com POI

Para aumentar a acurácia de predição de avaliação de um sistema de recomendação que contenha um módulo de filtragem colaborativa pura que utiliza a abordagem usuário-usuário propõe-se utilizar a função de utilidade conforme mostra a Figura 4.4. Dessa forma, tal função pode ser empregada não apenas a sistemas de recomendação novos, mas a sistemas já existentes e em operação.

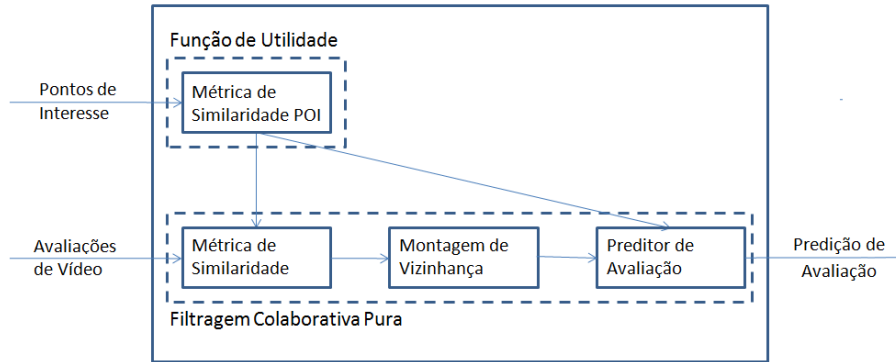


Figura 4.4: Modelo de um componente de filtragem colaborativa pura sob ação da função de utilidade baseada em pontos de interesse.

Nessa abordagem, a função de utilidade atua aumentando o grau de similaridade entre usuários, que é calculado pelo componente de filtragem colaborativa pura no passo "cálculo da similaridade entre o usuário ativo e os outros usuários existentes", conforme a equação 4.1.

$$sim^{FCa}(a, b) = sim^{FC}(a, b) * (1 + sim^{POI}(a, b)) \quad (4.1)$$

onde  $a$  é o usuário ativo (foco da recomendação),  $b$  é o outro usuário ao qual se quer calcular a similaridade com  $a$ ,  $sim^{FCa}$  é a similaridade aumentada do componente de filtragem colaborativa,  $sim^{CF}$  é a similaridade do componente de filtragem colaborativa pura baseada no Coeficiente de Pearson, e  $sim^{POI}$  é a função de utilidade. Se o valor computado pela função de utilidade for 0, a similaridade do componente de filtragem colaborativa não muda; se for maior do que 0, ela atua incrementando  $sim^{FC}$  percentualmente.

A  $sim^{FCa}$ , por sua vez, atua no passo de cálculo de predição (Equação 4.2) do componente de filtragem colaborativa. Assim os usuários que têm interesses em comum ou gosto similar em relação a vídeo com o usuário ativo têm seu peso aumentado ao se calcular a média ponderada de todas as avaliações dos usuários da vizinhança estipulada. Ou seja, tais usuários contribuem mais ao se calcular a predição, que é dada pela Equação 4.2.

$$pred(a, p) = \bar{r}_a + \frac{\sum_{b \in N} sim^{FCa}(a, b) * (r_{b,p} - \bar{r}_b)}{\sum_{b \in N} sim^{FCa}(a, b)} \quad (4.2)$$

onde  $pred(a, p)$  é a predição de avaliação que o usuário ativo  $a$  dará ao item  $p$ ;  $\bar{r}_a$  é a avaliação média do usuário ativo  $a$ ; e  $b$  é um usuário pertencente à vizinhança  $N$  montada, cuja avaliação média é denotada por  $\bar{r}_b$ .

## 4.5 Marcando POI

A marcação de POI está diretamente relacionada com a interface de usuário do sistema que contém o sistema de recomendação. Tal interface deve prover componentes específicos para marcação de pontos de interesse. Essa marcação pode ser realizada a partir de diferentes abordagens. Abaixo são propostas duas abordagens: (Exemplos de uso dessas em interface de usuário são apresentados na próxima seção.)

- Marcação de pontos de interesse com o uso de botões, na qual o usuário utiliza um ou mais botões para marcar seus pontos de interesse na linha de tempo de vídeo enquanto o assiste. Cada botão deve corresponder a um ponto de interesse de tamanho fixo e cuja extremidade final coincida com o instante corrente do vídeo.
- Marcação do início e do fim de cada ponto de interesse, na qual o usuário utiliza componentes de tela específicos para tal fim, e a marcação pode ser realizada enquanto se assiste ao vídeo ou depois de tê-lo assistido.

A abordagem de marcação de pontos de interesse deve ser escolhida de acordo com o contexto, pois ambas apresentam vantagens e desvantagens, conforme descrito a seguir. (Exemplos da aplicação de ambas as abordagens são discutidos no Capítulo 5.)

A abordagem de marcação de pontos de interesse através de botões (em interface de usuário do sistema, em interface de usuário de dispositivo remoto, ou em controle remoto) é indicada para sistemas (por exemplo, sites de vídeos, sistemas de vídeo sob demanda e dispositivos PVR) onde o objetivo do usuário é usufruir de entretenimento ou obter informação. A vantagem é que o usuário não perde tanto a atenção do vídeo quando quer marcar um ponto de interesse, e essa marcação ocorre sem muito esforço, de forma rápida e fácil. A desvantagem é que a marcação de início e final de ponto de interesse não é tão precisa quanto a linha de tempo do vídeo, e isso influencia na função de utilidade baseada em pontos de interesse, que, por sua vez, influencia na acurácia do sistema de recomendação. Além disso, o tamanho da extensão de um ponto de interesse também interfere na quantidade de intersecções, ou seja, se forem utilizados tamanhos curtos pode haver poucas intersecções, do contrário, muitas; e isso também influencia a acurácia do sistema de recomendação.

A abordagem de marcação de pontos de interesse delimitando-se o início e o final dos mesmos pode ser disponibilizada, por exemplo, através de componentes de tela no formato de cursores sobre a linha de tempo do vídeo. É indicada para ambientes onde o usuário tem mais liberdade (pode avançar e retroceder o vídeo, pode assisti-lo quantas vezes quiser), tais como sites e sistemas de vídeo sob demanda com objetivos mais específicos, como, por exemplo, sites de vídeos educacionais. A vantagem é que o usuário pode delimitar exatamente o início e o final de seus pontos de interesse, o que influencia a função de utilidade baseada em pontos de interesse, e, por sua vez, influencia a acurácia do sistema. A desvantagem é que a marcação exige um esforço maior por parte do usuário, já que precisa localizar e delimitar os pontos de interesse. Pode haver usuários que preferem ver todo o vídeo e depois retrocede-lo para marcar os pontos de interesse, mas outros podem querer marcar os pontos enquanto assistem ao

vídeo. No primeiro caso pode haver esquecimento da marcação de pontos de interesse, e no segundo o usuário pode perder a atenção no vídeo enquanto efetua a marcação dos pontos de interesse.

#### **4.6 Comparação da Abordagem Proposta com Outras Abordagens**

Conforme citado previamente durante a pesquisa que originou este trabalho foram encontrados apenas dois trabalhos que abordam o uso de pontos de interesse em sistemas de recomendação de vídeo.

O primeiro deles, Nathan et al. (2008), apenas sugere como pontos de interesse poderiam ser utilizados para trazer melhorias a sistemas de recomendação. A abordagem sugerida por seus autores tem algumas semelhanças como a abordagem proposta neste trabalho: ambos utilizam como referência a linha de tempo do vídeo, e o usuário participa de forma mais ativa e interativa. Ambas as abordagens também apresentam algumas diferenças: na abordagem proposta neste trabalho a marcação de pontos de interesse pode ser realizada enquanto o usuário assiste ao vídeo ou após assistir ao vídeo, já na abordagem de Nathan et al. (2008) só se pode marcar pontos de interesse enquanto se assiste ao vídeo (ou programa de TV); além disso na abordagem proposta neste trabalho são marcados apenas pontos de interesse do usuário (pontos que ele mais gosta ou mais se interessa), já na abordagem de Nathan et al. (2008) o usuário pode marcar tanto pontos que gosta como pontos que não gosta.

O segundo trabalho relacionado, de Chakoo; Gupta; Hiremath (2008), utiliza de fato pontos de interesse, porém para montar uma "recomendação visual de vídeo", a qual é disponibilizada ao usuário após a recomendação típica de vídeo já ter sido computada e apresentada ao usuário. A abordagem proposta pelos autores tem algumas semelhanças como a abordagem proposta neste trabalho: em ambas o usuário marca os segmentos que mais se interessa ou que mais gosta no vídeo, em ambas o usuário participa mais ativamente e mais interativamente, e em ambas se utiliza a linha de tempo do vídeo como referência, e, por fim, a marcação de pontos de interesse de Chakoo; Gupta; Hiremath (2008) é análoga à marcação pela abordagem onde o usuário delimita início e fim de ponto de interesse. A abordagem proposta por Chakoo; Gupta; Hiremath (2008) tem também algumas diferenças com a abordagem proposta neste trabalho: na abordagem de Chakoo; Gupta; Hiremath (2008) o foco é a geração de recomendação visual, já neste trabalho o foco é geração de recomendação típica, ou seja, de itens ao usuário.

## 5 O AMBIENTE IMPLEMENTADO

O ambiente foi implementado como um protótipo de aplicação Web (seguindo uma arquitetura cliente-servidor) (Figura 5.1) no formato seguido por muitos sites de vídeo da atualidade, ou seja, contendo uma tela de galeria de vídeos, na qual há uma listagem de vídeos, e uma tela com um *player* de vídeo, pela qual os usuários assistem a vídeos. Tal ambiente pode ser acessado de qualquer dispositivo que possua navegador Web, tais como, computadores *desktop*, notebooks, *tablets*, *smartphones* e TVs conectadas. Detalhes sobre a modelagem realizada antes da implementação do protótipo encontram-se no Apêndice A - A Modelagem do Ambiente Implementado.

Os vídeos que o ambiente utiliza são provenientes do YouTube, carregados sob demanda no site, diretamente no lado do cliente, através de uma API<sup>16</sup> de integração. Assim, não foi necessário armazenar os vídeos no servidor; esse armazena somente os dados dos vídeos, os quais são utilizados no carregamento sob demanda no lado do cliente. O YouTube atua, portanto, como um provedor de vídeo.

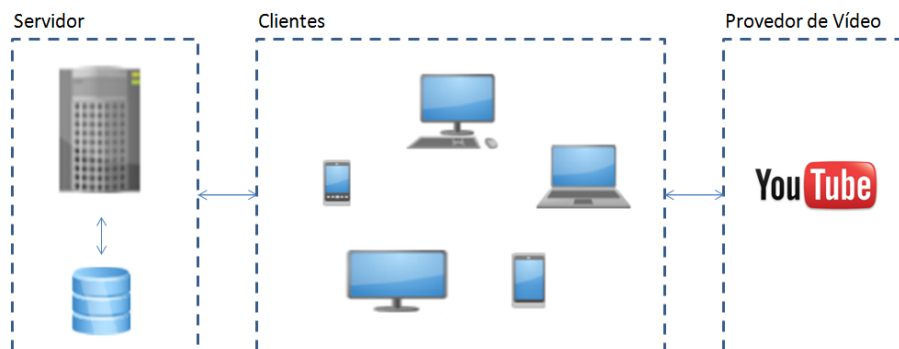


Figura 5.1: Arquitetura de referência do protótipo.

A implementação no lado do servidor foi feita orientada a objetos em JavaEE<sup>17</sup> utilizando o *framework* Vraptor<sup>18</sup> para desenvolvimento no padrão MVC (*Model-View-Controller*), banco de dados relacional PostgreSQL<sup>19</sup> e o *framework* de mapeamento

<sup>16</sup> <https://developers.google.com/youtube/>.

<sup>17</sup> <http://docs.oracle.com/javaee/>.

<sup>18</sup> <http://vraptor.caelum.com.br/pt/>.

<sup>19</sup> <http://www.postgresql.org/>.

objeto-relacional Hibernate<sup>20</sup>. No lado do cliente foi utilizado HTML, JavaScript e o framework JQuery<sup>21</sup>, para trabalhar com AJAX (*Asynchronous JavaScript and XML*).

O objetivo do protótipo é permitir que usuários busquem, assistam, avaliem vídeos e marquem, quando houver, seus pontos de interesse.

Além disso, antes de implementar o protótipo, definiu-se que a avaliação experimental da proposta apresentada consistiria na avaliação da acurácia de predição do sistema de recomendação em termos de acurácia de predição de avaliação, ou seja, avaliar a acurácia do sistema ao predizer a avaliação do usuário. (O planejamento detalhado da avaliação experimental é apresentado no Capítulo 6.) Tendo-se estabelecida essa definição, durante a implementação do protótipo decidiu-se adicionar algumas características para permitir tal avaliação experimental. Como o foco de pesquisa está diretamente relacionado com interesse e gosto pessoal, e como não existem *datasets* com pontos de interesse em vídeo, resolveu-se executar uma avaliação experimental do tipo Estudo de Usuário (descrita a seguir). Para isso o protótipo implementado possibilita que sejam realizados estudos de usuário do tipo *A-B testing*. Resolveu-se utilizar esse tipo de avaliação experimental, também, porque, segundo Ricci et al. (2011), ela provê uma configuração próxima a de sistemas reais.

No Estudo de Usuário do tipo *A-B testing*, cada usuário experimenta apenas uma abordagem candidata; onde cada abordagem candidata é um algoritmo, e os usuários são separados em grupos. Um candidato é o sistema de recomendação contendo o "algoritmo de filtragem colaborativa pura", utilizado por usuários de um grupo chamado "grupo controle"; e o outro candidato é sistema de recomendação contendo o "algoritmo de filtragem colaborativa pura sob ação da função de utilidade baseada em pontos de interesse", utilizado por usuários de um grupo chamado "grupo teste". E ainda, nesse tipo de avaliação, o sistema é utilizado por um grupo de usuários, os quais estão cientes que estão participando de um experimento, em um ambiente controlado (tal como um laboratório, onde todos os computadores e a rede de comunicação têm uma configuração padrão), e geralmente são dadas algumas tarefas específicas a eles. A avaliação experimental definida consiste em comparar estatisticamente a acurácia de predição de avaliação de avaliação do sistema dos dois grupos.

O protótipo contém ainda parâmetros de configuração, os quais são persistidos e editados em um arquivo de configuração, que é carregado no início da execução da aplicação no servidor. Entre esses parâmetros estão, por exemplo, a "quantidade mínima de usuários para definição de vizinhança" na filtragem colaborativa, e as configurações de baixo nível, tais como parâmetros de configuração de *pool* de conexões no banco de dados.

## 5.1 Tela Inicial

A tela inicial do protótipo (Figura 5.2) disponibiliza uma opção para que novos usuários possam se cadastrar para utilizar o sistema e uma opção para que usuários já cadastrados possam se identificar para utilizar o sistema. Adicionalmente, foram adicionadas opções para que o usuário possa escolher o idioma de sua preferência e possa recuperar sua senha de acesso, caso a perca ou esqueça.

---

<sup>20</sup> <http://www.hibernate.org/>.

<sup>21</sup> <http://jquery.com/>.

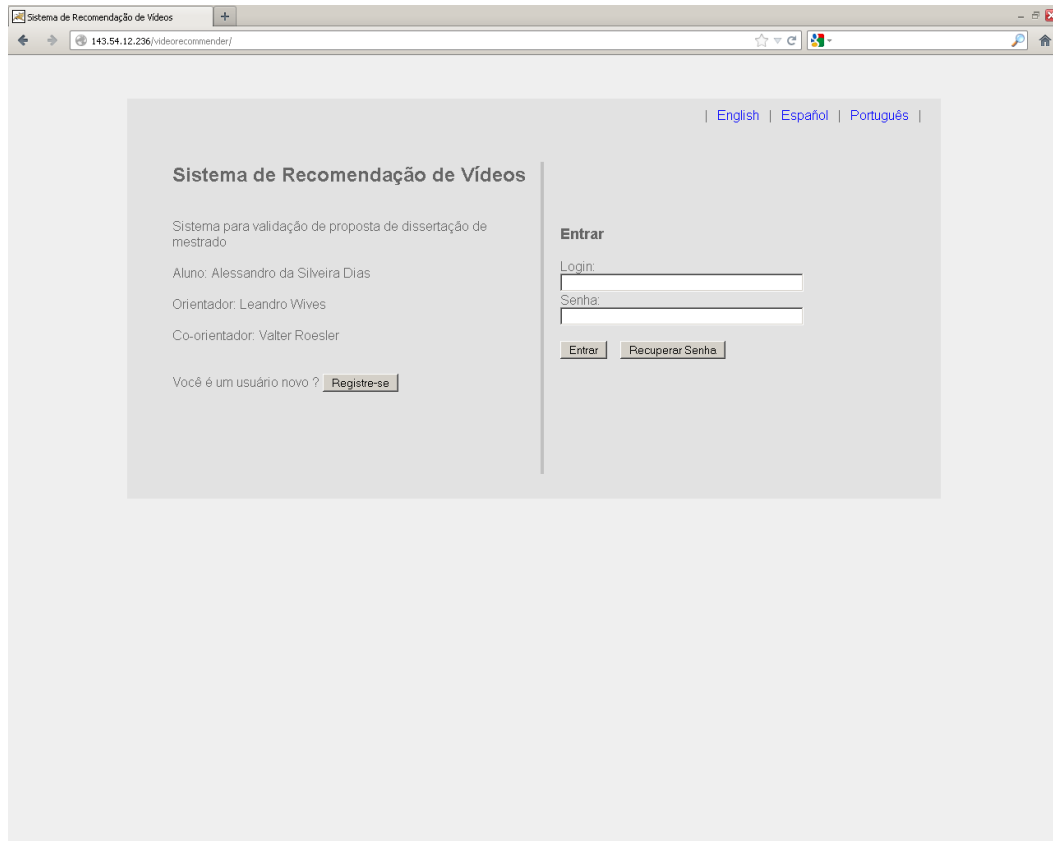


Figura 5.2: Tela inicial do protótipo.

## 5.2 Cadastro de Usuário

A tela de cadastro de usuário (Figura 5.3) possibilita que novos usuários criem uma conta de acesso ao sistema. Essa contém os campos de nome, e-mail, login, senha, e alguns campos de dados demográficos: idade, sexo, cidade e país. Há, também, um texto de aceitação na tela (exibido ao se passar o mouse sobre o ícone ao lado do botão Registrar), notificando aos participantes que estão participando de um experimento e os dados gerados por eles ao utilizarem o sistema serão utilizados em experimentos científicos.

Quando um usuário se cadastra no sistema ele é adicionado automaticamente a um dos grupos (controle ou teste). Se o último usuário cadastrado foi alocado ao grupo controle, o próximo a se cadastrar é alocado no grupo teste, e vice-versa. Cabe salientar que o primeiro usuário, por convenção, é alocado automaticamente no grupo controle.

## 5.3 Galeria de Vídeos

A tela “Galeria de Vídeos” (Figura 5.4) é apresentada após o usuário ser autenticado no sistema. Nela é apresentada uma listagem de vídeos sorteados, a qual pode ser modificada pelo usuário através do *combobox* “Categorias de Vídeos”. Este componente possibilita ao usuário buscar vídeos de categorias de seu interesse.

Para cada vídeo apresenta-se o seu título, a sua duração, um pequeno texto contendo sua descrição e uma figura para ilustrá-lo, coletada aleatoriamente de um de seus *frames*.

Na região esquerda da tela foi disponibilizada uma listagem de vídeos recomendados para o perfil do usuário ativo (logado). Essa listagem é gerada por um sistema de recomendação, detalhando na seção 5.5.

The screenshot shows a web browser window with the address bar displaying '143.54.12.236/videorecommender/cadastroUsuario'. The main content area is titled 'Sistema de Recomendação de Vídeos' and contains a registration form. The form is titled '- Cadastro de Usuário' and includes the instruction 'Informe seus dados abaixo para ter acesso ao sistema.' The form fields are arranged in two columns:

- Left column: 'Digite seu e-mail:', 'Digite um nome para seu usuário (login):', 'Digite sua senha:', 'Digite novamente sua senha:', and 'Link de sua foto:'.
- Right column: 'Digite seu nome:', 'Digite a sua idade:', 'Informe seu sexo:' (with radio buttons for 'Masculino' and 'Feminino'), 'Informe seu país:' (with a dropdown menu showing 'Brasil'), and 'Informe sua cidade:' (with a dropdown menu showing 'Porto Alegre').

At the bottom left of the form is a 'Registrar' button with a help icon.

Figura 5.3. Tela de cadastro de usuário.

## 5.4 Tela de Vídeo

A tela de vídeo (Figura 5.5) apresenta o vídeo que o usuário escolheu acessar pela “Galeria de Vídeos”, e disponibiliza opções para que o usuário avalie o vídeo e, quando desejar, marque seus pontos de interesse.

Essa tela apresenta o título do vídeo, em destaque; um pequeno texto com a descrição do vídeo; e o *player* de vídeo, com componentes de controle de vídeo, tais como *play*, *stop* e o cursor de vídeo, também utilizado para avançar e retroceder o vídeo.

Para que o usuário avalie o vídeo foi adicionado um *combobox*, o qual disponibiliza as seguintes opções de avaliação: "Muito Ruim", "Ruim", "Ok", "Bom" ou "Muito Bom". Esse *combobox* e o botão “Votar”, utilizado para confirmar a avaliação, são disponibilizados na tela assim que o usuário começa a assistir ao vídeo. Uma vez que a avaliação de vídeo é efetuada, o sistema retorna para a tela “Galeria de Vídeos”. Ao voltar para ela, o sistema apresenta uma mensagem agradecendo e solicitando que o usuário continue avaliando vídeos, com o objetivo de estimular a visualização de vídeos.



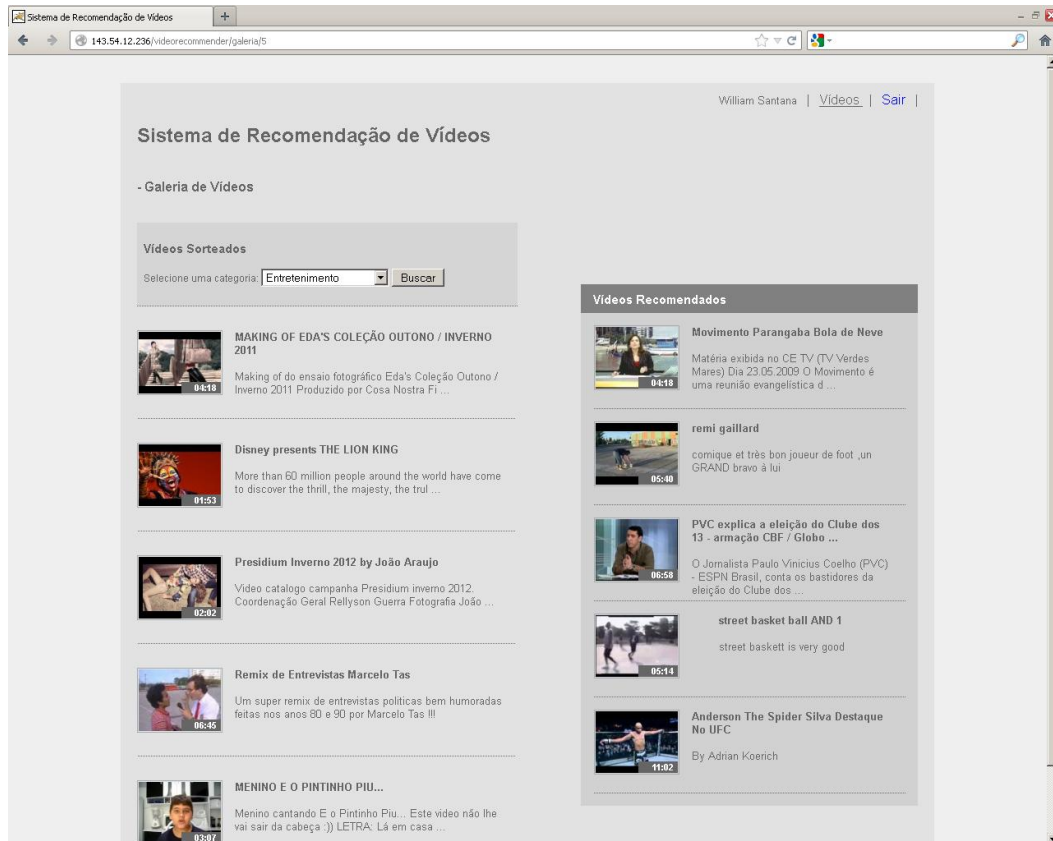


Figura 5.4: Tela de galeria de vídeos.

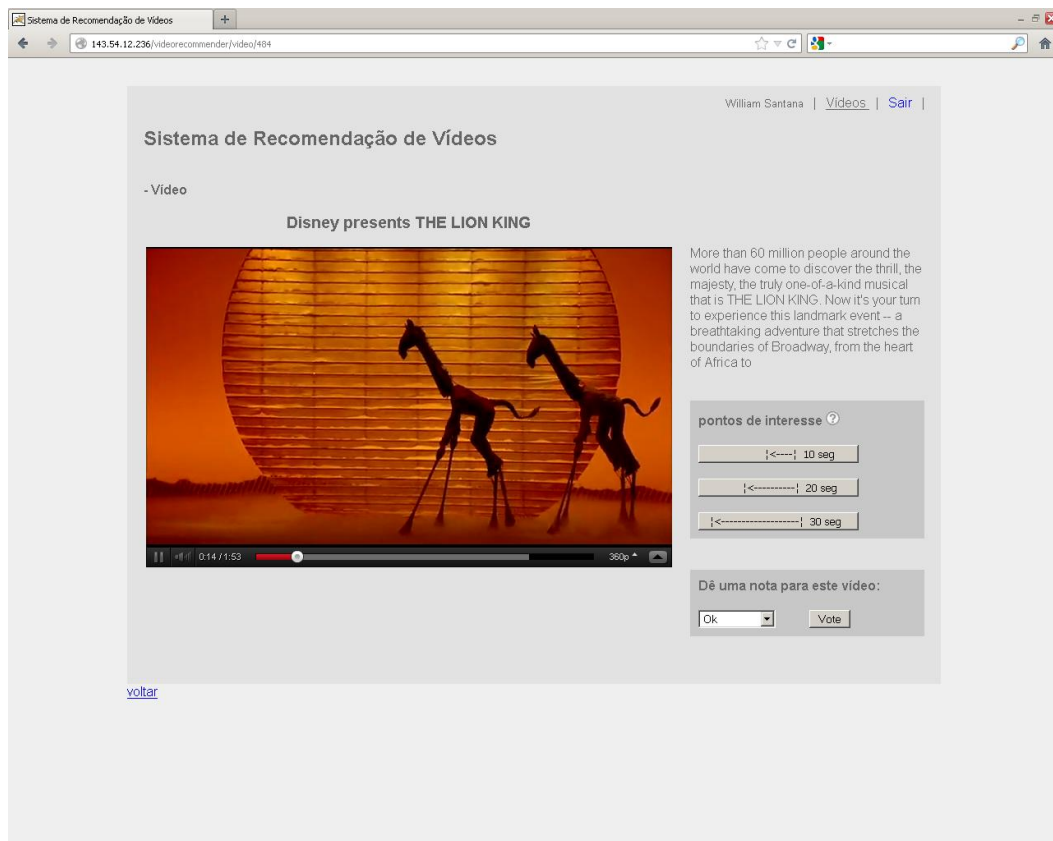


Figura 5.5: Tela de visualização de vídeo.

Para que o usuário marque seus pontos de interesse foram adicionados componentes de tela específicos. Esses componentes são disponibilizados na tela assim que o vídeo começa a ser apresentado.

Foram implementadas duas abordagens de marcação de pontos de interesse, com base na especificação apresentada na seção 4.5. São elas:

- Na primeira abordagem o usuário marca pontos de interesse através de botões de tamanho de ponto de interesse. Quando o usuário clica em um desses botões, o sistema marca um ponto de interesse do tamanho do ponto de interesse, sendo que o final desse está alinhado com o instante corrente do vídeo. No protótipo, essa abordagem foi implementada com a utilização de 3 botões: "10 segundos", "20 segundos" e "30 segundos" (Figura 5.6). Por exemplo, quando o usuário clica no botão "20 segundos" o sistema registra um ponto de interesse do instante corrente do vídeo até 20 segundos para trás no vídeo.
- Na segunda abordagem o usuário delimita na linha do tempo do vídeo o início e o final de cada um de seus pontos de interesse. No protótipo, essa abordagem foi implementada pela adição de um *slider* com 2 cursores, disposto na tela abaixo do cursor de linha do tempo do *player* de vídeo. Seu início e final é alinhado com o início e o final do cursor de linha do tempo do *player* de vídeo (Figura 5.7).



Figura 5.6: Abordagem de marcação de pontos de interesse através de botões.




Figura 5.7: Abordagem de marcação de pontos de interesse através de cursores em *slider*.

No caso da abordagem de marcação de pontos de interesse através de cursores em *slider*, adicionalmente, foi disponibilizada na tela a listagem de pontos de interesse marcados pelo usuário, listados de forma vertical e ordenados em função do tempo (Figura 5.7). Assim, o usuário pode acompanhar os pontos de interesse já marcados e pode apagar pontos de interesse caso tenha marcado errado ou mudado de ideia.

As funcionalidades relativas à marcação de pontos de interesse são apresentadas sempre na tela para os usuários, tanto do grupo controle quanto do grupo teste. Assim, ambos têm a mesma interação com o sistema.

Para definir a abordagem de marcação a ser utilizada, basta configurar o respectivo parâmetro no arquivo de configuração do protótipo.

## 5.5 Sistema de Recomendação Desenvolvido

O sistema de recomendação usado no protótipo foi implementado como um serviço e foi acoplado à tela “Galeria de Vídeos” (Figura 5.4) para fornecer os vídeos da listagem de vídeos recomendados. Tais vídeos são vídeos cuja previsão de avaliação computada tem valor maior ou igual a 4, ou seja, avaliações "Bom" e "Muito Bom" do usuário.

A Figura 5.8 mostra o diagrama de componentes desse sistema de recomendação. Tal sistema contém um componente de filtragem baseada em conteúdo e um componente de filtragem colaborativa, ambos conectados a um componente de filtragem híbrida. Acoplado ao componente de filtragem colaborativa está o componente que corresponde à função de utilidade baseada em pontos de interesse.

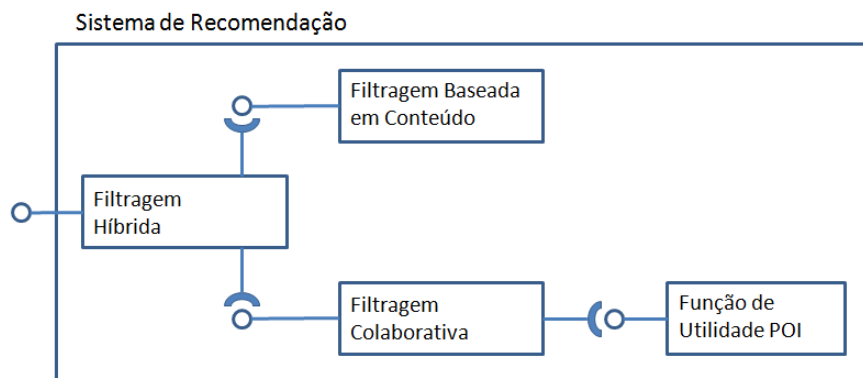


Figura 5.8: Diagrama de componentes do sistema de recomendação do protótipo.

Cada um deles é explicado a seguir.

### 5.5.1 O componente de filtragem híbrida

Lekakos; Caravelas (2006) apresentam experimentos que mostram que a acurácia de previsão de avaliação de um sistema de recomendação híbrido de vídeo baseado em filtragem baseada em conteúdo e filtragem colaborativa é maior do que a acurácia de previsão de avaliação dessas abordagens individualmente.

Com base nisso foi implementado um componente de filtragem híbrida análogo ao apresentado por Lekakos; Caravelas (2006). Sua implementação foi baseada no método de hibridização Switching (BURKE, 2002) e segue a seguinte lógica: primeiramente o sistema tenta fazer a recomendação baseada em filtragem colaborativa, caso não consiga faz a recomendação baseada em filtragem baseada em conteúdo. O uso da filtragem colaborativa como método primário é baseado na superioridade da filtragem colaborativa no domínio de recomendação de vídeo (LEKAKOS; CARAVELAS, 2006).

### 5.5.2 Componente de filtragem baseada em conteúdo

O componente de filtragem baseada em conteúdo utiliza uma técnica de recomendação comumente utilizada em Recuperação de Informação: a métrica de similaridade do cosseno. Essa métrica mede a similaridade entre dois vetores  $n$ -dimensionais baseada no ângulo entre eles. A similaridade entre dois itens (que nesse caso são vídeos)  $a$  e  $b$  – vistos como os vetores de avaliações de  $\vec{a}$  e  $\vec{b}$  – é formalmente definido na Equação 5.1 (Lekakos; Caravelas, 2006).

$$\text{sim}(\vec{a}, \vec{b}) = \frac{\vec{a} \cdot \vec{b}}{|\vec{a}| * |\vec{b}|} = \frac{\sum_i a_i b_i}{\sqrt{\sum_i a_i^2} * \sqrt{\sum_i b_i^2}} \quad (5.1)$$

onde  $\text{sim}(\vec{a}, \vec{b})$  é a similaridade entre os vídeos  $a$  e  $b$ ;  $|\vec{a}|$  é a distância Euclidiana do vetor; e  $a_i$  e  $b_i$  são os valores do  $i$ -ésimo elemento dos vetores de avaliações  $a$  e  $b$ .

A abordagem utilizada na implementação desse componente foi previamente utilizada com sucesso no domínio de vídeo em Lekakos; Caravelas (2006), e é descrita a seguir.

Cada item foi representado por um vetor de características de vídeo (*uploaders*, gêneros, tipos<sup>22</sup> de duração e palavras-chave do vídeo), cujo comprimento é igual ao número de características não exclusivas de todos os itens disponíveis. Os elementos do vetor são estados que representam a existência ou inexistência (booleano) de uma característica específica na descrição do item.

O algoritmo utilizado para produzir as recomendações é uma extensão do algoritmo baseado em itens Top-N, descrito em Karypis (2001). Devido ao fato de que o conjunto de vídeos não muda dinamicamente enquanto o sistema está *online*, as similaridades entre todos os pares de vídeos do *dataset* foram pré-computadas de forma *offline*, em uma fase de preparação do sistema, e para cada vídeo foram armazenados no banco de dados os  $k$  vídeos mais similares a ele, junto com seus respectivos valores de similaridade.

O algoritmo segue a seguinte lógica: quando um usuário que tenha avaliado positivamente (ou seja, dado uma nota 4 ou 5, que corresponde às opções "Bom" e "Muito Bom") um conjunto  $U$  de vídeos solicita recomendações, um conjunto  $C$  de vídeos candidatos à recomendação é criado como a união dos  $k$  vídeos mais similares para cada vídeo  $j \in U$ , excluindo vídeos já existentes em  $U$ . O próximo passo é calcular, a partir da métrica de similaridade do cosseno, a similaridade de cada vídeo  $c \in C$  para o conjunto  $U$  como a soma das semelhanças entre  $c \in C$  e todos os vídeos  $j \in U$ . Em seguida, os filmes em  $C$  são ordenados com base nessa similaridade. Por fim são computadas as predições numéricas (Figura 5.9).

Baseando-se no fato de que esta lógica utiliza os  $k$  vídeos similares de cada vídeo positivamente avaliado pelo usuário no passado optou-se por definir tal parâmetro como sendo 20 vídeos. Por exemplo, se um usuário avaliou positivamente 2 vídeos e cada um destes tem 20 vídeos similares então tem-se um conjunto de vídeos candidatos de no

---

<sup>22</sup> A duração dos vídeos, que é um valor numérico, foi normalizado seguindo a classificação de duração de vídeos de YouTube (2011), que considera vídeos *curtos* os vídeos com duração até 4 minutos, vídeos *médios* os com duração entre 4 minutos e 20 minutos, e vídeos *longos* os vídeos com mais do que 20 minutos de duração.

máximo 40 vídeos, o que é o suficiente para preencher a tela de galeria de vídeos, a qual apresenta apenas 5 vídeos recomendados.

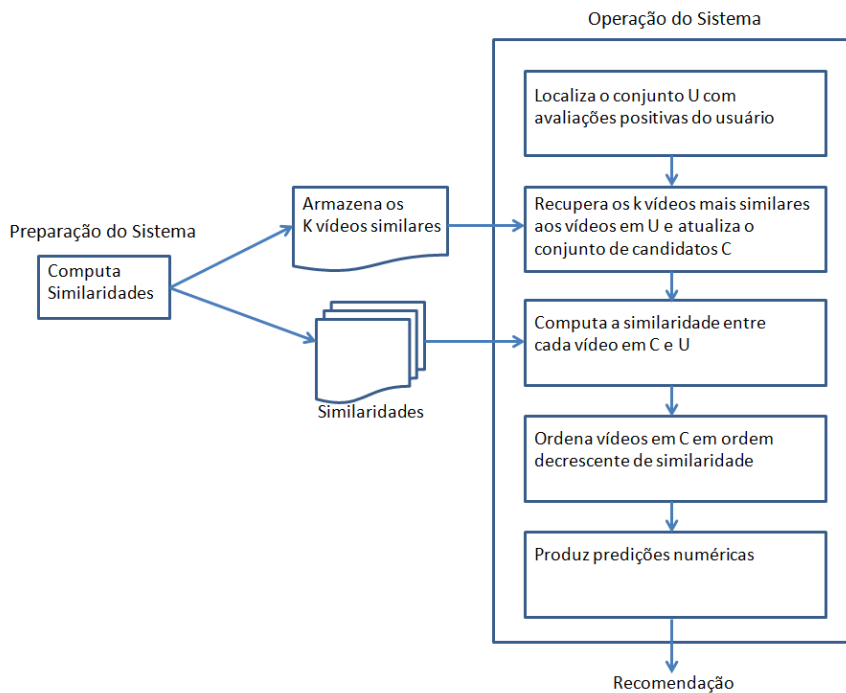


Figura 5.9: Processo de predição pelo componente de filtragem baseada em conteúdo.

Fonte: adaptado de (LEKAKOS; CARAVELAS, 2006).

Devido ao fato de se estar interessado em avaliações numéricas, a fim de depois combinar predições de filtragem baseada em conteúdo e filtragem colaborativa, o algoritmo computa a predição numérica  $Pr_i$  para o vídeo pela Equação 5.2.

$$Pr_i = 1 + \frac{(Sim_i - MinSim) * 4}{(MaxSim - MinSim)} \quad (5.2)$$

onde  $MaxSim$ ,  $MinSim$  é a máxima e a mínima similaridades para cada vídeo em  $c \in C$  para  $U$ , e  $Sim_i$  é a similaridade de um vídeo  $M_i$  para o conjunto  $U$ .

A equação acima normaliza similaridades entre  $[MaxSim, MinSim]$  para  $[1,5]$ , que é escala de avaliação utilizada na filtragem colaborativa do protótipo.

Devido ao fato de que as similaridades entre vídeos são computadas de forma *offline*, produz-se recomendações baseadas em conteúdo muito mais rápido do que recomendações baseadas em filtragem colaborativa. Ou seja, o passo "computação de similaridades entre cada vídeo em  $C$  e  $U$ " (Figura 5.9) é substituído por uma consulta ao conjunto de similaridades calculado previamente de forma *offline*.

### 5.5.3 O componente de filtragem colaborativa

O componente de filtragem colaborativa contém um algoritmo de filtragem colaborativa pura baseado em correlação usuário-usuário, o qual foi implementado conforme especificado na seção 2.7.1, ou seja, contendo um algoritmo baseado nesses 3 passos: (a) cálculo da similaridade entre o usuário ativo e os outros usuários existentes,

(b) construção de vizinhança, e (c) computação da predição baseada na média ponderada das avaliações dos usuários da vizinhança sobre o item alvo.

Como entrada o componente recebe uma matriz de avaliações de vídeos, cujos valores são numéricos de 1 a 5 e correspondem às opções de avaliação "Muito Ruim", "Ruim", "Ok", "Bom" e "Muito Bom" do protótipo. Como saída é retornado um valor Real que representa a predição de avaliação.

Foi implementada uma segunda versão desse componente, na qual o algoritmo de filtragem colaborativa pura está sob ação da função de utilidade baseada em pontos de interesse, ou seja, utiliza o componente da função de utilidade, o qual foi implementado conforme especificado na seção 4.4.

A versão do componente de filtragem colaborativa a ser utilizada é definida em tempo de execução: se o usuário ativo é do grupo controle, é utilizada a primeira versão (filtragem colaborativa pura), caso seja do grupo teste, é utilizada a segunda versão (filtragem colaborativa pura sob ação da função de utilidade).

## 5.6 Função de Utilidade Baseada em Pontos de Interesse

A função de utilidade foi implementada como um componente e seguindo a especificação da seção 4.3. Contém:

- na interface de entrada o par de usuários (sendo o primeiro, o usuário *base* - usuário ativo, foco da recomendação - e o segundo, o *outro* usuário, o qual é comparado com o usuário *base* para o cálculo de similaridade);
- na interface de saída o valor Real a ser retornado, no intervalo entre [0,1], e que representa o grau de similaridade do par de usuários.

Foram criados três parâmetros no arquivo de configuração do protótipo, que correspondem aos limiares propostos (T, N e M) para buscar usuários semelhantes ou com gosto em comum em relação a vídeo, propostos na seção 4.3. A Tabela 5.1 mostra exemplos de valores destes parâmetros.

Tabela 5.1: Exemplos de valores aceitáveis para os limiares propostos para a função de utilidade

<i>Identificador</i>	<i>Descrição</i>	<i>Exemplo de valor</i>
T	tamanho mínimo de intersecção de pontos de interesse (tamanho aceitável de intersecção)	7 segundos
N	quantidade mínima de intersecções de pontos de interesse de tamanho aceitável T por vídeo	2 intersecções
M	quantidade mínima de vídeos onde ocorrem N intersecções de tamanho aceitável T	3 vídeos

Internamente, o componente de função de utilidade utiliza um algoritmo que calcula o grau de similaridade de um par de usuários em três passos: (a) carga de todos os POI do usuário *base* e de todos os POI do *outro* usuário em todos os vídeos avaliados pelo usuário *base*, (b) verificação se o par de usuário tem um conjunto de no mínimo M

vídeos onde ocorram no mínimo  $N$  intersecções aceitáveis de POI de tamanho  $T$  segundos, e (c) computação do valor de retorno: caso a verificação feita do passo (b) seja negativa, o valor de retorno é 0, mas caso seja positiva, o valor de retorno é a razão entre o "número total de intersecção de pontos de interesse do par de usuários" e o "número total de pontos de interesse do usuário *base*". Por exemplo, se ao chegar no passo (c) um par de usuários tiver "número total de intersecção de pontos de interesse do par de usuários" igual a 25 e o "número total de pontos de interesse do usuário *base*" igual a 50 então a razão será 25/50, ou seja, o par de usuário terá grau de similaridade igual a 0.5 (o que corresponderia a um aumento de 50% na de similaridade  $sim^{FC}$  da Equação 4.1).

## 6 AVALIAÇÃO EXPERIMENTAL

A avaliação experimental da proposta apresentada consiste na avaliação da acurácia de predição do sistema de recomendação em termos de acurácia de predição de avaliação, ou seja, avaliar a acurácia do sistema ao predizer a avaliação do usuário.

Para essa avaliação experimental foram planejados dois experimentos:

- Experimento 1: experimento com vídeos e usuários de um domínio específico (vídeos educacionais e alunos), e a marcação de pontos de interesse sendo realizada seguindo a abordagem onde se delimita o início e o fim do ponto de interesse;
- Experimento 2: experimento com vídeos genéricos (de diferentes categorias como notícias, filmes, esportes, etc.) e usuários genéricos, e a marcação de pontos de interesse sendo realizada seguindo a abordagem baseada no uso de botões.

### 6.1 Preparação dos Experimentos

Para montar o catálogo de vídeos de cada um dos experimentos foi desenvolvido um *crawler* que coleta dados de vídeos do YouTube. Tais dados são: título do vídeo, duração (em segundos), conjunto de palavras-chave, descrição, categorias dos vídeos no site YouTube, ID do vídeo no YouTube, URL do vídeo, URL da imagem de *preview* e *uploader*. O *uploader* é o usuário que disponibilizou o vídeo no YouTube.

Para o Experimento 1 foi montado um catálogo contendo 50 vídeos educacionais da área de Algoritmos de Classificação e Pesquisa de Dados. Cada vídeo foi adicionado manualmente a uma dentre as cinco categorias disponibilizadas, que, nesse caso corresponderam aos seguintes algoritmos: Bubblesort, Insertionsort, Mergesort, Quicksort e Selectionsort. A escolha dos vídeos foi feita manualmente, sendo escolhidos 10 vídeos de cada algoritmo. Inferiu-se com base na quantidade de vídeos apresentadas por vez na tela do protótipo que 10 vídeos de cada algoritmo seriam o suficiente para o experimento. Tais vídeos têm durações diferentes e são agrupados e listados abaixo de acordo com a classificação de duração de vídeos de YouTube (2011):

- vídeos curtos (até 4 minutos): 29;
- vídeos médios (entre 4 minutos e 20 minutos): 21;
- vídeos longos (mais do que 20 minutos): 0.

Para o Experimento 2 foi montado um catálogo contendo 105 vídeos de diversos domínios. Cada vídeo pode pertencer a uma ou mais categorias de vídeo, que nesse caso



foram as seguintes: Notícia e Política, Filmes e Desenhos, Esportes, Pessoas e Blogs, Entretenimento, Educação, Ciência e Tecnologia. Para a escolha dos vídeos, inicialmente foram escolhidos manualmente alguns *uploaders* e a partir desses foram buscados automaticamente todos os seus vídeos. Em seguida fez-se uma escolha aleatória de vídeos para que cada categoria contivesse apenas 15 vídeos, pois na tela de galeria de vídeos são exibidos apenas 5 vídeos sorteados por vez. (É possível fazer várias combinações de 5 vídeos em um grupo de 15 vídeos, logo com estas combinações dá-se uma percepção de sorteio ao usuário mesmo tendo poucos vídeos por categoria). Por fim, fez-se uma substituição manual de vídeos para retirar os mais longos (mais de 20 minutos), pois poderiam trazer cansaço aos participantes durante a execução do experimento. Ao final teve-se a seguinte listagem de vídeos, agrupados de acordo com a classificação de duração de vídeos de YouTube (2011):

- vídeos curtos (até 4 minutos): 43;
- vídeos médios (entre 4 minutos e 20 minutos): 62;
- vídeos longos (mais do que 20 minutos): 0.

## 6.2 Protocolo Experimental

Inicialmente planejou-se que a avaliação experimental a ser realizada seria a do tipo Estudo de Usuário, utilizando *A-B testing*. A escolha desse tipo de avaliação, como já mencionado previamente, foi baseada no fato de que o foco de pesquisa estava diretamente relacionado com interesse e gosto pessoal; no fato da não existência de *datasets* de pontos de interesse em vídeo; e pelo fato de que, segundo Ricci et al. (2011), tal tipo de avaliação provê uma configuração próxima a sistemas reais. A partir desse planejamento foram desenvolvidas características adicionais no protótipo implementado, apresentadas previamente.

Porém percebeu-se que tal tipo de avaliação experimental não poderia ser realizada pelo fato de que não se saber de antemão os valores ótimos dos parâmetros a serem configurados no protótipo (parâmetro de "tamanho mínimo de vizinhança", na filtragem colaborativa, e parâmetros T, N e M, da função de utilidade). A utilização de valores não ótimos em tais parâmetros poderia comprometer o experimento. Então, resolveu-se mudar o tipo de avaliação experimental a ser aplicada. Felizmente o protótipo desenvolvido poderia ser utilizado nesse novo tipo de avaliação, com uma pequena modificação: todos os usuários cadastrados seriam adicionados ao grupo controle. Assim a função de utilidade não atuaria sobre o sistema durante o uso do sistema.

Segundo Ricci et al. (2011), após fazerem uma larga revisão do processo de avaliação experimental de sistemas de recomendação, os experimentos que podem ser feitos para avaliar sistemas de recomendação dividem-se em 3 tipos: experimento *offline*, estudo de usuário e experimento *online*. De acordo com eles, a melhor forma, e menos custosa, de avaliar sistemas de recomendação é primeiro realizar um experimento *offline*, em seguida estudo de usuário, e por fim realizar experimento *online*. Além disso, eles apontam que na fase de experimento *offline* já podem ser descartados candidatos (algoritmos sendo avaliados) e podem ser descobertos valores ótimos de parâmetros do sistema que podem ser utilizados em avaliações subsequentes baseadas em estudo de usuário ou experimento *online*. Com base nisso, resolveu-se realizar avaliação do tipo experimento *offline*, conforme detalhado a seguir. O protótipo desenvolvido poderia ser totalmente aproveitado para a montagem do *dataset* histórico

(que é o requisito para o experimento *offline*) sendo necessária apenas a pequena modificação no cadastro de usuário já citada.

Em experimentos *offline*, a avaliação de um sistema de recomendação consiste na partição do *dataset* histórico (dados gerados pelos usuários ao utilizarem o sistema) em duas partes diferentes: a primeira, referida como partição de treino, é dedicada à construção do modelo, e a segunda parte, referida como partição de teste, é usada para testar o modelo construído. Ricci et al. (2011) lembram da existência de um erro comum chamado de “*tuning to the test set*”, o qual ocorre quando a partição de teste é utilizada também para ajuste de parâmetros do algoritmo de recomendação. Os autores orientam separar aleatoriamente uma parte do *dataset* para ajuste de parâmetros e, na parte restante, realizar uma segunda separação de dados: uma partição para treino e outra partição para teste. Os dados utilizados para ajuste de parâmetro são desconsiderados na fase de treinamento e teste de modelo de predição.

Ainda em relação à partição do *dataset* histórico, na literatura existem diferentes técnicas de partição. Por exemplo, Ricci et al. (2011) cita a técnica *n-fold cross validation*<sup>23</sup> e apresenta 5 variações/estratégias desta no domínio de sistemas de recomendação.

Jannach et al. (2010) orientam que quando a quantidade de perfis do *dataset* histórico é pequena, ou seja, não se tem milhares de perfis de usuário, a estratégia *leave-one-out*, que é uma variação de *n-fold cross validation*, faz mais sentido de ser utilizada. Nessa, cada perfil de usuário é considerado uma partição; adicionalmente durante o teste o perfil de usuário deve ser particionado em duas partes, chamadas de "dados do perfil de usuário para treino" (para encontrar usuários similares no caso da filtragem colaborativa) e "dados do perfil de usuário para avaliação de predição". Essa estratégia, embora do ponto de vista computacional seja extremamente custosa, pois o modelo tem que ser reconstruído a cada teste de predição realizado, permite ao algoritmo explorar a maior quantidade de dados possível para aprendizagem/treino de modelo. Essa estratégia, a qual foi escolhida para ser utilizada nos experimentos propostos deste trabalho, utiliza a maior quantidade possível de dados para aprendizagem/treino de modelo, ou seja, utiliza como teste uma avaliação de item por vez de cada perfil e constrói o modelo com os dados restantes. Esse procedimento é repetido para cada avaliação de item do *dataset* histórico. Esse procedimento de avaliação já foi utilizado previamente em recomendação de vídeos, por Breese; Heckerman; Kadie (1998) e por Deshpande; Karypis (2004).

A Figura 6.1 é utilizada para ilustrar o procedimento apresentado acima na parte separada para treino e teste de predição. Nela, para facilitar a compreensão, as avaliações de vídeo do *dataset* histórico foram agrupadas por perfil de usuário. Por exemplo, as linhas de #3 até #5 são avaliações do perfil do usuário #16; focando na linha #3 tem-se que o usuário #16 avaliou o vídeo #11 com uma nota "Muito Bom" (que corresponde numericamente à avaliação de nota 5). Conforme descrito previamente, nesta estratégia *leave-one-out*, de forma a utilizar a maior quantidade possível de dados para aprendizagem/treino de modelo, utiliza-se a cada iteração uma avaliação para teste

---

<sup>23</sup> Na estratégia padrão *n-fold cross validation* o *dataset* é dividido em *n* partições (*folds*) aleatoriamente estratificadas: em um processo com *n* iterações, *n-1* partições são usadas para construir o modelo e uma partição é dedicada para o teste. Ao final, calcula-se a performance média de teste do sistema. Duda et al. (2000) e Witten; Frank (2005) citam 10 como sendo o número ótimo de *folds* para se ter um teste robusto.

e as demais para aprendizagem/treino de modelo. Por exemplo, a avaliação de vídeo da linha #8, destacada com um asterisco vermelho e que corresponde aos "dados de perfil de usuário para teste", está sendo utilizada para teste de predição na iteração corrente, e todas as demais avaliações são utilizadas para aprendizagem/treino, ou seja, as demais avaliações do perfil de usuário da avaliação em teste de predição (destacadas em azul e que correspondem aos "dados de perfil para treino") e as avaliações dos demais perfis.

Linha	Usuário	Vídeo	Avaliação
...	...	...	...
3	16	11	5
4	16	22	3
5	16	38	5
6	34	17	1
7	34	21	3
8	34	42	2 *
9	34	45	3
10	52	37	3
11	52	21	4
12	52	42	1
...	...	...	...

6.1: Um exemplo de partição de *dataset* histórico de avaliações de vídeo separado para treino e teste de modelo sendo utilizando para predição de avaliações

A métrica de avaliação escolhida para estimar a acurácia de predição de avaliação de modelo foi o RMSE (*Root Mean Square Error* - Raiz do Erro Quadrático Médio) por ser uma métrica apropriada para medição de precisão em sistemas que utilizam avaliações numéricas de usuários<sup>24</sup> e predições numéricas, além de ser uma métrica comumente utilizada na avaliação experimental de sistemas de recomendação de vídeo (WEN, 2008; KOREN; Bell; VOLINSKY, 2009; GRIMBERGHE; NANOPOULOS; THIEME, 2010; LAKIOTAKI; MATSATSINIS; TSOUKIAS, 2011). Ela é detalhada a seguir.

Sejam  $r_1, \dots, r_n$  as avaliações reais de um usuário em um conjunto de teste,  $p_1, \dots, p_n$  são as avaliações preditas, e  $E = e_1, \dots, e_n = \{p_1 - r_1, \dots, p_n - r_n\}$  são os erros, então a raiz do erro quadrático médio (RMSE) é calculada pela Equação 6.1.

$$RMSE = \sqrt{E^2} = \sqrt{\frac{\sum_{i=1}^n e_i^2}{n}} \quad (6.1)$$

Por fim, para garantir que os resultados obtidos fossem confiáveis, ou seja, que os resultados não tivessem sido obtidos ao acaso, planejou-se aplicar o teste de significância estatística Wilcoxon *signed rank test*. No domínio de sistemas de recomendação, Ricci et al. (2011) orientam comparar com esse teste o desempenho (que nesse caso foi por RMSE) do par de algoritmos testados por perfil de usuário.

<sup>24</sup> As opções de avaliação de vídeos "Muito Ruim", "Ruim", "Ok", "Bom" e "Muito Bom" correspondem às avaliações numéricas 1, 2, 3, 4 e 5 respectivamente.

Além de tudo isso, definiu-se que os usuários ficariam livres para escolher os vídeos que quisessem assistir, e que seria solicitado para que marcassem seus pontos de interesse toda vez que houvesse algum.

### 6.3 Experimentos Realizados

A seguir são apresentados os dois experimentos realizados e os resultados obtidos.

#### 6.3.1 Experimento 1: Vídeos Educacionais

Os participantes desse experimento foram alunos de três turmas da disciplina de Classificação e Pesquisa de Dados do curso de Graduação em Ciência da Computação da UFRGS no ano de 2012.

Alguns alunos participaram pouco, avaliando menos de 10 vídeos. Os perfis que tiveram esse tipo de participação, e seus dados, foram desconsiderados do *dataset* durante o experimento. Essa é uma prática comumente utilizada para evitar o problema do "usuário novo". Por exemplo, no MovieLens exige-se que o usuário tenha no mínimo 20 avaliações de vídeo para o sistema então iniciar a recomendar.

Com isso foi montado um *dataset* de dados históricos da utilização do protótipo contendo:

- 764 avaliações de vídeos;
- 269 pontos de interesse;
- 88 perfis de usuários (sendo 40 perfis da turma 1, 29 da turma 2 e 19 da turma 3).

Após a coleta do *dataset* histórico iniciaram-se os preparativos para realizar o experimento *offline*. Inicialmente, para evitar o problema “*tuning to the test set*”, foi feita a seguinte separação aleatória do *dataset*: os dados de 1/3 dos perfis de usuários foram utilizados para ajuste de parâmetros, e 2/3 para treino e teste de modelo de predição através da estratégia *leave-one-out*, conforme descrito previamente. Assim, teve-se a seguinte separação apresentada na Tabela 6.1.

Tabela 6.1: Separação randômica do *dataset* em dados para ajuste de parâmetros e dados para treinamento e teste de modelo de predição

<i>Turma</i>	<i>Perfis de usuários para ajuste de parâmetros (1/3)</i>	<i>Perfis de usuários para treinamento e teste de modelo de predição (2/3)</i>
turma 1	13	27
turma 2	9	20
turma 3	6	13
Total	28	60

Para determinar o valor ótimo do parâmetro "tamanho mínimo de vizinhança" do algoritmo de filtragem colaborativa pura o *leave-one-out* foi executado sobre os dados separados para treinamento de parâmetros à medida que foi sendo variado o tamanho

mínimo de vizinhança. Assim para cada tamanho mínimo de vizinhança o erro do sistema foi sendo calculado, com base na métrica RMSE. Essa abordagem que utiliza a estratégia *leave-one-out* para determinação de parâmetros é utilizada em vários trabalhos, tais como o de Wen (2008), o de Koren; Bell; Volinsky (2009), o de Grimberghe; Nanopoulos; Thieme (2010) e o de Lakiotaki, Matsatsinis; Tsoukias (2011).

Como mostrado na Figura 6.2, o ponto de menor erro do sistema, ou seja, de maior precisão, ocorre quando o tamanho da vizinhança é de no mínimo três vizinhos (usuários).

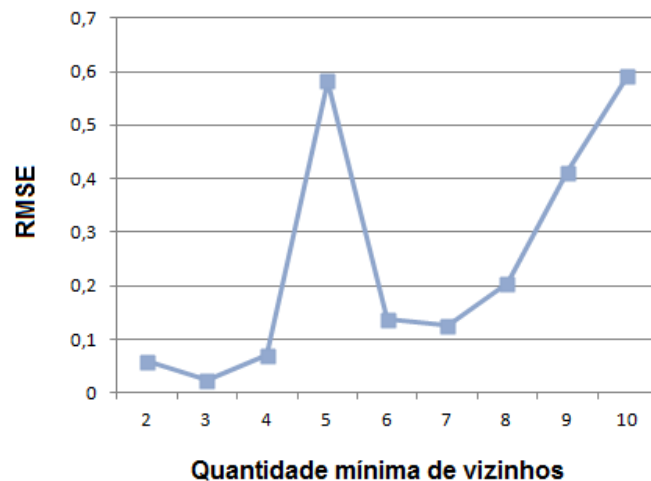


Figura 6.2: Erro do sistema à medida que varia o tamanho mínimo da vizinhança.

Para determinar o valor ótimo dos parâmetros da função de utilidade o *leave-one-out* foi executado sobre os dados separados para treinamento de parâmetros à medida que foram sendo variados. Assim para cada combinação de parâmetros o erro do sistema foi sendo calculado, com base na métrica RMSE. Essa abordagem que utiliza o *leave-one-out* para ajustar parâmetros é utilizada por Ghazanfar; Prügel-Bennett (2010-a; 2010-b).

Na Tabela 6.2 são listados os valores dos parâmetros acompanhados de seus valores de erro RMSE. Tal valor variou entre 0,0230 e 0,0297, sendo que o valor de erro mínimo ocorreu para diferentes parâmetros. Assim foi escolhido o conjunto de parâmetros que teve menor erro e foi menos restritivo<sup>25</sup>, ou seja,  $T=5$ ,  $N=2$  e  $M=2$  (destacado na listagem).

Tabela 6.2. Valores de parâmetros da função de utilidade acompanhados de seus valores de erro RMSE

$T$	$N$	$M$	$RMSE$
5	1	2	0,0297
5	1	3	0,0297

<sup>25</sup> Um conjunto de parâmetros é mais restritivo se ele tem valores maiores, ou seja, a função de utilidade é mais rígida ao buscar usuários com interesses em comum ou gosto similar em relação a vídeo. Por exemplo, um conjunto de parâmetros  $T=5$ ,  $N=3$ ,  $M=2$  é mais restritivo do que  $T=5$ ,  $N=2$ ,  $M=2$ , pois no primeiro caso é necessário no mínimo 3 interseções aceitáveis por vídeo, enquanto que no segundo caso basta que haja apenas 2 interseções aceitáveis no mínimo por vídeo.

<i>T</i>	<i>N</i>	<i>M</i>	<i>RMSE</i>
<b>5</b>	<b>2</b>	<b>2</b>	<b>0,0230</b>
5	2	3	0,0230
5	3	2	0,0230
5	3	3	0,0230
6	1	2	0,0297
6	1	3	0,0297
6	2	2	0,0230
6	2	3	0,0230
6	3	2	0,0230
6	3	3	0,0230
7	1	2	0,0256
7	1	3	0,0230
7	2	2	0,0230
7	2	3	0,0230
7	3	2	0,0230
7	3	3	0,0230
8	1	2	0,0230
8	1	3	0,0230
8	2	2	0,0230
8	2	3	0,0230
8	3	2	0,0230
8	3	3	0,0230
9	1	2	0,0230
9	1	3	0,0230
9	2	2	0,0230
9	2	3	0,0230
9	3	2	0,0230
9	3	3	0,0230
10	1	2	0,0230
10	1	3	0,0230
10	2	2	0,0230
10	2	3	0,0230
10	3	2	0,0230
10	3	3	0,0230

Após a fase de ajuste de parâmetros foi realizado o teste *offline* através da estratégia *leave-one-out*, conforme descrito previamente, nos 2/3 dos perfis restantes. Foi utilizado apenas o componente de filtragem colaborativa no treinamento-teste, pois é ele que sofre a ação da função de utilidade.

O sistema de recomendação conseguiu realizar 553 predições de avaliações de vídeo com base em filtragem colaborativa. Quando essa foi testada novamente, porém sob a ação da função de utilidade baseada em pontos de interesse, houve uma diminuição de erro do sistema de 16,72 % (ou seja, houve aumento de acurácia), apresentado na Figura 6.3. Das 553 predições, 58 sofreram ação da função de utilidade.

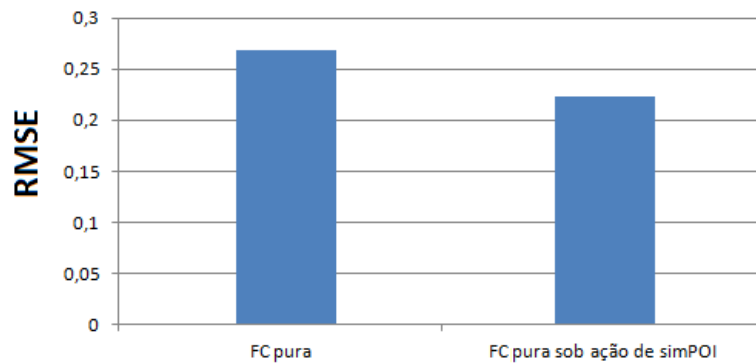


Figura 6.3: Erro do sistema sem e com o uso da função de utilidade baseada em pontos de interesse.

Em seguida foi realizado o teste de significância estatística. Foi aplicado o teste Wilcoxon *signed rank test* e obteve-se um  $p\text{-value} = 0,5566$  (com 95% de confiança), o que mostrou que o resultado não foi estaticamente significativo. Para ser estatisticamente significativo deveria haver um  $p\text{-value} \leq 0,0005$ , com 95% de confiança.

Foi feita uma verificação adicional no *dataset* histórico, montado a partir do uso do sistema, após o teste de significância estatística, e verificou-se que houveram muitos participantes que agiram de forma passiva, ou seja, avaliaram vários vídeos e não marcaram nenhum ponto de interesse (um destes relatou informalmente que lembrava da solicitação feita para sempre marcar os pontos de interesse, quando houvessem, mas não quis realizar a marcação de seus pontos de interesse). Dos 60 perfis de usuário utilizados para treinamento e teste de modelo apenas 29 marcaram pontos de interesse em vídeo, quase 50%. Provavelmente com uma participação mais ativa por parte dos participantes, ou seja, com um percentual maior de participação na marcação de pontos de interesse, a melhora na acurácia de predição de avaliação obtida poderia ser reforçada pela comprovação de que houve melhora estatisticamente significativa.

Como ocorreu melhora da acurácia de predição de avaliação no sistema de recomendação (diminuição do erro), porém o resultado não foi estatisticamente significativo, foram feitos testes adicionais para avaliar se o resultado foi obtido ao acaso ou não. Esses testes adicionais são apresentados abaixo.

a) Erro do sistema em cada uma das três turmas isoladamente

A Figura 6.4 apresenta o erro do sistema em cada uma das três turmas isoladamente. Nas turmas 1 e 3 não houve usuários com interesses similares ou gosto em comum em relação a vídeo, assim a filtragem colaborativa não sofreu ação da função de utilidade. Na turma 2 a função de utilidade atuou sobre 23 das 213 predições, ocorrendo uma diminuição do erro de 11,36 %.

b) Erro do sistema à medida que o *dataset* cresceu (novos perfis de usuário passaram a fazer parte do sistema)

A Figura 6.5 apresenta o erro do sistema à medida que o *dataset* cresceu, ou seja, à medida que aumentou o número de perfis de usuário no sistema. Quando foi testado com apenas uma turma (Turma 1) não houve usuários com interesses similares ou gosto

em comum em relação a vídeo, logo a filtragem colaborativa não sofreu ação da função de utilidade. Quando foi testado com duas turmas (Turmas 1 e 2) a função de utilidade atuou sobre 54 das 351 predições, ocorrendo uma diminuição do erro de 35,59%. Quando foi testado com três turmas (Turmas 1, 2 e 3), a função de utilidade atuou sobre 58 das 553 predições, ocorrendo uma diminuição de erro de 16,72 %.

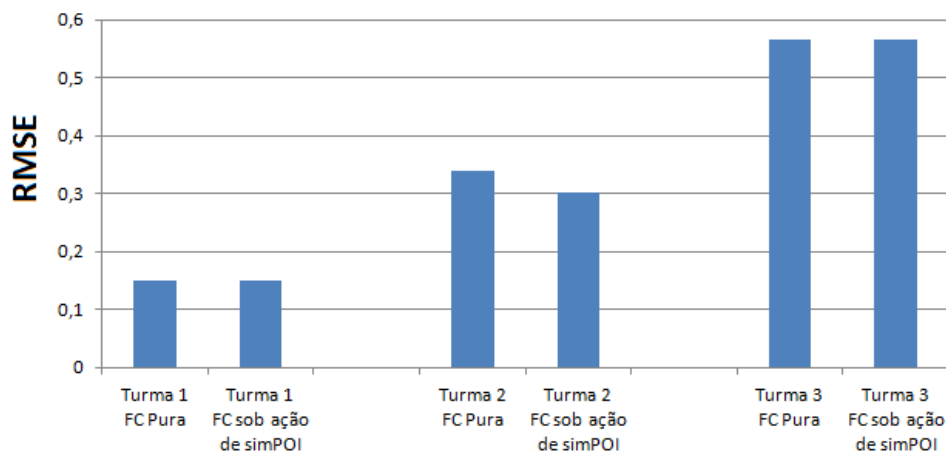


Figura 6.4: Erro do sistema em cada uma das 3 turmas isoladamente.

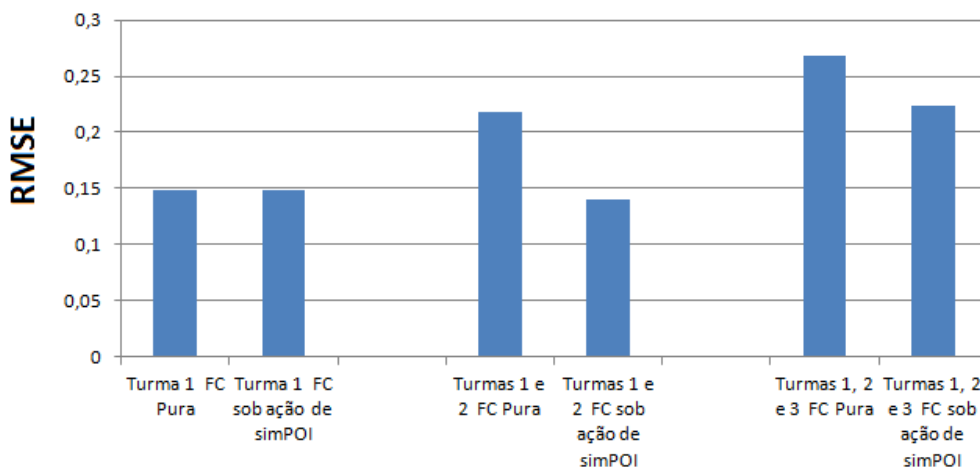


Figura 6.5: Erro do sistema à medida que o *dataset* cresceu.

Os resultados do experimento mostraram que houve aumento na acurácia de predição de avaliação do sistema de recomendação (diminuição do erro de predição) quando esse sofreu ação da função de utilidade (mesmo tendo havido usuários agindo de forma passiva, ou seja, avaliando vários vídeos e não marcando nenhum ponto de interesse). Embora o resultado não tenha tido significância estatística analisando-se o erro do sistema nos *datasets* de cada uma das turmas isoladamente e à medida que o *dataset* aumentava com a entrada de novas turmas, verificou-se que o erro diminuiu em todos os casos onde a função de utilidade atuou sobre o sistema. Esses são indícios de que os resultados não foram obtidos ao acaso e de que quando os testes forem aplicados a um *dataset* formado por milhares de usuários (e mais ativos) provavelmente haja uma melhora estatisticamente significativa.



Cabe resaltar que a técnica de amostragem estatística escolhida para esse experimento foi a do tipo Amostra por Conveniência, ou seja, é uma amostra formada por elementos que se reuniu na pesquisa simplesmente porque se dispunha deles. Conseqüentemente nessa técnica muitas vezes a amostra pode ser tendenciosa, o que requer muito sendo crítico ao se analisar os resultados. Existem outras técnicas, tais como, Amostra Sistemática e Amostra Estratificada, as quais são aplicadas quando se tem disponíveis numerosos elementos de uma população. Maiores detalhes sobre tais técnicas podem ser obtidos em Bussab; Bolfarine (2005).

### **6.3.2 Experimento 2: Vídeos Genéricos (filmes, notícias, esportes, etc.)**

Para que esse experimento tivesse uma quantidade grande de participantes (mais de 1000 pessoas) o sistema não foi disponibilizado apenas localmente, mas sim em nível nacional - pela Internet. Optou-se por fazer isso porque quanto maior é a amostra da população, ou seja, o número de perfis de usuário, maior é a chance de que os resultados sejam estatisticamente significativos.

Os participantes para esse experimento foram convidados através de convites por e-mail. Os convites foram enviados para os e-mails de comissões de vários cursos de universidades brasileiras, para que esses os repassassem para seus alunos de graduação, mestrado e/ou doutorado. Também foram enviados tais convites para os administradores de algumas listas de e-mail do Yahoo Grupos para que esses repassassem aos integrantes das suas listas de e-mail.

No convite nenhuma forma de recompensa por participar do experimento foi oferecida. Os participantes atuaram como voluntários. Um responsável de lista de e-mail pediu uma confirmação para se certificar de que se tratava de um experimento sério, e não um *spam*. Outro administrador de lista exigiu o parecer de uma comissão de ética para encaminhar o convite do experimento para sua lista de e-mail, mas não se providenciou tal avaliação previamente. Somente alguns responsáveis de lista informaram que encaminharam os convites para os participantes de suas listas.

Ao final apareceram apenas 142 voluntários para participarem do experimento. As idades variaram entre 17 e 58 anos; participaram 58 pessoas do sexo feminino e 86 do sexo masculino, de diferentes cidades do Brasil.

O sistema ficou disponível por duas semanas. Porém houve poucas avaliações de vídeo. Apenas nove participantes assistiram a mais de 10 vídeos, 55 assistiram a menos de quatro, e 59 participantes se cadastraram para acessar o sistema, mas não assistiram a nenhum vídeo. Provavelmente esses foram curiosos, que se cadastraram apenas para ver como funcionava o sistema. Com isso, o experimento 2 não pôde ser realizado.

Foi realizada uma pesquisa ao final da segunda semana com os participantes que avaliaram cinco ou menos vídeos para se saber o motivo de tão baixa participação. Poucos responderam e, na maioria, acusaram a falta de tempo para utilizar o sistema.

Com base na experiência adquirida neste experimento e no experimento 1 verificou-se que a abordagem proposta pode ser considerada como muito intrusiva no sentido de que requer um *feedback* explícito do usuário e também um nível significativo de envolvimento. Assim fica clara a necessidade da inclusão de mecanismos de compensação ou de mecanismos para estimular a participação das pessoas, pelo menos no início da utilização do sistema quando a função de utilidade não atua pelo fato de haverem poucos vídeos, ou nenhum, com pontos de interesse marcados.

## 6.4 Artefatos dos Experimentos

Durante o desenvolvimento da pesquisa foram desenvolvidos os seguintes artefatos:

- protocolo experimental;
- protótipo;
- *crawler* de vídeos;
- catálogos de vídeo;
- *dataset* histórico de uso do sistema (no contexto de vídeos educacionais).

O protocolo experimental consta no texto deste trabalho. O protótipo (tanto em versão binária quanto em versão código-fonte aberto), os dois catálogos de vídeos e o *dataset* histórico serão disponibilizados para *download* na Web, assim que forem tratadas questões de licenciamento de software, para que possam ser utilizados em pesquisas futuras ou estendidos/adaptados para outras pesquisas.

O *crawler* não é disponibilizado para *download*, pois não foi gerada uma versão executável dele. Essa execução foi realizada dentro da IDE Eclipse<sup>26</sup>, utilizando suas funcionalidades e de forma a ir criando os catálogos de vídeos incrementalmente. Essa abordagem foi necessária porque a API do YouTube bloqueia IP que realizam um número de requisições de vídeo por minuto acima da média estabelecida. Tal fato só ficou sendo conhecido durante a execução do *crawler*. Investigando-se o que poderia ter ocorrido, encontrou-se a descrição dessa restrição na documentação da API. Como a modificação do *crawler* para atender essa restrição demandaria tempo optou-se por ir executando o *crawler* incrementalmente dentro da IDE.

Tais artefatos a serem disponibilizados poderão ser utilizados, por exemplo, para avaliar a abordagem proposta (ou mesmo outras abordagens de recomendação de vídeo) em outras dimensões, tais como acurácia de predição de classificação, cobertura, novidade, robustez, privacidade, entre outras dimensões. Além disso, podem ser utilizados em pesquisas envolvendo recomendação de vídeo com foco em outras áreas, tais como, Interação Humano-Computador (IHC) e Processamento Paralelo e Distribuído.

---

<sup>26</sup> <http://www.eclipse.org/>

## 7 CONCLUSÕES

As técnicas de recomendação (recomendação baseada em conteúdo, recomendação baseada em filtragem colaborativa e abordagens híbridas) têm sido utilizadas com sucesso em muitos sistemas, tais como sistemas que fazem recomendação de livros e de CDs, tanto na academia quanto na indústria, desde meados dos anos 1990. As abordagens híbridas podem contornar problemas que as técnicas base apresentam quando utilizadas isoladamente, tais como a Superespecialização, na recomendação baseada em conteúdo; e a Esparsividade, na recomendação baseada em filtragem colaborativa; o que representou grande avanço. Além disso, a fim de proporcionar melhores recomendações e para ser capaz de utilizar recomendação em sistemas mais complexos, tais como, sistemas que fazem recomendações turísticas ou que fazem recomendação de certos tipos de serviços financeiros, a maior parte das técnicas de recomendação precisa ser estendida, levando em conta mais fatores. Portanto, a necessidade de desenvolver técnicas de recomendação mais avançadas tem sido pressionada por estes tipos de sistemas.

No contexto de recomendação de vídeo uma das formas possíveis de estender as técnicas de recomendação consolidadas, e que ainda não tinha sido pesquisada, é com a utilização de anotação de pontos de interesse em vídeo. Através dessas anotações, os usuários podem marcar os pontos mais interessantes para eles, ou que mais gostam, nos vídeos.

Com base nisso foi proposto o objetivo de se verificar se pontos de interesse poderiam ser utilizados para melhorar a acurácia de predição de avaliação de sistemas de recomendação de vídeo e foi lançada a seguinte hipótese: "pontos de interesse podem ser utilizados para encontrar pessoas similares, ou seja, que possuem interesses similares ou gosto em comum em relação a vídeo; e essa similaridade pode ser utilizada para aumentar a acurácia de predição de avaliação de um sistema de recomendação de vídeo". A partir daí foi desenvolvida uma abordagem inovadora que utiliza pontos de interesse, de forma a estender o perfil de usuário, para aumentar a acurácia de predição de avaliação de sistemas de recomendação que utilizam filtragem colaborativa a partir da abordagem usuário-usuário. Esta abordagem desenvolvida utiliza como base uma função de utilidade baseada em pontos de interesse e atua em duas etapas da filtragem colaborativa pura: "cálculo da similaridade entre o usuário ativo e os outros usuários existentes" e "computação de predição".

Foram propostas também duas abordagens para marcação de pontos de interesse: "marcação utilizando botões", em interface de usuário, em interface de usuário de dispositivo remoto, ou em controle remoto, e "marcação utilizando cursores",

delimitando-se o início e o final de cada ponto de interesse. Vantagens e desvantagens dessas foram apontadas para facilitar sua escolha para utilização em sistemas reais.

Para validação da proposta foram planejados dois experimentos utilizando um protótipo desenvolvido: um experimento com vídeos e usuários de um domínio específico (vídeos educacionais e alunos), e cuja marcação de pontos de interesse foi realizada seguindo a abordagem onde se delimita o início e o final do ponto de interesse; e outro experimento com vídeos genéricos (de diferentes categorias, tais como, notícias, filmes, esportes, entre outros) e usuários genéricos, e cuja a marcação de pontos de interesse foi realizada seguindo a abordagem baseada em uso de botões.

O segundo experimento não pode ser completado, pois se não atingiu uma participação mínima aceitável por parte dos voluntários. O primeiro experimento foi completado. Através dele a hipótese lançada foi confirmada e a abordagem foi validada. Nesse foi realizada uma avaliação experimental do tipo experimento *offline*, baseada na estratégia *leave-one-out* (que é uma variação de *n-fold cross validation*), a qual mostrou bons resultados: houve aumento na acurácia de predição de avaliação do sistema de recomendação (diminuição do erro de predição de avaliação em 16,72 %) quando esse sofreu ação da função de utilidade (mesmo tendo havido usuários agindo de forma passiva, ou seja, avaliando vários vídeos e não marcando nenhum ponto de interesse). Em seguida, para verificar se o resultado não foi obtido ao acaso, foi aplicado o teste de significância estatística Wilcoxon *signed rank test*, o qual indicou que o resultado não foi estaticamente significativo. A partir disso foi feita uma análise do *dataset* e verificou que muitos usuários agiram de forma passiva, ou seja, assistiram a vários vídeos e não marcaram pontos de interesse. Testes adicionais foram realizados para verificar se o resultado não tinha sido obtido ao acaso: o *leave-one-out* foi repetido utilizando o *dataset* de cada uma das turmas isoladamente e utilizando cada um dos *datasets* que iam sendo formados pela entrada de novas turmas no experimento; e novamente em todos os casos onde a função de utilidade atuou houve aumento na acurácia de predição de avaliação. Ou seja, em todos os casos onde a função de utilidade atuou houve aumento de acurácia de predição de avaliação. Esses são indícios de que os resultados não foram obtidos ao acaso e de que quando os testes forem aplicados a um *dataset* formado por milhares de usuários (e mais ativos) provavelmente haja uma melhora estatisticamente significativa.

Por fim, na abordagem proposta o usuário participa mais ativamente e mais interativamente. Com base nisto, e na experiência adquirida ao longo dos dois experimentos realizados, a abordagem proposta pode ser considerada como muito intrusiva no sentido de que requer um *feedback* explícito do usuário e também um nível significativo de envolvimento. Assim fica claro a necessidade da inclusão de mecanismos de compensação ou de mecanismos para estimular a participação das pessoas, pelo menos no início da utilização do sistema quando a função de utilidade não atua pelo fato de haverem poucos vídeos, ou nenhum, com pontos de interesse marcados.

## 7.1 Trabalhos Futuros

A partir desta pesquisa surgiram novos assuntos e temas que podem ser pesquisados e explorados futuramente. Esses são descritos a seguir.

Em relação ao cálculo de similaridade entre o par de usuários na função de utilidade podem ser pesquisadas outras abordagens para calcular esta similaridade, sempre

mantendo a interface de entrada e saída propostas. Por exemplo, para calcular tal similaridade podem ser utilizadas métricas de similaridade utilizadas em algoritmos de clusterização de dados intervalares, tais como a distância de Hausdorff (CHEVANT; LECHEVALLIER, 2002), a distância intervalar de Minkowski (PENG; LI, 2006) ou a distância intervalar *city-block* (SOUZA; CARVALHO, 2004). Nesta pesquisa por novas abordagens, o início e o fim de um ponto de interesse podem ser considerados como um dado intervalar.

Em relação à avaliação experimental, futuramente podem ser realizadas avaliações do tipo Estudo de Usuário baseadas em A-B *testing* (RICCI et al., 2011) para avaliar a acurácia de predição de avaliação. O protótipo está pronto para isso e os parâmetros ótimos de configuração do sistema obtidos na fase de ajuste de parâmetros do experimento *offline* podem ser aproveitados. Outro tipo de avaliação que também pode ser realizado é o experimento *online*. Nesse caso o protótipo implementado também pode ser utilizado sem nenhuma modificação. Nesse tipo de avaliação pode ser realizado o mesmo procedimento utilizado no Estudo de Usuário. A diferença é que o sistema será utilizado por um grupo grande ou não controlado de usuários, os quais não estão cientes que estão participando de um experimento em um ambiente não controlado (diferentes computadores, sistemas operacionais, *browsers*, velocidade de rede de comunicação, etc.), e os usuários são livres para fazer o que quiserem no sistema. A avaliação experimental pode consistir em comparar estatisticamente a acurácia de predição de avaliação do sistema dos dois grupos de usuários (controle *Vs* teste).

Os artefatos deste trabalho (protótipo desenvolvido, catálogos de vídeo, protocolo experimental e o *dataset* histórico) poderão ser utilizados (ou mesmo estendidos) em outros tipos de avaliação futuramente. Tais artefatos poderão ser utilizados, por exemplo, para avaliar a abordagem proposta (ou mesmo outras abordagens de recomendação de vídeo) em outras dimensões, tais como acurácia de predição de classificação, cobertura, novidade, robustez, privacidade, entre outras dimensões. Além disso, poderão ser utilizados em pesquisas envolvendo recomendação de vídeo com foco em outras áreas, tais como, Interação Humano-Computador (IHC) e Processamento Paralelo e Distribuído.

Outra sugestão de trabalho futuro é o estudo de uma "rede social baseada em pontos de interesse". Através da similaridade entre um par de usuários calculada através da intersecção de pontos de interesse pela função de utilidade, usuários com interesses similares ou gosto em comum em relação a vídeo podem ser descobertos. Com base nessa evidência a seguinte proposição é lançada para trabalho futuro: "a similaridade entre um par de usuários baseada em pontos de interesse, que deve ser expressa através de um valor numérico calculado pela função de utilidade, pode ser utilizada para construir uma rede social. Através dessa rede o indivíduo pode encontrar outros indivíduos similares a ele e receber (ou trocar) recomendações mais precisas, pessoa a pessoa, em um ambiente de recomendação social". Cada nó dessa rede seria um usuário e eles estariam conectados por arestas se tiverem interesses em comum ou gosto similar em relação a vídeos; cada aresta teria um peso, o qual seria definido pela função de utilidade. Outro tema subsequente que pode ser pesquisado seria a colaboração a partir do compartilhamento de pontos de interesse pelos usuários nessa rede social.

Por fim, outra sugestão de trabalho futuro é o estudo de uma abordagem baseada em pontos de interesse para recomendação multimídia. A abordagem proposta nesta pesquisa pode ser estendida para outros tipos de mídia (áudio, texto, imagem e

programas de TV). No caso de áudio podem ser utilizadas as duas abordagens propostas de marcação de pontos de interesse em vídeo, ou seja, através de botões em interface de usuário, de botões em interface de usuário de dispositivo remoto ou de controle remoto, ou delimitando-se o início e o fim de cada ponto de interesse; no caso de programas de TV em TV digital deve-se utilizar a abordagem de marcação de pontos de interesse através de botões; no caso de imagem a abordagem para marcação de pontos de interesse poderia ser realizada delimitando-se regiões de interesse na imagem; no caso de texto a abordagem para marcação de pontos de interesse pode ser realizada da mesma forma como se marca textos com uma caneta de destacar texto.

## REFERÊNCIAS

ADOMAVICIUS, G.; SANKARANARAYANAN, R.; SEN, S.; e TUZHILIN, A. Incorporating Contextual Information in Recommender Systems Using a Multidimensional Approach. **ACM Transactions on Information Systems**, [S.1.], v.23, n.1, p. 103-145, 2005.

ADOMAVICIUS G.; TUZHILIN, A. Toward The Next Generation of Recommender Systems: A Survey of the State-of-The-Art and Possible Extensions. **IEEE Transactions On Knowledge And Data Engineering**, [S.1.], v.17, n.6, p. 734–749, 2005.

ARDISSONO, L., GOY, A., PETRONE, G., SEGNAN, M., TORASSO, P. INTRIGUE: personalized recommendation of tourist attractions for desktop and handset devices. **Applied .Artificial Intelligence**, [S.1.], v.17, n.8-9, p. 687–714, 2003.

BALABANOVIC, M.; SHOHAM, Y. Fab: Content-Based, Collaborative Recommendation, **Communications of the ACM**, [S.1.], v.40, n.3, p. 66-72, 1997.

BARTH, F. J. Modelando o perfil de usuário para construção de sistemas de recomendação: um estudo teórico e estado da arte. **Revista de Sistemas de Informação da FSMA**, [S.1.], n.6, p. 59, 2010.

BORGES, D. M.; OLIVEIRA, F. L. **Análise e comparação dos sistemas de recomendação de produtos existentes em três empresas de comércio eletrônico (CE): Saraiva, Submarino e Amazon**. [S.1.], 2010. Disponível em: < <http://sistemas-humano-computacionais.wdfiles.com/local--files/capitulo%3Aredes-sociais/Mir2010.pdf> />. Acesso em: jan. 2012.

BREESE, J. S.; HECKERMAN, D.; KADIE, C. Empirical analysis of predictive algorithms for collaborative filtering. In: FOURTEENTH CONFERENCE ON UNCERTAINTY IN ARTIFICIAL INTELLIGENCE, UAI, 1998. **Proceedings...**, Morgan Kaufmann Publishers Inc., 2008. p. 43-52.

BURKE, R. Hybrid recommender systems: survey and experiments. **User Modeling and User Adapted Interaction**, [S.1.], v.12, n.4, p. 331–370. 2002

BUSSAB, W. O.; BOLFARINE, H. **Elementos de Amostragem**. São Paulo: Ed. Edgard Blucher, 2005.

CHAKOO, N., GUPTA, R., HIREMATH, J. Towards Better Content Visibility in Video Recommender Systems, In: FRONTIER OF COMPUTER SCIENCE AND TECHNOLOGY, FCST, 2008. **Proceedings...** p. 181-185.

CHAVENT, M. ; LECHEVALLIER, Y. Dynamical Clustering of interval data. Optimization of an adequacy criterion based on Hausdorff distance. In: CLASSIFICATION, CLUSTERING AND DATA ANALYSIS, **Proceedings...**, Springer, 2002, p. 53-60.

DELGADO, M. V. M.; FILHO A. M. S. A sobrecarga da informação na era da Internet. **Revista Espaço Acadêmico**, [S.1.], ano II, Abril/2003. Disponível em: <<http://www.espacoacademico.com.br/023rea.htm/>>. Acesso em: abr. 2011.

DESHPANDE, M.; KARYPIS, G. Item-based top-N recommendation algorithms. **ACM Transactions on Information Systems**. [S.1.], v.22, n.1, p. 143-177, 2004.

HERLOCKER, J.L.; KONSTAN, J.A.; BORCHERS, A.; RIEDL, J. An algorithmic framework for performing collaborative filtering. In: 22ND ANNUAL INTERNATIONAL ACM SIGIR CONFERENCE ON RESEARCH AND DEVELOPMENT IN INFORMATION RETRIEVAL, SIGIR, 1999, **Proceedings...**, ACM Press, 1999, p. 230-237.

GHAZANFAR, M.; PRÜGEL-BENNETT, A. An Improved Switching Hybrid Recommender System Using Naive Bayes Classifier and Collaborative Filtering, In: LECTURE NOTES IN ENGINEERING AND COMPUTER SCIENCE: PROCEEDINGS OF THE INTERNATIONAL MULTI CONFERENCE OF ENGINEERS AND COMPUTER SCIENTISTS, **Proceedings...**, IMECS, 2010, p. 493-502.

GHAZANFAR, M., PRÜGEL-BENNETT, A. A Scalable, Accurate Hybrid Recommender System, In: KNOWLEDGE DISCOVERY AND DATA MINING, WKDD, 2010, , **Proceedings...**, 2010, p. 94-98.

GOLDBERG, D. N.; OKI, B. M.; TERRY, D. Using collaborative filtering to weave an information tapestry. **Communications of the ACM - Special issue on information filtering**, [S.1.], v.35, n.12, p. 61-70, 1992.

GOMES, L. O. **Sistemas de recomendação de meios de hospedagem baseado em filtragem colaborativa e informações contextuais**. 2007. Tese (Mestrado em Engenharia e Gestão de Conhecimento) - Universidade Federal de Santa Catarina.



GOOGLE INC., **Estatísticas do YouTube**, [S.1.], 2011, Disponível em: <[http://www.youtube.com/t/press\\_statistics](http://www.youtube.com/t/press_statistics)>. Acesso em: out. 2011.

GRIMBERGHE, A. K.; NANOPOULOS, A.; THIEME L. S. A Novel Multidimensional Framework for Evaluating Recommender Systems. In: ACM RECSYS, 2010, **Proceedings...**, 2010, p. 34-41.

JANNACH, D.; ZANKER, M.; FELFERNIG, A.; FRIEDRICH, G. **Recommender Systems: An Introduction**. New York: Cambridge University Press, 2011.

KARYPIS, G. Evaluation of item-based top-N recommendation algorithms. In: CONFERENCE ON INFORMATION AND KNOWLEDGE MANAGEMENT, ACM CIKM, 2001, **Proceedings...**, 2001, p. 247-254.

LAKIOTAKI, K.; MATSATSINIS, N.; TSOUKIAS, A. Multicriteria User Modeling in Recommender Systems. **IEEE Intelligent Systems**, [S.1.], v.26, n., p. 64-76, 2011.

KOREN, Y.; BELL, R.; VOLINSKY, C. Matrix Factorization Techniques for Recommender Systems. **Computer**, [S.1.], v.42, n.8, p. 30-37, 2009.

LEKAKOS, G.; CARAVELAS, P. MoRe: a Recommendation Systems combining Content-based and Collaborative filtering. In: EUROITV CONFERENCE, 4., **Proceedings...**, 2006, p. 183-188.

LIEBERMAN, H., FRY, C., WEITZMAN, L. Exploring the web with reconnaissance agents. **Communications of the ACM**, [S.1.], v.44, n.8, p. 69-75, 2001.

LINDEN, G.; SMITH, B.; YORK, J. Amazon.com recommendations: Item-to-item collaborative filtering, **IEEE Distributed Systems OnLine**, [S.1.], v.1, 2003.

MAES, P; SHARDANAND, U. Social Information Filtering: Algorithms for Automating "Word of Mouth". In: SIGCHI CONFERENCE ON HUMAN FACTORS IN COMPUTING SYSTEMS, CHI, 1995, **Proceedings...**, 1995, p. 210-217.

MELVILLE, P., MOONEY, R.J., e NAGARAJAN, R. Content-boosted collaborative filtering. ACM SIGIR WORKSHOP ON RECOMMENDER SYSTEMS, **Proceedings...**, 2001.

MONTANER, M.; LÓPEZ, B.; de LA ROSA, J.L. A Taxonomy of Recommender Agents on the Internet. **Artificial Intelligence Review**. Kluwer Academic Publishers, [S.1.], v.19, p. 285-330, 2003.

NATHAN, M.; HARRISON, C.; YAROSH, S.; TERVEEN, L.; STEAD, L.; AMENTO, B. CollaboraTV: making television viewing social again. In: 1ST INTERNATIONAL CONFERENCE ON DESIGNING INTERACTIVE USER EXPERIENCES FOR TV AND VIDEO, UXTV, 2008, **Proceedings...**, 2008, p 85-94.

NAUDET, Y; MIGNON, S.; LECAQUE, L.; HAZOTTE, C.; GROUES, V. Ontology-Based Matchmaking Approach for Context-Aware Recommendations. In: INTERNATIONAL CONFERENCE ON AUTOMATED SOLUTIONS FOR CROSS MEDIA CONTENT AND MULTI-CHANNEL DISTRIBUTION, AXMEDIS, 2008, **Proceedings...**, 2008, p. 218-223.

PENG, W.; LI, T. Interval Data Clustering with Applications, In: TOOLS WITH ARTIFICIAL INTELLIGENCE, ICTAI, 2006, **Proceedings...**, 2006, p.355-362.

QIN, S.; MENEZES, R.; SILAGHI, M. A Recommender System for Youtube Based on its Network of Reviewers, In: IEEE SECOND INTERNATIONAL CONFERENCE ON SOCIAL COMPUTING, SOCIALCOM, 2010, **Proceedings...**, 2010, p.323-328.

RAMAKRISHNAN, N.; KELLER, B. J.; MIRZA, B. J.; GRAMA, A. Y.; KARYPIS, G. Privacy Risks in Recommender Systems, **IEEE Internet Computing**, [S.1.], v. 5, n.6, p. 54-62, 2001.

RESNICK, P.; IAKOVOU N.; SUSHAK, M.; BERGSTROM, P.; RIEDL, J. GroupLens: An Open Architecture for Collaborative Filtering of Netnews, In: ACM CONFERENCE ON COMPUTER SUPPORTED COOPERATIVE WORK, CSCW, 1994, **Proceedings...**, 1994, p. 175-186.

RESNICK, P.; VARIAN, H. Recommender Systems. **Communications of the ACM**, New York, [S.1.], v.40, n.3, p. 55-58, 1997.

RICCI, F.; ROKACH, L.; SHAPIRA, B.; KANTOR, P. B. **Recommender Systems Handbook**. New York: Springer. 2011.

SCHAFER, J. B.; KONSTAN, J. A.; RIEDL, J. E-Commerce Recommendation Applications. **Data Mining e Knowledge Discovery**, [S.1.], v.5, n.1-2, p. 115-153, 2001.

SMYTH, B., e COTTER, P. A Personalized TV Listings Service for the Digital TV Age. **Knowledge-Based Systems**, [S.1.], v.13, p. 53-59, 2000.

SOUZA, R. M. C. R.; CARVALHO, F. A. T. Clustering of interval data based on city-block distances. **Pattern Recognition Lett.**, [S.1.], v.25, n.3, p. 353–365. 2004.

SPIEGEL, S. **A Hybrid Approach to Recommender Systems based on Matrix Factorization**. 2009. Tese (Doutorado em Ciência da Computação) - Technical University Berlin (Alemanha).

SUMIYOSHI, H.; SANO, M.; GOTO, J.; MOCHIZUKI, T.; MIYAZAKI, M.; FUJII, M.; SHIBATA, M.; YAGI, N. CurioView: TV recommendations related to content being viewed, In: BROADBAND MULTIMEDIA SYSTEMS AND BROADCASTING, BMSB, 2010, **Proceedings...**, 2010, p.1-6.

WEN, Z. Recommendation System Based on Collaborative Filtering, Stanford CS229 Projects, 2008.

YOUTUBE. **YouTube API - Google Developers**, [S.1.], 2012 Disponível em: <<https://developers.google.com/youtube/>>. Acesso em: Jan, 2012.

# APÊNDICE A – A MODELAGEM DO AMBIENTE IMPLEMENTADO

## 1. INTRODUÇÃO

Nesse documento são apresentados artefatos desenvolvidos para a modelagem do ambiente implementado, apresentado no Capítulo 5.

## 2. MODELAGEM DO AMBIENTE IMPLEMENTADO

Para descrever as funcionalidades propostas para o sistema foi utilizado o Diagrama de Caso de Uso. Para representar a estrutura do sistema, através de classes e suas relações, foi utilizado o Diagrama de Classes. Tais diagramas pertencem a UML (*Unified Modeling Language*). Essa é um padrão gráfico para visualizar, especificar, construir e documentar os artefatos de um sistema de software. Para a modelagem de interface foi utilizada uma abordagem de prototipação horizontal, ou seja, foi criada uma interface quase completa e com funcionalidades reduzidas.

### 2.1. MODELAGEM DE FUNCIONALIDADES

Para descrever as funcionalidades propostas para o sistema foi utilizado o Diagrama de Caso de Uso. A Figura 2.1 apresenta o diagrama de casos de uso referente ao ambiente implementado. Este ambiente permite aos seus usuários que busquem, assistam, avaliem vídeos e marquem, quando houver, seus pontos de interesse. Estas duas últimas funcionalidades, Avaliar Vídeos e Marcar Ponto de Interesse, são efetuadas na tela onde o usuário assiste a vídeos; ao assistir vídeos existe uma interação com o provedor de vídeos; e ao buscar vídeos são apresentadas recomendações de vídeo personalizadas ao usuário. Além disso, a marcação de pontos de interesse pode ser realizada a partir da abordagem que utiliza botões ou a partir da abordagem onde se delimita início e fim de ponto de interesse. Nesse último caso o sistema permite, também, ao usuário que veja a lista de pontos de interesse já marcados e exclua pontos de interesse. Outras funcionalidades, inerentes a sistemas web que necessitam de autenticação de usuário, são: Efetuar *Login* e Efetuar *Logout*, e a funcionalidade relativa ao cadastro de usuário.

### 2.2. MODELAGEM DE ESTRUTURA

Para representar a estrutura do sistema, através de classes e suas relações, foi utilizado o Diagrama de Classes. A Figura 2.2 apresenta o diagrama de classes para o ambiente implementado. Nesse ambiente as classes principais são *Usuario* e *Video*.

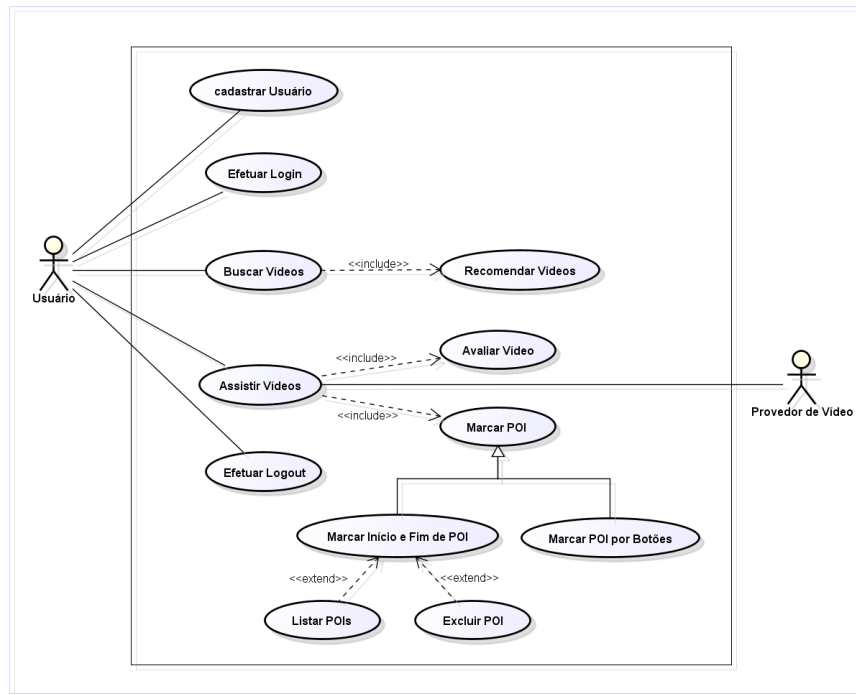


Figura 2.1: Diagrama de Casos de Uso do Ambiente Implementado

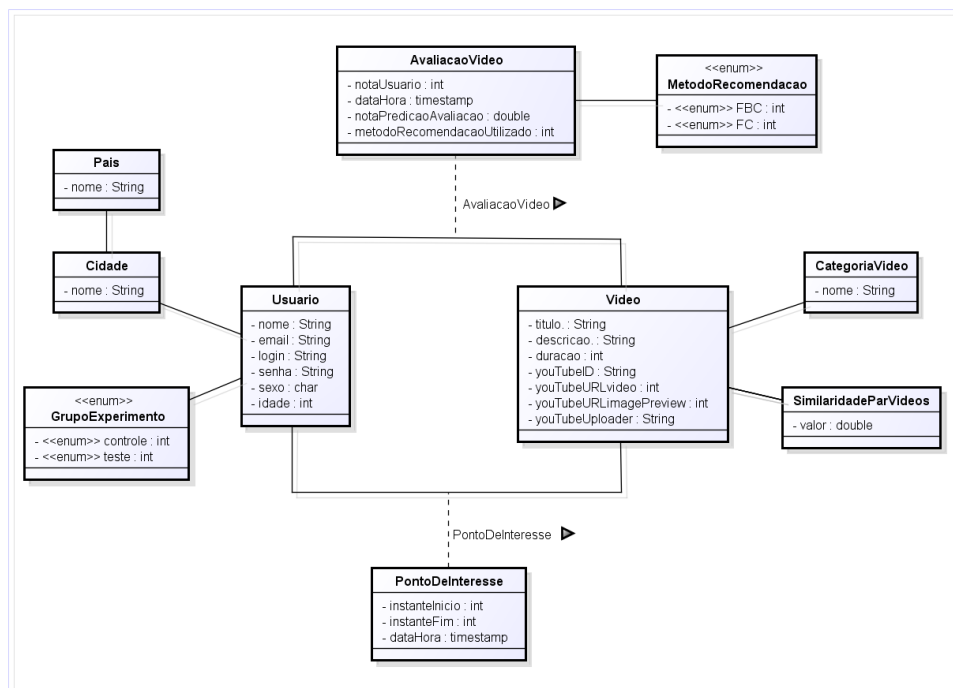


Figura 2.2: Diagrama de Classes do Ambiente Implementado

A classe *Video* contém atributos que correspondem a informações sobre vídeo, tais como, título, descrição, duração, entre outras, as categorias de vídeos associadas ao vídeo, e algumas informações para integração com o provedor de vídeos, que neste caso

é o YouTube. Para que seja possível realizar recomendações baseada em Filtragem Baseada em Conteúdo de forma mais rápida as similaridades de pares de vídeos são computadas previamente em uma fase *offline* e armazenadas no sistema em uma classe auxiliar chamada *SimilaridadeParVideos*.

A classe *Usuario* contém atributos que correspondem a informações sobre usuário, tais como, nome, e-mail, sexo, idade, entre outras, informações para acesso ao sistema, além do grupo ao qual o usuário pertence no experimento.

A classe *PontoDeInteresse* contém atributos para indicar o início e fim de pontos de interesses marcados por usuários em vídeos, além do instante no tempo que tal marcação foi efetuada.

A classe *AvaliacaoVideo* contém atributos para indicar a nota dada por um usuário ao avaliar um vídeo, além de outros atributos que permitem computar estatísticas de predição de avaliação ao avaliar o sistema de recomendação utilizando avaliações experimentais do tipo Estudo de Usuário A-B *testing* ou do tipo experimento *offline*.

## 2.3. MODELAGEM DE INTERFACE

Para a modelagem de interface foi utilizada uma abordagem de prototipação horizontal, ou seja, foi criada uma interface quase completa e com funcionalidades reduzidas. Inicialmente foi feita a identificação dos requisitos do sistema, das tarefas que os usuários realizariam e do ambiente. Optou-se por construir uma interface com um *layout* semelhante ao da interface de muitos sites de vídeo da atualidade, ou seja, contendo uma tela de galeria de vídeos, na qual há uma listagem de vídeos, e uma tela com um *player* de vídeo, pela qual os usuários assistem a vídeos; tudo isso de forma a tornar o sistema mais familiar a muitos usuários da Web. As tarefas de usuário principais definidas foram: buscar, listar, escolher, assistir e avaliar vídeos e marcar pontos de interesse. Além disso, o sistema seria integrado a um provedor de vídeos, que nesse caso foi o YouTube, através de uma API de integração.

A partir desse levantamento (requisitos, tarefas do usuário e ambiente) foram planejadas e implementadas as telas principais do protótipo horizontal. Pela primeira tela, de nome Galeria de Vídeos, e cujo esboço é apresentado na Figura 2.3, o usuário visualizaria a listagem de vídeos, podendo buscar vídeos de seu interesse através de componentes de interface específicos para tal fim; poderia ver detalhes de vídeos, tais como, título, breve descrição, tempo entre outros; e poderia escolher vídeos para assistir. Pela segunda tela, de nome Visualização de Vídeos, cujo esboço é apresentado em duas versões na Figura 2.4 e que é apresentada após se escolher um vídeo da tela de Galeria de Vídeos, o usuário poderia visualizar vídeos, através de um *player* de vídeo; avaliar vídeos e marcar seus pontos de interesse em vídeo. Sendo que estas duas opções só poderiam ser disponibilizadas após o início da apresentação do vídeo, para que não fossem feitas a avaliação ou a marcação de pontos de interesse sem se ter visto parte do vídeo. Para a marcação de pontos de interesse foram planejadas duas abordagens: marcação com o uso de botões e marcação pela delimitação de início e fim de pontos de interesse, sendo esta última realizada através de componentes de interface *Slider*, alinhado com o componente de interface *ProgressBar* do *player* de vídeo.



Figura 2.3: Esboço de interface da tela Galeria de Vídeos.



Figura 2.4: Duas versões do esboço de interface da tela de Visualização de Vídeo, sendo à esquerda a partir da abordagem de marcação de pontos de interesse por botões e à direita a partir da abordagem onde se delimita início e fim de pontos de interesse.

Por fim, testes funcionais (com as funcionalidades base implementadas), de integração de sistemas e de usabilidade com usuários finais indicaram: a necessidade, quando utilizada a abordagem de onde se delimita início e fim de pontos de interesse, de uma visualização da listagem de pontos de interesse já marcados e de opções para que o usuário pudesse excluir pontos de interesse, que ele marcou de forma errada ou que não queria mais como pontos de interesse; a necessidade de informações extras sobre a semântica de pontos de interesse, as quais foram adicionadas à interface através de componentes de interface *Tooltip* mostrando informações textuais de ajuda; e, por fim, a necessidade de uma animação indicando que a marcação de ponto de interesse foi realizada, para o usuário não ter um *feedback* que o sistema está efetuando o registro o pontos de interesse. A partir daí foi gerada uma versão 2 da interface de usuário do protótipo horizontal e os testes foram repetidos com outros usuários finais. A partir desse processo foram modeladas as telas principais do ambiente implementado (Capítulo 5).