

**UNIVERSIDADE FEDERAL DE ITAJUBÁ**

**PROGRAMA DE PÓS-GRADUAÇÃO EM  
CIÊNCIA E TECNOLOGIA DA COMPUTAÇÃO**

**SeReS: Um Sistema de Recomendação de Conteúdo Baseado em  
Processamento Semântico para o SBTVD**

**Glauco da Silva**

**Itajubá, janeiro de 2011**

**UNIVERSIDADE FEDERAL DE ITAJUBÁ  
PROGRAMA DE PÓS-GRADUAÇÃO EM  
CIÊNCIA E TECNOLOGIA DA COMPUTAÇÃO**

**Glauco da Silva**

**SeReS: Um Sistema de Recomendação de Conteúdo Baseado em  
Processamento Semântico para o SBTVD**

**Dissertação submetida ao Programa de Pós-Graduação  
em Ciência e Tecnologia da Computação como parte  
dos requisitos para obtenção do Título de Mestre em  
Ciências em Ciência e Tecnologia da Computação**

**Área de Concentração: Sistemas de Computação**

**Orientador: Prof. Dr. Laércio Augusto Baldochi Júnior**

**Janeiro de 2011**

**Itajubá - MG**

Ficha catalográfica elaborada pela Biblioteca Mauá –  
Bibliotecária Cristiane N. C. Carpinteiro- CRB\_6/1702

S586s

Silva, Glauco da

SeReS: um sistema de recomendação de conteúdo baseado em processamento semântico para o SBTVD. / por Glauco da Silva . -- Itajubá (MG) : [s.n.], 2011.

101 p.: il.

Orientador: Prof. Dr. Laércio Augusto Baldochi Júnior.  
Dissertação (Mestrado) – Universidade Federal de Itajubá.

1. Ativação semântica. 2. Ontologias. 3. Sistemas de recomendação.  
4. Televisão digital. I. Baldochi Júnior, Laércio Augusto, orient. II.  
Universidade Federal de Itajubá. III. Título.

# Dedicatória

*Dedico este trabalho à minha família  
e à memória de meu avô João Pereira da Silva*

# Agradecimentos

Primeiramente agradeço a Deus, que me deu saúde, conhecimento, discernimento e me permitiu concluir mais essa etapa da minha vida.

Agradeço ao professor Dr. Laércio Augusto Baldochi Júnior pela orientação, pelo incentivo e pela confiança em mim depositada, sempre acreditando na realização deste trabalho.

Serei eternamente grato a meus pais, Walter e Lúcia, que sempre me apoiaram, incentivaram e me proporcionaram a oportunidade de chegar até aqui. Também agradeço meus irmãos, Douglas e Lucas, pelo apoio e incentivo durante a realização deste trabalho.

Agradeço de forma especial minha noiva, Aline, que me acompanhou durante os anos no mestrado, sempre me apoiando e incentivando; e sempre estando ao meu lado, mesmo quando eu não lhe dava a atenção merecida ou durante as minhas ausências. Nunca vou me esquecer disso. Te amo.

Agradeço também todas as pessoas da Coordenadoria de Tecnologia da Informação do Instituto de Aeronáutica e Espaço (IAE) pelo apoio durante o mestrado, principalmente meu amigo Luiz Aldo que desde o início incentivou e apoiou a realização deste meu projeto.

Meu muito obrigado a todos os membros do LUMI (Laboratório de Usabilidade e Mídias Interativas) da UNIFEI, bem como aos professores e colegas do programa de Mestrado em Ciência e Tecnologia da Computação.

Agradeço aos professores/amigos da Fatec Guaratinguetá, principalmente Luiz Eduardo Guarino de Vasconcelos, André Ricardo Soares Amarante, Leandro Guarino de Vasconcelos, Adriano Carlos Rosa, Rinaldo César Martins Motta e João Roberto Ultramari, pelo apoio, auxílio e incentivo na realização deste trabalho.

Por fim, agradeço a todos que direta ou indiretamente contribuíram e participaram da realização deste trabalho.

# Resumo

Nos ambientes de TV Digital (TVD) atuais o usuário tem que lidar com centenas de canais e milhares de programas que estão diariamente disponíveis para consumo. Esse volume imenso de conteúdo multimídia faz com que o usuário perca um tempo considerável buscando programas de seu interesse sem, muitas vezes, conseguir encontrar o que procura. No sentido de facilitar o consumo do conteúdo disponível, os sistemas de recomendação, largamente explorados no contexto da Web, vêm sendo adaptados para os ambientes de TVD. As soluções existentes, sobretudo no contexto do Sistema Brasileiro de TV Digital (SBTVD), apresentam limitações que levam a recomendações superespecializadas. No sentido de prover recomendações de conteúdo mais efetivas para o SBTVD, esta dissertação apresenta o SeReS - *Semantic-based Recommender System*. Como o nome sugere, o SeReS utiliza processamento semântico a fim de identificar as semelhanças entre programas que um usuário assistiu e outros que se encontram disponíveis para consumo. Para permitir essa abordagem, foi desenvolvida uma ontologia de domínio capaz de modelar os programas televisivos. Esta ontologia foi utilizada na construção de uma rede semântica capaz de produzir o perfil do usuário com base no seu consumo de programas. O perfil resultante pode ser usado diretamente na recomendação de novos conteúdos ao usuário ou pode ser fornecido a outras aplicações.

**Palavras-chave:** Ativação semântica. Ontologias. Sistemas de recomendação. Televisão digital.

# Abstract

In modern Digital TV Environments (DTV), the user has to deal with hundreds of channels and thousands of programs on a daily basis. Searching this large volume of multimedia content is time-consuming and frequently leads to frustration, as the user may be unable to find the content she is looking for. In order to facilitate the consumption of the available content, programs known as recommender systems, widely used on the Web, have been adapted DTV environments. The existing solutions, mainly those proposed for the Brazilian DTV System (SBTVD), present limitations associated to the super specialization of the resulting recommendations. In order to provide more effective content recommendations in the SBTVD environment, this dissertation presents SeReS - a Semantic-based Recommender System. As the name suggests, SeReS exploits semantic reasoning techniques to identify similarities among shows that a user has already seen and other shows available for consumption. To implement this approach, it was necessary to develop an ontology for the DTV domain, which was used to build a semantic network. Using spreading activation techniques, the proposed approach extracts a profile for the user based on her prior consumption. The resulting profile may be directly used for recommending new content or it may be deployed to other applications.

**Keywords:** Semantic spreading. Ontologies. Recommender systems. Digital television.

# Lista de Figuras

2.1	Modelo de camadas para TVD . . . . .	p. 21
2.2	Arquitetura de um sistema de TVD com a camada do <i>middleware</i> . . . . .	p. 22
2.3	Distribuição dos padrões de TVD pelo mundo . . . . .	p. 23
2.4	Componentes do Ginga <i>Common Core</i> . . . . .	p. 25
3.1	Ontologia para instrumentos musicais . . . . .	p. 30
3.2	Linguagens utilizadas para representar ontologias . . . . .	p. 32
3.3	Representação de uma expressão RDF na forma de grafo . . . . .	p. 33
4.1	Filtragem baseada em conteúdo . . . . .	p. 44
4.2	Filtragem colaborativa baseada em usuário . . . . .	p. 48
4.3	Filtragem colaborativa baseada em conteúdo . . . . .	p. 49
5.1	Conjunto de classes da ontologia . . . . .	p. 60
5.2	Prefixos das ontologias . . . . .	p. 61
5.3	Conteúdo <i>Batman Returns</i> e suas informações coletadas . . . . .	p. 62
5.4	Parte da ontologia com instâncias criadas (Silva; Baldochi, 2010) . . . . .	p. 63
5.5	Parte da rede semântica utilizada (Silva; Baldochi, 2010) . . . . .	p. 64
5.6	Incidência de valores de ativação sobre um item (Silva; Baldochi, 2010) . . . . .	p. 65
5.7	Exemplo de consumo e recomendação para o usuário <i>u</i> . . . . .	p. 68
5.8	Arquivo XML com o perfil do usuário <i>u</i> . . . . .	p. 69
5.9	Ativação de itens até o 2 <sup>o</sup> nível da rede semântica . . . . .	p. 71
5.10	Pseudo-código do algoritmo de ativação semântica . . . . .	p. 72
5.11	Arquitetura do sistema . . . . .	p. 72



5.12	Trecho do arquivo com informações sobre os atores, diretores etc. (Dias, 2010) . . . . .	p. 76
6.1	Trecho da rede semântica para o usuário 1834935888 . . . . .	p. 83
6.2	Trecho do perfil do usuário 1834935888 com os conteúdos recomendados .	p. 85
6.3	Características dos filmes <i>Avatar</i> e <i>Wanted</i> . . . . .	p. 86
6.4	Arquitetura do EGA proposta por Moreno, Soares Neto e Soares (2009) .	p. 87
6.5	Arquitetura do EPG com o SeReS integrado . . . . .	p. 89

# Lista de Tabelas

5.1	Classes da ontologia e suas descrições . . . . .	p. 61
5.2	Pesos utilizados para os relacionamentos . . . . .	p. 66
5.3	Avaliações do usuário 579265740 para os atores (Dias, 2010) . . . . .	p. 74
5.4	Usuários selecionados para formarem o grupo (Dias, 2010) . . . . .	p. 75
5.5	Atores selecionados para aplicar a recomendação (Dias, 2010) . . . . .	p. 75
6.1	Itens ativados diretamente para o usuário 1834935888 . . . . .	p. 84

# Lista de Siglas

<b>API</b>	<i>Application Programming Interface</i>
<b>ATSC</b>	<i>Advanced Television System Committee</i>
<b>CSS</b>	<i>Cascading Style Sheets</i>
<b>DAML</b>	<i>DARPA Agent Markup Language</i>
<b>DARPA</b>	<i>Defense Advanced Research Projects Agency</i>
<b>DMB</b>	<i>Digital Multimedia Broadcast</i>
<b>DVB</b>	<i>Digital Video Broadcast</i>
<b>EPG</b>	<i>Electronic Program Guide</i>
<b>GEM</b>	<i>Globally Executable MHP</i>
<b>HDTV</b>	<i>High Definition Television</i>
<b>HTML</b>	<i>HyperText Markup Language</i>
<b>IPTV</b>	<i>Internet Protocol Television</i>
<b>ISDB</b>	<i>Integrated Services Digital Broadcasting</i>
<b>ITU-T</b>	<i>International Telecommunication Union - Telecommunication Standardization Sector</i>
<b>JVM</b>	<i>Java Virtual Machine</i>
<b>NCL</b>	<i>Nested Context Language</i>
<b>OIL</b>	<i>Ontology Inference Layer</i>
<b>OKBC</b>	<i>Open Knowledge Base Connectivity</i>
<b>OWL</b>	<i>Web Ontology Language</i>

<b>PDA</b>	<i>Personal Digital Assistant</i>
<b>RDF</b>	<i>Resource Description Framework</i>
<b>SBTVD</b>	Sistema Brasileiro de Televisão Digital
<b>SDTV</b>	<i>Standard Definition Television</i>
<b>SeReS</b>	<i>Semantic-based Recommender System</i>
<b>SHOE</b>	<i>Simple HTML Ontology Extensions</i>
<b>SQL</b>	<i>Structured Query Language</i>
<b>STB</b>	<i>Set Top Box</i>
<b>TOVE</b>	<i>Toronto Virtual Enterprise</i>
<b>TVDi</b>	Televisão Digital Interativa
<b>TVD</b>	Televisão Digital
<b>W3C</b>	<i>World Wide Web Consortium</i>
<b>XML</b>	<i>Extensible Markup Language</i>
<b>XOL</b>	<i>Ontology Exchange Language</i>

# Sumário

<b>1</b>	<b>Introdução</b>	p. 14
1.1	Objetivos	p. 16
1.2	Metodologia	p. 17
1.3	Estrutura da dissertação	p. 18
<b>2</b>	<b>Televisão Digital Interativa</b>	p. 20
2.1	Sistema Brasileiro de Televisão Digital - SBTVD	p. 23
2.2	Considerações finais	p. 28
<b>3</b>	<b>Ontologias e redes semânticas</b>	p. 29
3.1	Ontologias	p. 29
3.1.1	Linguagens de representação de ontologias	p. 31
3.1.2	Metodologias para desenvolvimento de ontologias	p. 37
3.2	Redes semânticas	p. 40
3.3	Considerações finais	p. 42
<b>4</b>	<b>Sistemas de recomendação</b>	p. 43
4.1	Sistemas de recomendação baseados em conteúdo	p. 43
4.2	Sistemas de recomendação baseados em filtragem colaborativa	p. 46
4.3	Sistemas de recomendação híbridos	p. 51
4.4	Sistemas de recomendação baseados em semântica	p. 54
4.5	Considerações finais	p. 55

<b>5</b>	<b>Recomendação de conteúdo baseada em processamento semântico</b>	p. 57
5.1	Ontologia proposta . . . . .	p. 58
5.2	Construção da rede semântica . . . . .	p. 64
5.3	Geração do perfil do usuário . . . . .	p. 67
5.4	Ativação semântica . . . . .	p. 70
5.5	Integração de filtragem colaborativa ao SeReS . . . . .	p. 72
5.6	Trabalhos relacionados . . . . .	p. 77
5.7	Considerações finais . . . . .	p. 80
<b>6</b>	<b>SeReS: Testes e proposta de implementação no ambiente Ginga</b>	p. 82
6.1	Desenvolvimento do SeReS . . . . .	p. 82
6.2	Proposta de integração no Ginga . . . . .	p. 86
6.3	Considerações finais . . . . .	p. 90
<b>7</b>	<b>Conclusão</b>	p. 91
7.1	Resultados e contribuições . . . . .	p. 92
7.2	Trabalhos futuros . . . . .	p. 93
	<b>Referências Bibliográficas</b>	p. 95

# 1 Introdução

A sobrecarga de informação tem se tornado um problema recorrente nos últimos anos. No entanto, este problema não é novo: por volta de 1994, no início da *World Wide Web*, esta sobrecarga já era perceptível (Nelson, 1994). Atualmente ela é muito mais grave, ainda mais com as mídias de massa e os meios de comunicação globais se tornando uma presença generalizada na vida cotidiana. Como resultado, as pessoas têm que se esforçar para encontrar a informação, serviço ou produto que desejam, fazendo com que seja cada vez mais difícil distinguir o que é relevante do que é irrelevante. Na tentativa de resolver estes problemas, pesquisadores desenvolveram os chamados sistemas de recomendação, programas de computador que utilizam técnicas de filtragem de informações, com o intuito de apresentar itens de informação que possam ser de interesse do usuário. Tais itens podem ser notícias (Das et al., 2007), produtos de consumo (Schafer; Konstan; Riedi, 1999; Huang; Zeng; Chen, 2007) ou conteúdo televisivo (Ali; van Stam, 2004; Blanco-Fernández et al., 2008; Hölbling; Pleschgatterinig; Kosch, 2010).

O domínio da televisão digital (TVD) vem ganhando força, pois ele promete uma nova experiência de assistir televisão. Com o objetivo de não tornar essa nova experiência frustrante, o primeiro passo é oferecer formas de lidar com centenas de canais para encontrar conteúdos interessantes. Dessa forma, o ambiente de TVD tem sido considerado um domínio interessante para os sistemas de recomendação. Datado de 1999, o TiVo (Ali; van Stam, 2004) foi o primeiro grande sistema comercial de recomendação dirigido ao domínio de conteúdos televisivos. Mais recentemente, com a difusão da plataforma da televisão digital interativa (TVDi), uma grande variedade de novos sistemas têm sido propostos. Em geral, esses sistemas utilizam técnicas de recomendação bem conhecidas, já empregadas em pesquisas que envolvem recuperação de informação, e são classificados como sistemas de recomendação baseados em conteúdo e baseados em filtragem colaborativa (Adomavicius; Tuzhilin, 2005).

Sistemas de recomendação baseados em conteúdo usam as características de um programa, como elenco, gênero ou diretor como atributos para um sistema de aprendizado,

geralmente baseado em métricas de similaridade. Como essas métricas utilizam abordagens sintáticas, só é possível detectar semelhanças entre programas de TV que compartilham atributos comuns. Esta abordagem leva a superespecialização, sugerindo conteúdos que compartilham atributos com outro conteúdo que o usuário já gostava. Portanto, a superespecialização leva a recomendações esperadas.

Para fornecer aos usuários recomendações inesperadas, porém relevantes, os sistemas de recomendação colaborativos utilizam a técnica de recomendar a cada usuário programas que tenham sido interessantes para outros usuários com preferências similares. Técnicas de filtragem colaborativa são eficazes para combater a superespecialização. No entanto, outras dificuldades surgem a partir desta abordagem. É difícil realizar recomendações para novos usuários, uma vez que não se possui nenhum dado pessoal que possa ser usado para encontrar sua vizinhança (grupo de usuários com gostos similares). Este é o problema conhecido como “*cold start*”. Outro problema surge quando o usuário possui gostos muito incomuns e/ou particulares, o que faz com que este usuário não tenha nenhum vizinho. Isso é conhecido como o problema da “ovelha negra”. A escalabilidade também é um problema deste tipo de sistema, pois o número de usuários é muito grande. Dessa forma a carga de processamento exigida para se formar os grupos de usuários é muito alta. Finalmente, preocupações com a privacidade também são relevantes, como a determinação de quais dados do usuário devem ser coletados, e como eles serão armazenados e compartilhados.

Soluções híbridas, que fundem as técnicas baseadas em conteúdo e baseadas em filtragem colaborativa têm sido usadas para superar as limitações de cada abordagem isolada (Burke, 2007). Como a filtragem baseada em conteúdo explora somente as características do domínio, ela pode ser usada para recomendar itens para novos usuários e para as pessoas com preferências incomuns. Ainda assim, essas recomendações são mais pobres do que as produzidas para usuários “regulares”, uma vez que elas sofrem com o excesso de especialização.

Uma abordagem mais recente para tratar a superespecialização é baseada em técnicas de raciocínio. Utilizando idéias da *Web Semântica*, ontologias vem sendo formalizadas para domínios específicos, tais como a TVDi. Em conjunto com as ontologias, estratégias baseadas em conteúdo são utilizadas. Essas estratégias inferem associações semânticas entre as preferências do usuário e os itens disponíveis no sistema de recomendação. Essa abordagem permite a descoberta de conhecimento sobre as preferências do usuário, o qual é então utilizado para comparar os itens que podem lhe ser sugeridos. Um ponto importante sobre essa estratégia é que ela permite a recomendação de conteúdos que não



compartilham atributos comuns com outros programas que o usuário tenha consumido no passado. Esta é uma clara indicação de que o resultado das recomendações não é superespecializado.

Nesta dissertação é apresentado um sistema de recomendação destinado ao Sistema Brasileiro de Televisão Digital Terrestre (SBTVD). O SBTVD foi desenvolvido como uma variante do sistema japonês, conhecido como ISDB (*Integrated Services Digital Broadcasting*). Com o intuito de atender às demandas locais, o governo brasileiro decidiu desenvolver um *middleware* para o SBTVD a partir do zero. Chamado Ginga (Soares et al., 2010), este novo *middleware* abriu oportunidades para o desenvolvimento de novos serviços e aplicações, incluindo os sistemas de recomendação para TVD.

Foi observado na literatura a existência de diversos trabalhos que abordam a recomendação de conteúdo para a TVD (Ali; van Stam, 2004; Blanco-Fernández et al., 2008; Naudet et al., 2008; Hölbling; Pleschgatterinig; Kosch, 2010), inclusive sistemas para o SBTVD (Alves, 2008; Ávila; Zorzo, 2009; Lucas; Zorzo, 2009). Alguns destes trabalhos utilizam a abordagem baseada em conteúdo, enquanto outros utilizam a abordagem baseada em filtragem colaborativa.

Considerando que os sistemas de recomendação existentes para o SBTVD (Alves, 2008; Ávila; Zorzo, 2009; Lucas; Zorzo, 2009) são limitados e que os trabalhos desenvolvidos atuam somente com informações baseadas puramente em conteúdo, esta dissertação apresenta um sistema que explora a semântica dos programas disponíveis, fazendo com que conteúdos não relacionados diretamente com o consumo do usuário possam ser recomendados.

## 1.1 Objetivos

No sentido de suprir as deficiências dos sistemas de recomendação tradicionais, sobretudo aqueles já propostos para o SBTVD, este trabalho tem como meta produzir um perfil de cada usuário do SBTVD tomando como base o seu consumo de programas televisivos e a similaridade semântica desses programas com outros disponíveis na grade de programação. Este perfil estendido pode ser diretamente processado no *set top box* (STB) do usuário, produzindo recomendações instantâneas, ou então intercambiado com outros programas para, por exemplo, permitir a disponibilização de propaganda direcionada para cada usuário.

No sentido de alcançar este objetivo geral, os seguintes objetivos específicos foram

delineados:

1. definir uma ontologia que represente os conteúdos disponíveis no SBTVD e suas informações de forma que seja possível explorar a semântica entre os conteúdos. As informações disponíveis devem estar de acordo com a norma ABNT 15603-2 (ABNT, 2008a). Após a definição da ontologia é necessário criar instâncias de conteúdos existentes.
2. criar uma rede semântica a partir da ontologia definida, para que seja possível relacionar conteúdos através de suas características e inferir relacionamentos não disponíveis diretamente entre eles.
3. a partir do consumo de um usuário, determinar seus interesses utilizando as informações de cada conteúdo consumido.
4. percorrer a rede semântica construída visando obter conteúdos que podem ser recomendados ao usuário. O ponto de início do processamento da rede é baseado no consumo do usuário.
5. gerar o perfil do usuário com seus conteúdos consumidos, seus interesses e conteúdos recomendados. Esse perfil deve ser representado em um formato que permita o intercâmbio entre aplicações e que facilite a persistência e recuperação dos dados armazenados.
6. processar o perfil gerado, a fim de informar as recomendações obtidas.

## 1.2 Metodologia

Através de análises de sistemas de recomendação para o SBTVD (Alves, 2008; Ávila; Zorzo, 2009; Lucas; Zorzo, 2009), verificou-se que a recomendação baseada puramente em conteúdo leva em consideração somente o histórico do usuário para sugerir novos conteúdos, o que faz com que as sugestões sejam previsíveis.

Nenhum dos trabalhos estudados utiliza técnicas semânticas para explorar as informações dos conteúdos, ou seja, eles simplesmente se baseiam em informações sintáticas, como por exemplo, o título ou gênero do conteúdo. Dessa forma, a primeira ação tomada para alcançar os objetivos apresentados na Seção 1.1 foi definir uma forma de representar os conteúdos através de suas informações, visando explorar a semântica envolvida nessa representação.

Essa atividade envolve a definição de uma ontologia de domínio que representa os conteúdos disponíveis no SBTVD. Para se desenvolver a ontologia utilizou-se a linguagem OWL (*Web Ontology Language*), e o software Protégé<sup>1</sup> para sua modelagem. As classes definidas na ontologia possuem atributos e relacionamentos que permitem uma melhor definição de cada conteúdo.

Complementando a ontologia, foram criadas instâncias dos conteúdos para que fosse possível realizar a recomendação. As informações dos conteúdos foram retiradas de bases disponíveis na *Web*, como IMDB<sup>2</sup> e TheTVDB.com<sup>3</sup>. Ao fim desses processos, a atividade 1 apresentada na Seção 1.1 é atendida.

A partir da ontologia e das instâncias criadas, uma rede semântica foi construída para representar as informações dos programas de TV e suas ligações. Essa rede criada é utilizada para se encontrar os interesses do usuário e os conteúdos que podem ser recomendados a ele. O sistema aplica técnicas de ativação semântica, a fim de descobrir a proximidade semântica de programas de TV que o usuário consumiu e outros disponíveis na grade de programação. Como resultado, o sistema cria o perfil do usuário, que é utilizado tanto para representar seus interesses como para recomendar conteúdos diretamente para ele. Dessa forma, os objetivos 2, 3, 4, 5 e 6 apresentados na Seção 1.1 são contemplados.

Após a criação do perfil do usuário, ele é representado em XML (*Extensible Markup Language*) de forma que seja facilitada sua integração com outras aplicações, bem como seu intercâmbio e armazenamento. Esse processo complementa o objetivo 5 da Seção 1.1.

A proposta apresentada por esta dissertação é validada com a modelagem e implementação do SeReS - *Semantic-based Recommender System*. O SeReS incorpora os resultados obtidos nos objetivos especificados na Seção 1.1, de forma que seja possível realizar a recomendação para o usuário.

### 1.3 Estrutura da dissertação

A dissertação está estruturada da seguinte forma:

O Capítulo 2 apresenta um histórico da TVD, mostra os principais sistemas existentes no mundo e apresenta o SBTVD.

---

<sup>1</sup><http://protege.stanford.edu>

<sup>2</sup><http://www.imdb.com/>

<sup>3</sup><http://thetvdb.com/>

No Capítulo 3 são apresentados alguns aspectos da *Web Semântica*, principalmente a utilização de ontologias, as linguagens utilizadas para sua representação, como construir uma ontologia e como gerar a rede semântica a partir de uma ontologia.

Os principais tipos de sistemas de recomendação existentes são apresentados no Capítulo 4, mostrando suas funcionalidades e suas limitações.

O Capítulo 5 apresenta a construção do SeReS, seu funcionamento e sua forma de recomendar conteúdos através da abordagem semântica. Também são apresentados alguns trabalhos relacionados, mostrando suas características e um comparativo com o SeReS.

No Capítulo 6 são apresentados os testes realizados para validar o SeReS, bem como a proposta de integração do sistema no *middleware* Ginga.

Por fim, no Capítulo 7 são apresentadas as considerações finais sobre a dissertação, as principais contribuições do trabalho e sugestões para trabalhos futuros.

## 2 Televisão Digital Interativa

Desde que a televisão (TV) surgiu, no início do século XX, diversos aparelhos foram comercializados e vários programas foram criados. O maior avanço que ocorreu nas transmissões de sinais de TV foi a transformação de imagens em preto e branco para a colorida. Dessa forma, tem-se que a TV em cores foi o maior avanço atingido com a TV, até o surgimento da TVD.

Devido a necessidade de melhoria da imagem e do som nas transmissões de TV, tem-se buscado uma melhor qualidade desses requisitos, o que acarretou o surgimento da TVD. Essa tecnologia não busca somente alterar as formas de transmissão de analógica para digital, mas também altera toda a forma de se produzir conteúdo, de se armazenar as informações e possibilita a interação com o telespectador.

Uma confusão que sempre ocorre é pensar que TVD é o mesmo que HDTV (*High Definition Television*). Na verdade, HDTV corresponde à qualidade da imagem transmitida, considerando a quantidade de linhas que definem como a imagem será apresentada na tela, quanto maior o número de linhas, maior a qualidade exibida.

Segundo Chorianopoulos e Lekakos (2007) a definição de TVD está vinculada a quem fornece a definição: um engenheiro dirá que a TVD é uma transmissão digital em *broadcast* e um canal de retorno; um produtor de conteúdo dirá que é um conjunto de gráficos interativos; e um profissional de mídias irá descrever novos formatos de mídias, jogos e interatividade. De uma forma mais genérica, Cesar e Chorianopoulos (2008) definem TVD como uma experiência audiovisual que envolve pelo menos um usuário e um ou mais dispositivos audiovisuais.

Para Yang et al. (2008) a parte interativa da TVD é composta por um controle remoto e aplicações interativas como relatórios de clima, votações, jogos etc. Essa interatividade é realizada através das aplicações que estão embutidas no programa da TVD. É comum na literatura o uso do acrônimo TVDi para referenciar os sistemas de TV que suportam interatividade. Nesta dissertação, por simplificação, será usado o acrônimo TVD para

todo sistema de TV digital, seja ele interativo ou não.

A interação quebra um paradigma bem definido em relação à TV, o de que o telespectador possui uma atitude passiva com a programação, ou seja, o máximo de interação que o usuário realiza é mudar de canal, não podendo interagir com um programa ou alterar parâmetros de acordo com o seu gosto. A TVD muda isso, pois permite que o telespectador passe a ter uma postura ativa, podendo definir preferências e interagir com as aplicações disponíveis na grade de programação da TV, através de enquetes, jogos ou pesquisas. Diversas pesquisas tem sido realizadas no sentido de permitir que o usuário interaja com a programação da TV de formas diferentes (Blanco-Fernández et al., 2006; Aroyo et al., 2007; Alves, 2008; Coelho, 2008).

A arquitetura da TVD é baseada em camadas, na qual as camadas inferiores prestam serviços às camadas superiores, e cada camada possui seus próprios protocolos e suas próprias funções. A Figura 2.1 apresenta o modelo de camadas da TVD (Montez; Becker, 2005).

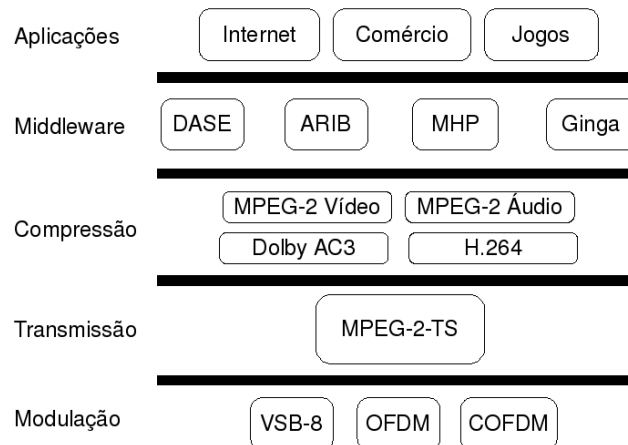


Figura 2.1: Modelo de camadas para TVD

Conclui-se que TVD não é somente uma forma de transmitir dados digitais. Ela também é composta por tecnologias de desenvolvimento de aplicações, formas de transmissão, codificação de vídeo e áudio, captura de perfil dos usuários e outros. Para permitir a interação com o usuário é necessário que exista um canal de retorno, pois os usuários precisam enviar dados informando preferências ou informações que permitam definir o seu perfil.

Quando se trabalha com TVD, o dispositivo receptor pode ser de diversos tipos (TV, PDA - *Personal Digital Assistant*, *Smartphone* e outros), com configurações diversificadas (capacidade de armazenamento, capacidade de processamento, resolução de tela etc.) e

com sistemas operacionais diferentes. Por esse motivo, é necessário a utilização de um software que identifique o tipo de dispositivo e como as informações serão passadas para ele. Esse software é o *middleware*.

O *middleware* pode ser entendido como uma camada de software que fica localizado entre o sistema operacional e as aplicações. Ele é responsável por disponibilizar as aplicações de acordo com o dispositivo utilizado pelo usuário, seja ele um telefone celular ou uma TV de alta resolução. Para permitir a diversificação de dispositivos, é necessário que estes forneçam às aplicações uma API (*Application Programming Interface*) genérica, padronizada e bem definida que deve identificar as especificações dos dispositivos receptores. A partir dessas informações, a API determina quais dados/funcionalidades podem ser oferecidas ao dispositivo, incluindo a possibilidade de interatividade. A Figura 2.2 apresenta a forma de trabalho do *middleware* dentro do sistema de TVD.



Figura 2.2: Arquitetura de um sistema de TVD com a camada do *middleware*

De acordo com Montez e Becker (2005), a função do *middleware* é fornecer um serviço padronizado para as aplicações ocultando as diferenças e tecnologias utilizadas para compressão, transporte e modulação das informações. A utilização do *middleware* permite que as aplicações sejam executadas em qualquer dispositivo receptor que tenha suporte ao *middleware* adotado, permitindo, assim, que as aplicações sejam portadas mais facilmente para os diversos dispositivos existentes.

A transmissão de TVD aberta no mundo ainda é motivo de estudo e de muita discussão com relação a definição de padrões para sua transmissão. No caso de TVD por assinatura o cenário é diferente, pois já existe um padrão bem consolidado e bem definido, o OpenTV (Coelho, 2008).

Para a TVD aberta, três padrões são os mais utilizados: o americano ATSC (*Advanced Television System Committee*) (Richer et al., 2006; ATSC, 2009), o europeu DVB (*Digital Video Broadcast*) (DVB, 2009) e o japonês ISDB (Takada; Saito, 2006). Existe ainda o

DMB (*Digital Multimedia Broadcast*), que é o padrão adotado na China. O Brasil adotou o padrão japonês (República, 2006) com algumas adaptações para o cenário brasileiro e para atender as requisições determinadas pelo Presidente da República (República, 2003). A Figura 2.3 apresenta a distribuição dos padrões de TVD adotados ao redor do mundo.

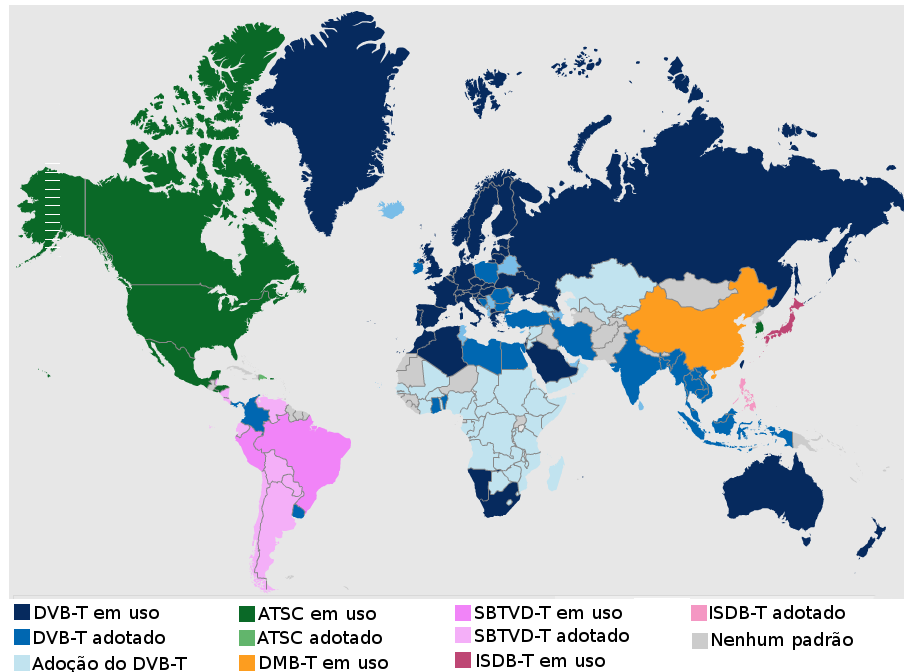


Figura 2.3: Distribuição dos padrões de TVD pelo mundo

## 2.1 Sistema Brasileiro de Televisão Digital - SBTVD

A TV é o meio de comunicação mais utilizado pelos brasileiros, estando presente em 95,7% das residências no país (IBGE, 2009). Devido a essa grande penetração da TV no Brasil, ela se torna o melhor meio para oferecer a tecnologia digital para os menos favorecidos, que não possuem acesso à Internet ou a um computador.

O SBTVD foi instituído pelo Decreto Presidencial nº 4.901 de 26 de novembro de 2003 (República, 2003) e tem em seu Artigo 1º, entre outros, os seguintes objetivos:

- *“Promover a inclusão social, a diversidade cultural do País e a língua pátria por meio do acesso à tecnologia digital, visando a democratização da informação;*
- *Propiciar a criação de rede universal de educação a distância;*



- *Estimular a pesquisa e o desenvolvimento e propiciar a expansão de tecnologias brasileiras e da indústria nacional relacionadas à tecnologia de informação e comunicação.”*

O SBTVD deve possibilitar que a transmissão digital seja realizada em alta resolução (HDTV) e resolução padrão (SDTV - *Standard Definition Television*); deve permitir a recepção por aparelhos fixos, móveis e portáteis e deve permitir a interatividade (República, 2006).

Para evitar a adoção de um sistema internacional, optou-se por desenvolver um padrão que se adequasse melhor ao cenário brasileiro, uma vez que mais de 95% da população possui acesso a TV aberta (IBGE, 2009). Uma mobilização de cientistas, pesquisadores, universidades, órgãos públicos e empresas privadas ocorreu para que o SBTVD fosse desenvolvido seguindo as exigências do Decreto 4.901 (República, 2003).

O Ginga (LAViD; Telemidia, 2009; Soares et al., 2010) é o *middleware* utilizado pelo SBTVD. Ele surgiu de uma parceria entre os laboratórios TeleMídia (Telemidia, 2009) da Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio) e LABViD (LAViD, 2009) da Universidade Federal da Paraíba (UFPB).

O *middleware* é composto por três módulos principais: *Common Core*, Ginga-NCL (Soares; Rodrigues; Moreno, 2007; ABNT, 2008b, 2008c) e Ginga-J (Souza Filho; Leite; Batista, 2007; ABNT, 2008d). Aplicações podem ser desenvolvidas seguindo dois padrões de programação diferentes, através de uma linguagem procedural ou uma linguagem declarativa. O desenvolvedor da aplicação é livre para escolher o melhor padrão a seguir de acordo com as especificações necessárias para o funcionamento de sua aplicação, dependendo da necessidade, um padrão é mais adequado que outro.

Aplicações procedurais são desenvolvidas utilizando-se a linguagem Java, enquanto as aplicações declarativas são desenvolvidas em NCL (*Nested Context Language*). A linguagem NCL foi desenvolvida pelo laboratório TeleMídia da PUC-Rio, e em abril de 2009 se tornou padrão internacional do ITU-T (*International Telecommunication Union - Telecommunication Standardization Sector*), sob a recomendação H.761 (ITU, 2009).

A arquitetura e as facilidades do Ginga foram desenvolvidas para sistemas de transmissão em *broadcast* e receptores terrestres, no entanto, ele pode ser utilizado para outros tipos de transmissão, como satélite, TV a cabo ou IPTV (Soares; Rodrigues; Moreno, 2007).

No *Common Core* estão localizados os serviços que são necessários tanto para a má-

quina de execução (Ginga-J), quanto para a máquina de apresentação (Ginga-NCL). O *Common Core* é responsável pela integração entre os módulos Ginga-NCL e Ginga-J. Ele é composto por decodificadores de conteúdo comum e procedimentos que são utilizados para obter conteúdos transportados em fluxos de transporte ou pelo canal de retorno (Soares; Rodrigues; Moreno, 2007). A Figura 2.4 apresenta a arquitetura do *Common Core* e seus componentes básicos (Soares; Rodrigues; Moreno, 2007).



Figura 2.4: Componentes do Ginga *Common Core*

A descrição dos componentes do Ginga *Common Core* são apresentados a seguir.

- **Sintonizador:** Módulo responsável pela escolha do canal físico e um dos fluxos de transporte (*Transport Stream*) que está sendo transmitido no canal.
- **Filtro de seção:** Assim que o canal é selecionado, o *middleware* precisa ter acesso a partes específicas do fluxo de transporte. O filtro de seção é capaz de buscar no fluxo exatamente a parte que as APIs precisam para serem executadas. Dessa forma ele deixa passar somente as informações requeridas pela API, realizando uma filtragem no fluxo.
- **Processador de dados:** Módulo responsável pelo acesso, processamento e repasse dos dados recebidos pela camada física. Possui também a responsabilidade de notificar os outros módulos sobre qualquer evento recebido.
- **Persistência:** O *middleware* permite que se salve arquivos, mesmo que o processo que o criou tenha sido finalizado, para que seja possível abrí-lo novamente. Este módulo é o responsável por esta persistência dos arquivos.
- **Iniciador de aplicações:** Módulo que faz o gerenciamento das aplicações. Possui a função de carregar, configurar, inicializar e executar qualquer aplicação (declarativa ou procedural). Ele também é responsável pelo controle de vida das aplicações e pelo controle dos recursos utilizados por elas.

- **Adaptador do A/V principal:** Esse módulo permite que as aplicações tenham acesso ao fluxo de áudio e vídeo. Isso é necessário quando uma aplicação precisa ter controle de suas ações baseado no que está sendo transmitido.
- **Gerenciador gráfico:** Responsável por definir como as imagens, vídeos, dados etc., serão apresentados ao usuário. A forma e apresentação são definidas pelo padrão do ISDB (ARIB, 2008).
- **Gerenciador de atualizações:** Módulo que gerencia as atualizações realizadas no sistema; verificando se existe alguma modificação, realizando o *download* de versões mais atuais e atualizando o *middleware* sempre que houver uma nova versão ou uma correção de versões anteriores. Este procedimento deve ser realizado em tempo de execução, sem atrapalhar o uso normal do usuário.
- **Exibidor de mídia:** Módulo que contém as ferramentas utilizadas para exibir os arquivos de mídias recebidos (MPEG, JPEG, MP3, GIF, XML etc.).
- **Interface com o usuário:** Módulo que captura e interpreta os eventos gerados pelo usuário e informa os outros módulos interessados nesses eventos.
- **Gerenciamento de contexto:** Responsável por capturar preferências do usuário, informando outros módulos que tenham interesse nessas preferências. Essas informações podem ser: horários em que o usuário assiste a TV, programação preferida, entre outras.
- **Canal de retorno:** Responsável por prover a interface dos outros módulos com o canal de retorno. Além disso, deve realizar o gerenciamento do canal de retorno de forma que informações sejam transmitidas assim que o canal estiver disponível, ou “forçar” a transmissão caso o horário exato de transmissão tenha sido estipulado pelo usuário ou por uma aplicação.
- **Acesso condicional:** Módulo responsável por restringir conteúdos inapropriados recebidos pelos canais de programação.

Ginga-NCL é um subsistema do Ginga que processa documentos NCL (Soares; Rodrigues; Moreno, 2007; Oliveira; Cunha, 2008). Um componente chave do Ginga-NCL é a máquina de interpretação de conteúdo declarativo (formatador NCL Maestro) e seu módulo de gerenciamento de base privada. O Maestro tem a função de receber os documentos NCL e controlar sua apresentação, sempre tentando garantir que os relacionamentos entre os objetos de mídia sejam respeitados (Oliveira; Cunha, 2008).

Outros módulos importantes do Ginga-NCL são o exibidor (*user agent*) de XHTML, que inclui interpretadores de estilo CSS (*Cascading Style Sheets*) e ECMAScript e a máquina de apresentação LUA, que é responsável por interpretar scripts LUA (ABNT, 2008c). Dependendo da implementação XHTML, o Ginga-NCL pode ser compatível com outros padrões declarativos.

De acordo com Rodrigues e Soares (2006), a linguagem NCL é declarativa e baseada em XML. A NCL é dividida em módulos, que agrupam elementos e atributos XML que possuam alguma relação semântica entre si. De acordo com as necessidades de uma aplicação, as funcionalidades da linguagem podem ser reunidas, visto que a relação semântica agrupa os elementos e atributos.

Como na linguagem NCL existe uma separação estrita entre conteúdo e estrutura, ela não define nenhum tipo de mídia por si só. Ao invés disso, ela define uma ligação que mantém os objetos ligados às apresentações multimídia. Entretanto, um documento NCL somente define como os objetos estão estruturados e relacionados no tempo e no espaço (Soares; Rodrigues; Moreno, 2007), sendo de responsabilidade do Maestro exibir o conteúdo de forma correta.

A linguagem LUA (ABNT, 2008b), que também foi desenvolvida na PUC-Rio, é a linguagem de script adotada pelo Ginga-NCL. LUA é muito utilizada na área de entretenimento, principalmente no desenvolvimento de jogos. Ela é leve, simples de usar e possui alto desempenho.

Ginga-J é um componente do *middleware* que fica residente nos dispositivos receptores (STB, TV, PDA etc.). Um dos principais objetivos do Ginga é interagir com dispositivos móveis/portáteis, não somente enviando dados para estes dispositivos, mas também recebendo e interpretando os dados enviados pelos dispositivos (Souza Filho; Leite; Batista, 2007).

O usuário pode interagir com a aplicação através de dispositivos de entrada e saída associados ao equipamento que contém o *middleware*. Esses dispositivos podem ser controles remotos ou teclados. Em resposta à entrada do usuário, o equipamento pode apresentar uma saída visual ou um som utilizando sua tela de exibição e caixas de som, no caso de uma TV por exemplo, ou usando a tela do dispositivo de interação, como um PDA.

Vários usuários podem interagir com o Ginga ao mesmo tempo. Para isso ocorrer, cada usuário deverá ter um dispositivo de interação e o Ginga poderá diferenciar os comandos enviados por e para cada dispositivo.

O Ginga-J é a parte procedural do Ginga. Baseado em tecnologias Java (*Java Virtual Machine* - JVM e APIs), ele incorpora diversas inovações, principalmente para atender as requisições impostas pelo Decreto 4.901 (República, 2003), mas mantém a compatibilidade com a maioria dos *middlewares* existentes, desde que eles trabalhem com o GEM (*Globally Executable MHP*) (ETSI, 2008).

## 2.2 Considerações finais

Neste Capítulo foram apresentadas as principais características da TVD e a sua abrangência no mercado mundial. Os principais sistemas existentes foram mostrados e em seguida foi abordado o SBTVD, que por ser um sistema novo, viabiliza a possibilidade de várias pesquisas na área de TVD.

Além dos sistemas abordados, também foi realizado um levantamento dos *middlewares* utilizados pelos sistemas de TVD existentes, mostrando as características de cada um. As bibliotecas de suporte aos *middlewares* também foram apresentadas, uma vez que é importante conhecer como as aplicações podem ser desenvolvidas para cada sistema.

Por fim, foi realizada uma descrição detalhada do SBTVD, mostrando suas características, sua finalidade e o *middleware* adotado por este padrão, denominado Ginga. A descrição do Ginga também foi realizada, mostrando os três módulos principais, e a função específica de cada um deles.

## 3 Ontologias e redes semânticas

Este Capítulo apresenta algumas técnicas empregadas na *Web Semântica*, que foram adotadas para o desenvolvimento do SeReS. A primeira técnica apresentada é a ontologia, abordando sua definição, sua representação e suas formas de criação. Em seguida é abordada a rede semântica, que permite relacionar conteúdos e conceitos existentes na ontologia.

O Capítulo está organizado da seguinte maneira: a Seção 3.1 apresenta a definição de ontologias, o motivo de sua utilização e as linguagens utilizadas para sua representação. As metodologias para construção de ontologias são descritas na Seção 3.1.2. As redes semânticas são apresentadas na Seção 3.2. Por fim, na Seção 3.3 são apresentadas as considerações finais do Capítulo.

### 3.1 Ontologias

O termo ontologia é original da filosofia, e representa um subcampo dessa ciência, que significa o estudo da natureza da existência, ou seja, é a forma de representar os tipos de coisas existentes e como elas são caracterizadas. Em computação, ontologias são utilizadas em áreas de pesquisa da inteligência artificial (representação do conhecimento, recuperação de informação, sistemas cooperativos e outros) para facilitar o compartilhamento e reuso de conhecimento (Fensel, 2004).

Diversas definições para ontologia são encontradas na literatura, uma das mais citadas no meio acadêmico é a definição de Gruber (1993), que define uma ontologia como sendo “*uma especificação explícita de uma conceitualização*”, ou seja, uma ontologia é um modelo de domínio descrito explicitamente. Em 1998, Studer, Benjamins e Fensel (1998) ampliam a definição de Gruber, explicando que uma ontologia é “*uma especificação formal e explícita de uma conceitualização compartilhada*”.

A “conceitualização” se refere a um modelo abstrato de algo real que identifica os

seus conceitos. “Explícito” significa que os conceitos utilizados e as restrições de uso são definidos de forma explícita. “Formal” se refere ao fato de que a ontologia é representada por uma linguagem legível por máquinas, e “Compartilhada” significa que o conhecimento é consensual, ou seja, não é definido por uma única pessoa e sim por um grupo que aceita aquelas definições para um determinado domínio.

De uma maneira geral, uma ontologia é utilizada para descrever formalmente um domínio de conhecimento. Basicamente, uma ontologia é composta por um conjunto de conceitos e relacionamentos entre esses conceitos. Os conceitos são representados através de classes, que compõem o domínio de conhecimento, enquanto os relacionamentos permitem a hierarquia entre as classes e fornecem as relações que as classes possuem entre si (propriedades, restrições de valores, disjunção e especificações lógicas de relacionamentos entre classes) (Antoniou; van Harmelen, 2008).

Um exemplo de ontologia é apresentado na Figura 3.1, no qual o domínio utilizado é o de instrumentos musicais (Adaptado de Breitman (2005)). É possível observar que existe uma hierarquia entre os conceitos.

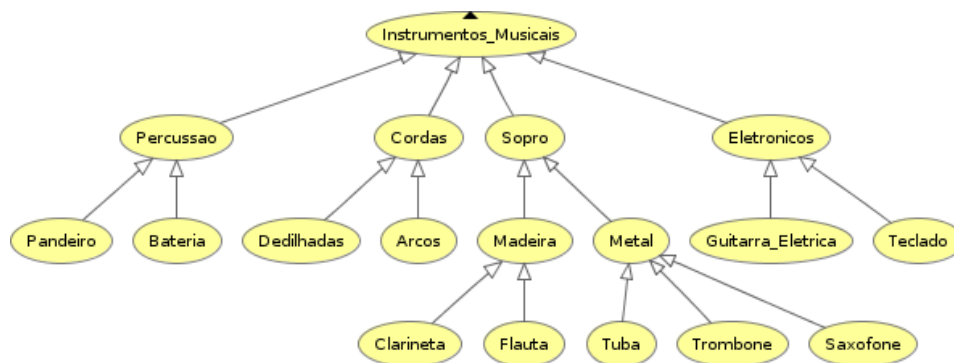


Figura 3.1: Ontologia para instrumentos musicais

A utilização de ontologias oferece algumas vantagens, como:

- Prevenção contra significados diferentes de termos em um domínio: como a ontologia representa uma base de conhecimento compartilhada e consensual, os termos utilizados não apresentarão ambiguidade;
- Independência de software: as ontologias utilizam uma abordagem declarativa, o que permite que elas sejam desenvolvidas em qualquer software que trabalhe com edição de textos;
- Interoperabilidade entre softwares: as ontologias são escritas em linguagens legíveis

por máquinas (Seção 3.1.1), e permitem que qualquer software que suporte essas linguagens possa ler e entender a ontologia;

- Compartilhamento da ontologia através de arquivos descritivos: como as ontologias são representadas por arquivos baseados em XML, e no seu conteúdo estão definidos todas as classes e relacionamentos, é possível compartilhar esse conhecimento através de um único arquivo;
- Reutilização de ontologias: é possível utilizar ontologias já existentes para se modelar um novo domínio, o que evita o retrabalho, uma vez que o reuso permite que se adapte ontologias existentes ao novo domínio desejado;
- Realiza inferências: a partir de relacionamentos e restrições definidas na ontologia, os softwares são capazes de inferir informações e expandir a base de conhecimento.

Observando as vantagens que uma ontologia oferece, foi desenvolvida uma ontologia de domínio para ser aplicada ao SBTVD que representa os conteúdos disponíveis na grade de programação. Esta ontologia é descrita no Capítulo 5.

### 3.1.1 Linguagens de representação de ontologias

Diversas linguagens para representação de ontologias foram desenvolvidas nos últimos anos. Algumas foram desenvolvidas por grupos de pesquisas e outras definidas pelo W3C (*World Wide Web Consortium*). A necessidade de se definir uma linguagem para representar ontologias é permitir que as informações semânticas presentes nos conteúdos sejam disponibilizados para os usuários.

Alguns trabalhos (Gómez-Pérez; Corcho, 2002; Corcho; Fernández-López; Gómez-Pérez, 2003) realizaram o levantamento das principais linguagens desenvolvidas e utilizadas na representação de ontologias. Essas linguagens e seus relacionamentos são apresentados na Figura 3.2 e suas descrições são apresentadas a seguir.

#### XOL

A linguagem XOL (*Ontology Exchange Language*) (Karp; Chaudhri; Thomere, 1999) é baseada em XML e foi desenvolvida para oferecer um formato para troca de ontologias entre sistemas. As definições da ontologia codificam informações sobre o domínio utilizado, por exemplo, classes de objetos; e informações que não são do domínio, como definições dos objetos.



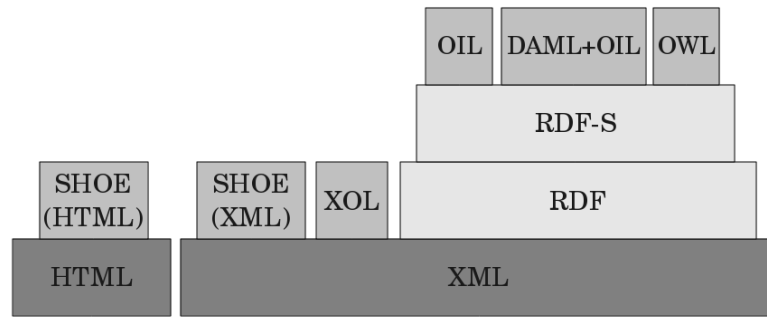


Figura 3.2: Linguagens utilizadas para representar ontologias

Sua semântica é baseada no OKBC-Lite, que é uma simplificação do modelo de conhecimento OKBC<sup>1</sup> (*Open Knowledge Base Connectivity*). O OKBC é uma API utilizada para acessar sistemas de representação de conhecimento.

Os desenvolvedores definiram como objetivo que o XOL seria uma linguagem de troca, utilizada como uma linguagem intermediária para transferir ontologias entre sistemas diferentes, ferramentas de desenvolvimento de ontologias ou programas aplicativos (Karp; Chaudhri; Thomere, 1999).

## SHOE

A linguagem SHOE (*Simple HTML Ontology Extensions*) (Heflin; Hendler; Luke, 1999), desenvolvida na Universidade de Maryland, foi criada como uma extensão do HTML (*HyperText Markup Language*) e incorpora conhecimentos semânticos em documentos HTML ou outros documentos *Web*. Atualmente, a linguagem também suporta a sintaxe XML, melhorando a busca de informações em páginas *Web* e a descoberta de conhecimento. Esse processo é dividido em três fases: Definição da ontologia, inserção das informações ontológicas nas páginas *Web* e um agente semântico de recuperação de informação.

A linguagem fornece *tags* específicas para representar as informações ontológicas. Os navegadores *Web* não exibem essas *tags* quando a página é acessada, pois o HTML não as possui em sua especificação. SHOE realiza distinção entre asserções ou instâncias e a terminologia da ontologia, e permite que se defina conceitos, relacionamento e atributos.

<sup>1</sup><http://www.ai.sri.com/~okbc/>

## RDF e RDF-Schema

A linguagem RDF<sup>2</sup> (*Resource Description Framework*) é uma especificação do W3C e foi desenvolvida para padronizar a definição e o uso de descritores dos recursos na *Web* (Decker et al., 2000). A linguagem também fornece interoperabilidade e semântica dos metadados, facilitando a busca de recursos na *Web*.

A base do RDF é a tripla *objeto-atributo-valor*, que pode ser escrita como  $P(x,y)$ , ou seja, um objeto  $x$  tem um atributo  $P$  com valor  $y$ . Outra maneira de se representar este relacionamento é através de um grafo direcionado com seus nós e arestas nomeados. Por exemplo, a afirmação *Nicolas Cage atuou no filme “60 segundos”* pode ser representada como *Atuou(Nicolas Cage, “60 segundos”)* ou então na forma de grafo, conforme apresentado na Figura 3.3.




Figura 3.3: Representação de uma expressão RDF na forma de grafo

Essas representações são boas quando se está projetando o sistema e se deseja visualizar os relacionamentos, porém para que as máquinas possam processar essas informações é necessário outra representação, que neste caso é baseada em XML. Todo documento RDF utiliza um elemento XML com a *tag* `rdf:RDF`. Seu conteúdo é formado por um conjunto de descritores, que utilizam a *tag* `rdf:Description`, sendo que cada descritor corresponde a um recurso do elemento representado. Para a afirmação utilizada anteriormente, o código RDF fica da seguinte forma:

```

<rdf:RDF>
  <rdf:Description about:"60 segundos">
    <ont:atuou>
      Nicolas Cage
    </ont:atuou>
  </rdf:Description>
</rdf:RDF>
  
```

Segundo Breitman (2005) o RDF é um modelo utilizado para representar objetos e seus relacionamentos fornecendo uma semântica simples através da linguagem XML,

---

<sup>2</sup><http://www.w3.org/RDF/>

porém, a autora afirma que o RDF consegue representar bem os metadados, mas não consegue oferecer os recursos necessários para ser uma linguagem de ontologias. Por esse motivo, foi desenvolvido o *RDF-Schema*, que é uma linguagem utilizada para descrever vocabulários permitindo que se consiga descrever propriedades e classes para os recursos RDF.

De acordo com Decker et al. (2000) o *RDF-Schema* permite que desenvolvedores definam um vocabulário para os dados RDF e especifiquem em quais tipos de objetos os atributos definidos no vocabulário podem ser aplicados. Esse esquema possui termos pré-definidos para representar alguns relacionamentos, como `rdfs:Class`, `rdfs:subClassOf` e `rdfs:type`. Para tornar o arquivo RDF mais legível, o *RDF-Schema* fornece propriedades que podem ser adicionadas aos recursos: `rdfs:comment`, que permite que comentários sejam associados aos recursos descritos e `rdfs:label`, que permite que se adicione um nome significativo ao recurso.

Para exemplificar a utilização do *RDF-Schema*, o código a seguir representa uma propriedade que é aplicada a todas as pessoas e tem seu valor expresso como um número inteiro.

```
<rdf:DatatypeProperty rdf:ID="Idade">
  <rdfs:domain rdf:resource="#Pessoa"/>
  <rdfs:range rdf:resource="&xsd:positiveInteger"/>
</rdf:DatatypeProperty>
```

Neste código é definido que a relação “Idade” possui como domínio uma “Pessoa” e como valores possíveis (*range*) números inteiros positivos, ou seja, uma “Pessoa tem idade igual a um valor maior que zero”.

## OIL

A linguagem OIL (*Ontology Inference Layer*) (Fensel et al., 2001) teve apoio de um consórcio da Comunidade Européia e surgiu através do projeto *On-to-Knowledge*<sup>3</sup>. Ela surgiu devido a necessidade de uma linguagem avançada que permitisse expressar e representar ontologias no ambiente *Web*, uma vez que o RDF não oferece a semântica e nem o formalismo que permita realizar inferências. Ela é baseada em três pilares:

<sup>3</sup><http://www.aifb.kit.edu/web/On-To-Knowledge>

- **Lógica descritiva:** Utilizada para descrever o conhecimento em termos de conceitos e restrições que são utilizadas para realizar inferências, permitindo que novas taxonomias sejam classificadas a partir do conhecimento existente.
- **Sistemas baseados em *frames*:** Utiliza primitivas de modelagem epistemológica, que são classes (*frames*) com propriedades (atributos). OIL tem como base a noção de um conceito e a definição de suas superclasses e atributos. Os relacionamentos podem ser definidos como atributos de uma classe, e assim como as classes podem ser arranjados em uma hierarquia.
- **Linguagens padrão *Web*:** Devido a necessidade de se utilizar linguagens que sejam padronizadas na *Web*, OIL tem sua sintaxe baseada em XML e RDF.

Quando se descreve uma ontologia em OIL, toda sua informação é organizada em três camadas: a camada de objeto, onde as instâncias da ontologia são descritas; a camada de definição, onde são fornecidas as definições da ontologia – nesta camada é definida a terminologia que deve ser instanciada na camada de objeto; e a camada de recipiente (*container*), onde são armazenadas informações a respeito da própria ontologia tais como autor, data de criação, assunto, etc.

Uma das vantagens de se utilizar a linguagem OIL para representar ontologias é que ela permite a construção de uma hierarquia entre classes, bem como relacionamentos e suas restrições entre as classes (Fensel et al., 2001; Breitman, 2005).

## DAML

Na mesma época em que a OIL era desenvolvido na Europa, a DARPA (*Defense Advanced Research Projects Agency*) estava desenvolvendo o projeto DAML<sup>4</sup> (*DARPA Agent Markup Language*). De acordo com Horrocks (2002) foi decidido que o primeiro passo seria adotar uma linguagem de ontologia para facilitar a interoperabilidade semântica entre os vários projetos do programa. A linguagem foi baseada no RDF, utiliza construtores de orientação a objetos e linguagens de representação de conhecimento baseadas em *frames*, e recebeu o nome de DAML-ONT. Assim como RDF-S, a DAML-ONT sofre com uma especificação semântica pobre, e por esse motivo foi necessário a criação de uma nova linguagem.

Como as linguagens OIL e DAML-ONT foram desenvolvidas na mesma época e apresentavam algumas semelhanças, os desenvolvedores concluíram que os objetivos de ambos

---

<sup>4</sup><http://www.daml.org/>

os grupos seriam atingidos de uma forma otimizada se eles combinassem seus esforços, assim resolveram mesclar as linguagens e criaram a DAML+OIL, descrita a seguir.

## DAML+OIL

DAML+OIL (Horrocks, 2002; Mcguinness et al., 2002) é uma linguagem para representar ontologias e é utilizada para descrever a estrutura de um domínio. Trabalha com a abordagem de orientação a objeto, no qual o domínio é descrito na forma de classes e propriedades.

A linguagem oferece uma maior ênfase para a semântica e introduz vários construtores de linguagens que aumentam o poder de expressividade da DAML. Em dezembro de 2000 foi lançada a primeira versão da linguagem (Mcguinness et al., 2002; Breitman, 2005) que oferecia manipulação de conceitos, restrições de cardinalidade, modificação de restrições semânticas e integração de condições necessárias e suficientes.

A linguagem DAML+OIL é dividida em duas partes: o domínio dos objetos, que é composto por todos os objetos de classes definidos pela ontologia DAML; e o domínio de tipos de dados, que é composto pelos valores provenientes do XML. O objetivo dessa separação é permitir que se utilize mecanismos de inferência.

## OWL

OWL<sup>5</sup> (Horrocks; Patel-Schneider; van Harmelen, 2003) é uma linguagem para representação de ontologias desenvolvida pelo grupo *Web Ontology Working Group* do W3C. Essa linguagem foi criada para representar informações sobre objetos e relações entre esses objetos, visando atender algumas necessidades de aplicações que precisam processar o conteúdo de informações em vez de somente apresentá-las para leitura.

OWL permite que máquinas interpretem os conteúdos *Web*, pois ela é baseada em XML, RDF e RDF-S, além disso oferece um vocabulário adicional que implementa uma semântica formal.

A linguagem OWL é dividida em três sublinguagens que aumentam o poder de expressividade de acordo com a linguagem utilizada:

- OWL *Lite*: Suporta a criação de hierarquias e restrições simples, não permitindo que se trabalhe com estruturas de relacionamento complexas. A principal idéia do

---

<sup>5</sup><http://www.w3.org/TR/owl-features/>

OWL *Lite* é fornecer um caminho rápido para migração de taxonomias e tesouros para o formato de ontologias.

- OWL-DL (*Description Logic*): Oferece o máximo de expressividade enquanto garante que todas as conclusões são computáveis e podem ser finalizadas em um tempo finito. Esta linguagem inclui todas as construções da linguagem OWL.
- OWL-*Full*: Oferece o máximo de expressividade e liberdade sintática do RDF sem garantias computacionais de que as informações serão processadas. Essa linguagem permite que uma ontologia aumente o significado de um vocabulário já definido em RDF ou OWL.

A linguagem adotada para representar a ontologia do SeReS foi a OWL-DL, pois ela oferece uma grande expressividade e garante que as inferências realizadas sejam computadas em um tempo finito, o que não compromete a computação do sistema.

### 3.1.2 Metodologias para desenvolvimento de ontologias

Para se construir e oferecer manutenção a uma ontologia é necessário seguir alguns passos de forma que sua construção atenda as necessidades exigidas pelo sistema em que será aplicada. Segundo Pinto e Martins (2004) para se construir uma ontologia é necessário seguir algumas etapas: especificação, conceitualização, formalização, implementação e manutenção. Em cada uma das etapas existem atividades que devem ser realizadas, conforme descrito a seguir.

- Especificação: Determinar qual é o propósito e o escopo da ontologia. O propósito deve responder a pergunta “Porque a ontologia está sendo desenvolvida?” e o escopo deve responder “Qual é a finalidade da ontologia e quem são seus usuários?”
- Conceitualização: Fase onde se descreve através de um modelo conceitual a ontologia a ser construída, baseando-se nas especificações definidas no passo anterior. Metodologias diferentes utilizam modelos conceituais diferentes. O modelo conceitual da ontologia contém os conceitos do domínio e os relacionamentos entre esses conceitos.
- Formalização: Fase na qual o modelo conceitual é colocado em um modelo formal, não necessariamente o final. Os conceitos são definidos através de axiomas e restrições que impedem a ambiguidade de seus significados. Também é definida a hierarquia dos conceitos.

- Implementação: Utilização de uma linguagem de representação de ontologia para especificar o modelo formal.
- Manutenção: Fase que ocorre durante todo o processo de desenvolvimento da ontologia e também após a sua finalização. Este processo tem o objetivo de atualizar e corrigir a ontologia desenvolvida.

Há também algumas atividades que devem ser executadas durante toda a fase do desenvolvimento, são elas: aquisição de conhecimento, avaliação e documentação.

Na aquisição de conhecimento é necessário levantar os conceitos e informações sobre o domínio, isto pode ser realizado através de entrevistas com especialistas do domínio, análise de textos, pesquisas bibliográficas, entre outros. A avaliação consiste na verificação da qualidade da ontologia, checando se ela é adequada para representar o domínio em que será aplicada. A documentação deve ser realizada em cada fase, descrevendo o que está pronto, como foi feito e porque foi feito. Uma forma de facilitar a manutenção e o uso da ontologia é também documentar os termos utilizados, facilitando a interpretação dos conceitos e informações utilizadas.

Visando o desenvolvimento de ontologias, várias metodologias foram criadas, conforme descrito em Jones, Bench-Capon e Visser (1998) e Pinto e Martins (2004). Algumas dessas metodologias são apresentadas a seguir, considerando as etapas de desenvolvimento e as formas utilizadas para se construir uma ontologia.

A metodologia TOVE (*Toronto Virtual Enterprise*) (Grüninger; Fox, 1995) utiliza o conceito de cenários de motivação, que são utilizados para descrever as motivações da ontologia proposta, em seguida são elaboradas questões de competência, ou seja, quais questões a ontologia deve atender.

Na descrição dos cenários de motivação são criados problemas que descrevem a motivação do desenvolvimento da ontologia. Nesta etapa, deve-se identificar as possíveis aplicações e soluções. Em seguida, são elaboradas perguntas baseadas nos cenários de motivação que a ontologia deve ser capaz de responder. A fase seguinte consiste em especificar termos da ontologia em uma linguagem formal, ou seja, definir termos, conceitos e predicados que serão utilizados no desenvolvimento da ontologia. Após a definição dos termos, deve-se adotar uma linguagem formal para representar as questões de competência e definir as regras e restrições para adicionar semântica aos termos e relacionamentos. Por último, é necessário verificar a competência da ontologia em relação ao conjunto de questões elaborado.

Seguindo o mesmo critério de etapas para o desenvolvimento de ontologias, a metodologia *Enterprise* (Uschold; Grüninger, 1996) foi proposta, na qual devem ser realizados quatro passos para se criar uma ontologia.

Primeiro deve-se identificar o porquê da ontologia ser construída, definir seu uso e quem são seus usuários. Em seguida, tem início a etapa de construção da ontologia, na qual são identificados os conceitos e seus relacionamentos, de forma que as definições sejam criadas de maneira não ambígua; esses conceitos são então codificados através de uma linguagem formal; e por último é realizada uma verificação de uso de uma ontologia já existente, evitando o retrabalho para desenvolvimento de uma nova ontologia. A fase seguinte consiste na avaliação da ontologia através de critérios técnicos, como verificar a especificação dos requisitos, validar as questões de competência e realizar uma comparação com o mundo real. Finalmente, deve-se documentar toda a ontologia, visando uma melhor utilização e manutenção da mesma. Os conceitos e relacionamentos devem ser descritos de forma a fornecer entendimento para quem for utilizar a ontologia.

*Methontology* (Fernández; Perez; Juristo, 1997) é uma metodologia proposta com base na experiência dos autores em desenvolvimento de ontologias para o domínio da química. Eles especificam algumas atividades que devem ser cumpridas durante o processo de desenvolvimento de uma ontologia.

A primeira etapa dessa metodologia tem como objetivo produzir um documento com a especificação informal da ontologia em linguagem natural, utilizando um conjunto de representações ou usando questões de competência. No estágio seguinte é realizado o levantamento dos termos da ontologia através de entrevistas com especialistas do domínio ou através de análises textuais em documentos da área. Na fase seguinte os termos do domínio são identificados como conceitos, instâncias, relacionamentos ou propriedades e cada um deles é representado de forma informal. Em seguida, é verificada a possibilidade de utilizar outras ontologias, visando aproveitar definições já existentes. A fase seguinte consiste em representar a ontologia através de uma linguagem formal. A avaliação da ontologia antes dela ser disponibilizada deve ser realizada após sua representação formal. A documentação deve ser realizada durante todo o processo de desenvolvimento. Por fim, a manutenção tem como objetivo manter a ontologia atualizada, uma vez que o domínio pode sofrer alterações e novas informações podem ser incorporadas à ontologia.

O método 101 foi proposto por Noy e McGuinness (2001) como um guia para a criação de uma primeira ontologia. As autoras afirmam que não pretendem definir uma metodologia e sim apresentar idéias que auxiliaram no desenvolvimento de suas ontologias.



De acordo com as autoras, existem algumas regras para se desenvolver uma ontologia: 1) não existe um único método correto para modelar um domínio, sempre vão existir opções. A melhor opção depende da aplicação e do que se pretende modelar; 2) o processo de desenvolvimento de ontologias é iterativo, ou seja, durante todo o processo é necessário revisar a ontologia; 3) os conceitos na ontologia devem ser bem próximos dos objetos reais e dos relacionamentos.

Baseada nessas regras, a metodologia é dividida em etapas, que consistem em determinar o domínio e o escopo da ontologia, considerar a reutilização de ontologias existentes, enumerar os termos importantes na ontologia, definir as classes e a hierarquia de classes, definir as propriedades das classes, definir os valores das propriedades e finalmente criar instâncias.

Como pode ser observado, todas as metodologias são semelhantes e utilizam etapas para o desenvolvimento de ontologias. Segundo (Jones; Bench-Capon; Visser, 1998), a criação de uma ontologia está mais relacionada com a familiaridade que o desenvolvedor possui com o sistema, do que com o processo a ser seguido para seu desenvolvimento, portanto não existe um método melhor que outro.

A ontologia desenvolvida nesta dissertação para representar os conteúdos da TVD foi criada seguindo o método 101, que permite uma descrição mais detalhada de cada etapa do processo de desenvolvimento.

## 3.2 Redes semânticas

Redes semânticas são grafos direcionados utilizados para representar conceitos de uma base de conhecimento através de palavras e frases da linguagem natural, onde os nós representam os conceitos e os arcos representam os relacionamentos semânticos entre os nós (Simons, 1972). De uma forma mais genérica, Sowa (1987) define uma rede semântica como um grafo que representa uma base de conhecimento.

Na computação, as redes semânticas foram utilizadas primeiramente na área de inteligência artificial, para em seguida serem adotadas em diversas outras áreas como representação de conhecimento, recuperação de informações e recomendação de conteúdo. Outras ciências também utilizam as redes semânticas, como a linguística (Hartley; Barn- den, 1997) e a psicologia (Johnson-Laird; Herrmann; Chaffin, 1984).

Pelo fato das redes semânticas serem representadas na forma de grafos é possível

utilizá-las para representar uma base de conhecimento ou utilizá-las em sistemas de recuperação de informações. Segundo Sowa (1987) são seis os tipos de redes semânticas mais comuns, descritas a seguir.

- Redes de definições: dão ênfase ao subtipo (subclasse), ou seja, enfatizam o relacionamento “*é-um*” entre um conceito e um novo conceito criado. A rede resultante possui uma hierarquia de generalização, na qual é utilizada a herança de propriedades dos conceitos.
- Redes assertivas: são redes criadas para validar proposições. A informação neste tipo de rede é assumida verdadeira, a menos que seja indicado o contrário. Algumas redes assertivas são utilizadas como modelos de estruturas conceituais sobre a semântica de linguagens naturais.
- Redes de implicação: utilizam a implicação como relação primária das conexões entre nós. Podem ser utilizadas para representação de padrões de causalidade ou inferências.
- Redes executáveis: redes que possuem alguma forma de processamento. Essas redes podem realizar inferências, troca de mensagens e busca por padrões e associações.
- Redes de aprendizagem: redes criadas ou estendidas para adquirir conhecimento a partir de exemplos. O conhecimento aprendido pode causar alterações na rede original pela adição ou exclusão de nós e arcos na rede, bem como a modificação de valores de pesos associados aos relacionamentos.
- Redes híbridas: redes que utilizam duas ou mais técnicas apresentadas anteriormente. Essas redes podem ser criadas separadamente, mas interagem entre si.

A criação de uma rede semântica pode ser realizada de forma explícita ou através do aproveitamento de alguma base de conhecimento, como por exemplo uma ontologia que representa algum domínio. A partir de uma ontologia é possível extrair informações de forma que seja possível elaborar uma rede semântica. Como a ontologia pode ser representada por um grafo com seus conceitos e relacionamentos, a criação da rede semântica a partir dela se torna praticamente direta, pois a rede semântica também é representada através de grafos.

### 3.3 Considerações finais

Este Capítulo apresentou as principais características de algumas técnicas semânticas adotadas no desenvolvimento do SeReS.

Primeiramente foram abordadas as ontologias e a sua utilização para representar um domínio de conhecimento. É importante observar como a ontologia auxilia o compartilhamento de informações entre sistemas, uma vez que ela representa de forma não ambígua conceitos que compõem o domínio utilizado em um sistema.

Foram abordadas também as linguagens utilizadas para representar ontologias, a evolução dessas linguagens e as melhorias adicionadas à cada nova versão desenvolvida. As linguagens permitem que as informações sejam trocadas entre sistemas de forma simples e rápida, uma vez que os arquivos são auto-explicativos.

Além das linguagens e das ontologias, também foram abordadas as principais metodologias utilizadas para o desenvolvimento de ontologias, suas abordagens e etapas a serem cumpridas para se criar uma ontologia.

Por último foi realizado o levantamento sobre redes semânticas, que são redes que representam uma base de conhecimento. A partir de uma ontologia é possível criar uma rede semântica, uma vez que a ontologia permite que se represente todos os conceitos, propriedades e relacionamentos da base de conhecimento.

No desenvolvimento do SeReS foi criada uma ontologia de domínio para representar os conteúdos disponíveis no SBTVD. Para representar a ontologia foi utilizada a linguagem OWL-DL, descrita na Seção 3.1.1, pois essa linguagem permite que os conceitos e relacionamentos sejam representados de forma a explorar toda sua expressividade.

Para o desenvolvimento da ontologia foi utilizado o método 101, descrito na Seção 3.1.2, que permite um melhor detalhamento das fases e uma melhor compreensão do que deve ser realizado em cada etapa do desenvolvimento.

Finalmente, para se criar a rede semântica a partir da ontologia, adotou-se uma rede híbrida, descrita na Seção 3.2. A rede adotada é composta por uma rede de definição, na qual são considerados os relacionamentos existentes para representar novos conceitos inseridos na rede; e uma rede de execução, que processa informações e realiza inferências para descobrir novas informações a partir dos dados existentes.

## 4 Sistemas de recomendação

Este Capítulo apresenta os principais tipos de sistemas de recomendação existentes, enfatizando as técnicas e os algoritmos utilizados por eles. Os sistemas de recomendação são utilizados para facilitar a busca por conteúdos de interesse do usuário, uma vez que eles apresentam uma relação de itens que possuem vínculos com os conteúdos já consumidos pelo usuário.

Existem basicamente três tipos de sistemas de recomendação: baseados em conteúdo, baseados em filtragem colaborativa e híbridos. Esses sistemas possuem características específicas e cada um deles utiliza uma técnica diferente para recomendar conteúdos para o usuário. A Seção 4.1 descreve os sistemas baseados em conteúdo; a Seção 4.2 apresenta os sistemas baseados em filtragem colaborativa; a Seção 4.3 apresenta os sistemas híbridos; os sistemas baseados em semântica são apresentados na Seção 4.4; finalmente, a Seção 4.5 apresenta as considerações finais do Capítulo.

### 4.1 Sistemas de recomendação baseados em conteúdo

Sistemas baseados em conteúdo são sistemas nos quais a recomendação é baseada no consumo anterior do usuário. Eles são construídos para recomendar itens que são similares a conteúdos já consumidos pelo usuário (Terveen; Hill, 2001) e que possuem um nível de interesse (preferência) por parte do usuário. As preferências são determinadas através do *feedback* do usuário. Este *feedback* pode ser obtido de duas formas: explícita, quando o usuário informa o que achou do conteúdo (bom, ruim, regular) ou implícita, que pode ser, por exemplo, baseada no tempo que o usuário gastou consumindo o conteúdo. Os itens consumidos e as preferências do usuário compõem o seu perfil, que é utilizado para realizar a recomendação.

Nesses sistemas, os conteúdos são recomendados através de uma comparação entre as informações disponíveis no sistema e as informações de preferências contidas no per-

fil do usuário. Esta abordagem utiliza um esquema de pesos para que conteúdos com maior similaridade obtenham um peso maior, enquanto conteúdos com menor semelhança recebem pesos menores.

A Figura 4.1 apresenta o processo da recomendação em um sistema baseado em conteúdo. Primeiramente, é necessário obter as informações do usuário alvo, de forma explícita ou implícita, para geração do seu perfil. Neste exemplo, o usuário consumiu o programa  $P_3$ . Após este passo, quando as recomendações começam a ser produzidas, as informações do perfil do usuário são comparadas com os conteúdos que podem ser recomendados. Os conteúdos que possuírem maior similaridade com as preferências do usuário lhe são apresentados como recomendações, no exemplo os conteúdos  $P_1$ ,  $P_5$  e  $P_9$ .

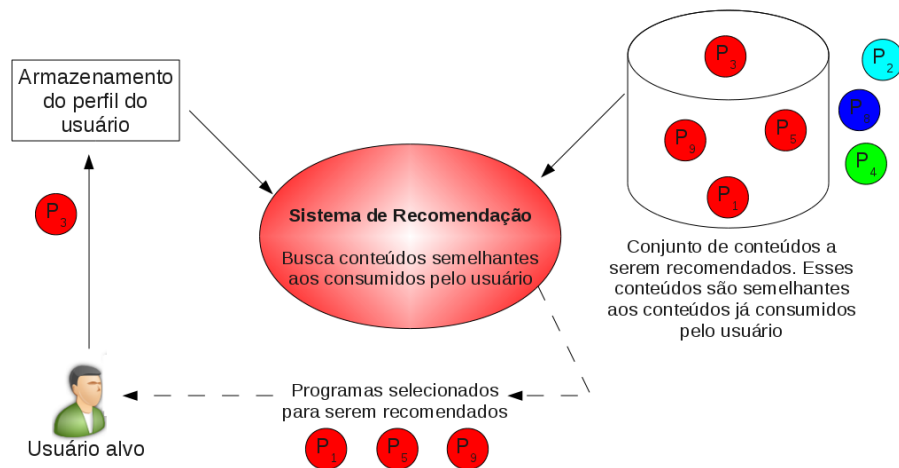


Figura 4.1: Filtragem baseada em conteúdo

Para se realizar esta recomendação é necessário utilizar técnicas que consigam encontrar similaridades entre os itens. Primeiro, é necessário estabelecer a forma como o perfil do usuário será representado. De uma maneira formal e seguindo a notação utilizada por Adomavicius e Tuzhilin (2005), seja  $Conteudo(I_n)$  o conjunto de informações que caracteriza o item  $I_n$ , isto é, o conjunto de informações de  $I_n$  usado para realizar a recomendação. Geralmente, este conjunto de informações é representado por um vetor que armazena os pesos correspondentes ao interesse do usuário por cada informação presente no vetor ( $w_{xn}$ ), conforme apresentado na Equação 4.1.

$$Conteudo(I_n) = (w_{1n}, w_{2n}, \dots, w_{kn}) \quad (4.1)$$

Nesse tipo de sistema, vários itens que podem ser recomendados são comparados com os itens consumidos e os que possuírem mais semelhanças serão recomendados. For-

malmente, seja  $PerfilUsuario(U)$  o perfil do usuário  $U$  que contém as preferências deste usuário. Esses perfis são gerados analisando o conteúdo de itens consumidos e avaliados pelo usuário. Sendo assim, o perfil do usuário pode ser representado por um vetor contendo os pesos de interesses do usuário ( $w_{Ux}$ ), conforme ilustra a Equação 4.2.

$$PerfilUsuario(U) = (w_{U1}, w_{U2}, \dots, w_{Uk}) \quad (4.2)$$

De posse do vetor é possível utilizar técnicas variadas para realizar a recomendação a partir dos itens avaliados, como, por exemplo, o método da distância euclidiana ou o método dos cossenos (Xu et al., 2002).

Um exemplo de sistema de recomendação baseado em conteúdo é o News Dude (Bill-sus; Pazzani, 1999, 2000). Este sistema trabalha como um agente pessoal de notícias. Essas notícias são recomendadas tomando como base termos existentes nos textos. Os interesses dos usuários são obtidos não somente através de avaliações dos usuários, mas também pelo tempo que eles passam lendo as novas notícias avaliadas. Para determinar as recomendações, novas notícias são descritas através de vetores, que são comparados utilizando o método dos cossenos.

### **Limitações dos sistemas baseados em conteúdo**

Sistemas baseados em conteúdo possuem algumas limitações já identificadas e descritas na literatura (Burke, 2002; Adomavicius; Tuzhilin, 2005). As principais limitações são descritas a seguir.

- **Análise restrita dos conteúdos:** Esses sistemas são restritos às informações associadas aos itens a serem recomendados. Por exemplo, um sistema de recomendação de filmes somente pode se basear nas informações escritas dos filmes: nome dos atores, nome dos diretores, gêneros etc.

A eficácia desses sistemas depende dos dados descritivos de cada item. Entretanto, para se obter um conjunto suficiente de informações sobre os itens, essas informações devem estar disponíveis de forma que possam ser interpretadas por um computador, ou extraídas manualmente de uma maneira fácil. Em alguns casos, é difícil conseguir essas informações, pois existem sistemas que possuem dificuldades para extração automática de informações e muitas vezes a extração manual não é muito prática de ser realizada.

- Superespecialização de conteúdos: Os sistemas baseados em conteúdo somente recuperam itens que possuem similaridade com um perfil específico do usuário. Gostos, interesses e preferências de outros usuários que podem melhorar as recomendações não são levados em conta, ou seja, esses sistemas não podem recomendar itens que sejam diferentes dos itens já consumidos pelo usuário.
- Efeito portfólio: Problema da não diversidade. Em alguns casos, itens não devem ser recomendados se eles são muito similares aos itens que o usuário já consumiu. Para evitar esse problema, deve-se recomendar ao usuário um conjunto variado de opções, e não somente um conjunto homogêneo de alternativas. Por exemplo, algumas vezes pode não ser uma boa idéia recomendar todos os filmes estrelados pela atriz “*Nicole Kidman*” para um usuário que gostou de um filme em que ela atuou. O fato dele ter gostado de um filme estrelado por ela, não significa que ele vai gostar de todos os filmes em que a atriz trabalhou.
- Problema *cold start*: Problema do novo usuário. Um usuário deve ter consumido um número suficiente de itens antes do sistema conseguir construir o seu perfil e apresentar recomendações confiáveis. Um usuário novo que não possui conteúdos consumidos ou que possui pouco consumo pode receber uma recomendação pouco precisa sobre suas preferências.

## 4.2 Sistemas de recomendação baseados em filtragem colaborativa

Filtragem colaborativa é a técnica que agrupa usuários com perfis semelhantes para realizar recomendação. Permite que a aplicação recomende conteúdo consumido por outros usuários que possuem preferências semelhantes às do usuário alvo.

Essa técnica funciona da seguinte forma: os conteúdos consumidos pelos usuários recebem uma determinada pontuação, que permite que o perfil de cada usuário seja gerado. Essa pontuação é então relacionada com preferências de outros usuários, gerando assim um conjunto de usuários com perfis semelhantes.

Uma grande vantagem desse sistema é que conteúdos que não compartilham atributos com outros conteúdos consumidos pelo usuário podem vir a ser recomendados a ele, trazendo o elemento surpresa à recomendação (Burke, 2002). Por exemplo, um usuário

que consumiu o filme “*Avatar*” demonstra interesse em assuntos relacionados com “*Aliens*” ou “*Meio ambiente*”. Dessa forma, o documentário “*Oceans*”, que tem relação com “*Meio Ambiente*”, ou o filme “*ET - O extrarrestre*”, que se relaciona com “*Aliens*” pode ser recomendado a ele.

Segundo Reategui e Cazella (2005) é necessário agrupar os usuários para que seja possível utilizar técnicas que permitam encontrar similaridades entre eles. Existem diversas técnicas que podem ser utilizadas para encontrar similaridades entre usuários, algumas delas são apresentadas em (Sarwar et al., 2001; Reategui; Cazella, 2005; Korenius; Laurikala; Juhola, 2007). Segundo Reategui e Cazella (2005) e Serpa et al. (2010), a correlação de Pearson é a técnica mais utilizada. De acordo com essa técnica, a similaridade entre os itens são avaliados em uma escala de -1 (sem correlação) a 1 (total correlação). O cálculo dessa correlação é dado pela Equação 4.3.

$$corr_{ab} = \frac{\sum_i (r_{ai} - \bar{r}_a)(r_{bi} - \bar{r}_b)}{\sqrt{\sum_i (r_{ai} - \bar{r}_a)^2 \sum_i (r_{bi} - \bar{r}_b)^2}} \quad (4.3)$$

Sendo  $corr_{ab}$  a correlação do usuário  $a$  com o usuário  $b$ ,  $r_{ai}$  a avaliação atribuída pelo usuário  $a$  ao item  $i$ ,  $r_{bi}$  a avaliação que o usuário  $b$  atribui ao item  $i$ ,  $\bar{r}_a$  a média de todas as avaliações do usuário  $a$  que são comuns ao usuário  $b$  e  $\bar{r}_b$  a média de todas as avaliações do usuário  $b$  comuns ao usuário  $a$ . É importante observar que é necessário mais de uma avaliação em comum para que a correlação possa ser aproveitada.

Segundo Serpa et al. (2010), outra forma de correlação é o cosseno, que é uma correlação geométrica definida pelo ângulo entre dois itens, dada pela Equação 4.4, onde  $a_{ik}$  é o  $k$ -ésimo atributo do item  $i$  e  $L$  o número de atributos.

$$D_{ij} = \frac{\sum_{k=1}^L a_{ik} a_{jk}}{\sqrt{\sum_{k=1}^L a_{ik}^2 \sum_{k=1}^L a_{jk}^2}} \quad (4.4)$$

O valor de  $D_{ij}$  pode variar entre -1 e 1, sendo que quando  $D_{ij} = 1$  o ângulo entre os vetores é  $0^\circ$ , e quando  $D_{ij} = -1$ , o ângulo é  $180^\circ$ . A distância considerada é  $d_{ij} = 1 - |D_{ij}|$ .

Estas correlações são utilizadas para encontrar similaridades entre itens possibilitando assim a formação de grupos com interesses semelhantes. Para se realizar o agrupamento, existem duas formas de se trabalhar (Gutiérrez, 2008):



## Filtragem colaborativa baseada em usuário

Compara os conteúdos consumidos pelo usuário alvo com os consumos de outros usuários para determinar um grupo de pessoas com interesses semelhantes. Dessa forma, os conteúdos com maior pontuação, que ainda não foram consumidos pelo usuário alvo podem ser recomendados a ele.

Basicamente, o sistema funciona da seguinte forma: um telespectador que assistiu ao programa  $P_1$  pode estar interessado no programa  $P_2$  se outros telespectadores que assistiram ao programa  $P_1$  também assistiram ao programa  $P_2$ .

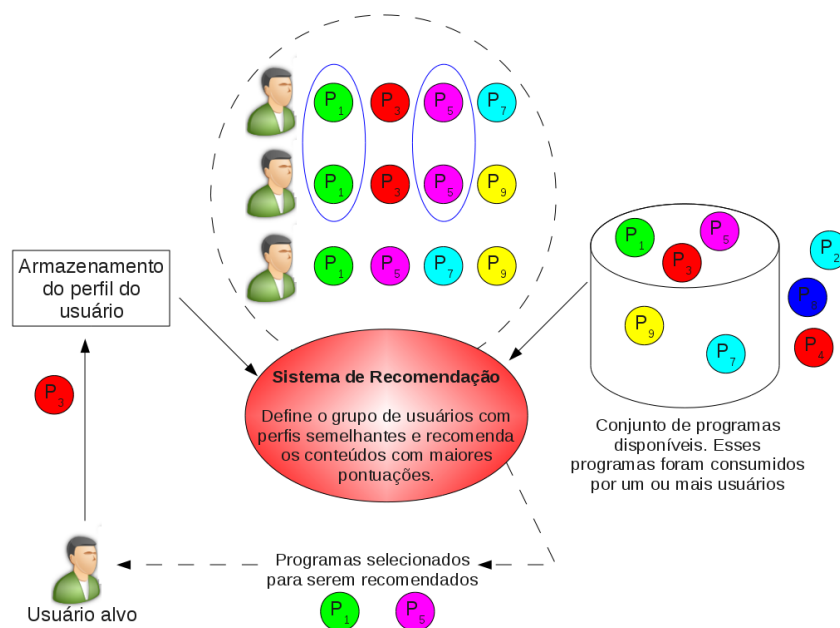


Figura 4.2: Filtragem colaborativa baseada em usuário

A Figura 4.2 apresenta o funcionamento da filtragem colaborativa baseada em usuário. O usuário alvo assiste a um programa  $P_3$ , essa informação é armazenada e assim o perfil do usuário é gerado; em seguida, o perfil é passado ao sistema de recomendação, que associa o perfil criado com todos os perfis de outros usuários já existentes, gerando assim grupos com as mesmas características. Em seguida, os programas que possuem os maiores consumos, no caso  $P_1$  e  $P_5$ , são selecionados e recomendados ao usuário alvo. Somente os programas que já foram consumidos podem ser recomendados, estes programas são representados na Figura pelo “conjunto de programas disponíveis”.

## Filtragem colaborativa baseada em conteúdo

Esta abordagem toma como base cada conteúdo consumido pelo usuário alvo e encontra outros conteúdos que possuem semelhança com os programas consumidos. A similaridade entre conteúdos é definida em termos de correlações de consumo (pontuação) entre os usuários.

Essa técnica foi desenvolvida para criar sistemas de recomendação com baixo custo computacional, pois esses sistemas não precisam realizar buscas em banco de dados que contém milhares de registros para encontrar usuários com preferências semelhantes (Sarwar et al., 2001). Ao invés de realizar essas buscas, o sistema gera uma pré-pontuação dos itens baseado em seus atributos e então gera recomendações sem necessitar de uma grande carga de processamento. De uma forma geral, essa técnica analisa os conteúdos consumidos pelo usuário alvo para identificar relacionamentos entre os programas, e então utiliza os relacionamentos para realizar recomendações para o usuário (Sarwar et al., 2001; Deshpande; Karypis, 2004).

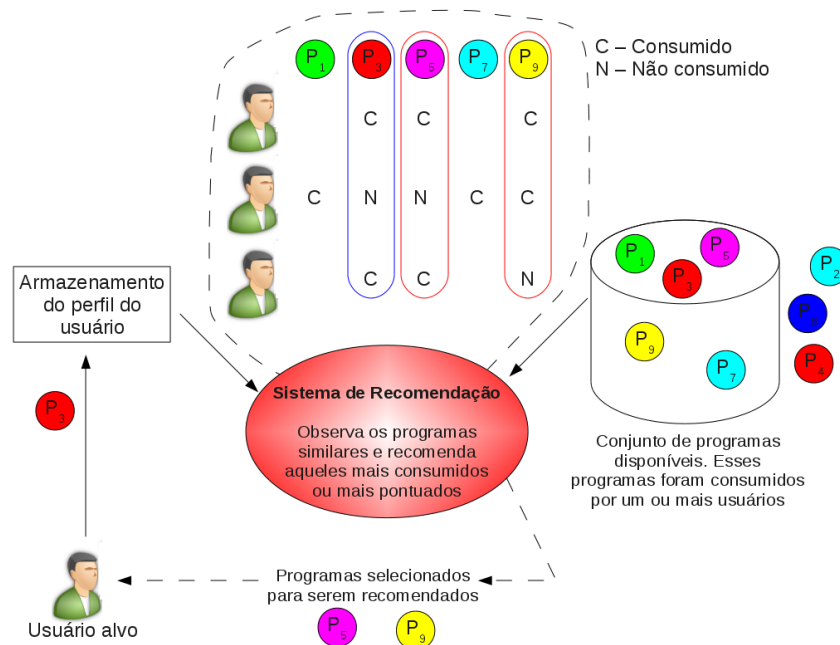


Figura 4.3: Filtragem colaborativa baseada em conteúdo

A Figura 4.3 apresenta o funcionamento da técnica de recomendação baseada em conteúdo. O conjunto de programas que podem ser recomendados é limitado aos conteúdos que já foram consumidos pelos usuários do sistema. O perfil do usuário alvo é armazenado localmente e então é realizada uma busca a conteúdos similares aos do perfil. Os programas similares são definidos e então é realizada uma filtragem selecionando os programas mais

consumidos. Esses conteúdos são recomendados ao usuário alvo. É importante notar que o conteúdo já assistido pelo usuário não faz parte da lista de recomendação.

Um dos sistemas de recomendação baseado em filtragem colaborativa mais conhecidos é o adotado pelo site de vendas *Amazon.com*<sup>1</sup> (Linden; Smith; York, 2003). Nesse sistema, a recomendação é realizada baseando-se nas avaliações dos itens disponíveis. Usuários com interesses semelhantes aos do avaliador de um item o recebem como recomendação.

### Limitações dos sistemas baseados em filtragem colaborativa

Abordagens que utilizam a filtragem colaborativa conseguem suprir algumas limitações dos sistemas baseados em conteúdo. Como os sistemas colaborativos utilizam perfis de vários usuários, eles podem recomendar qualquer tipo de conteúdo, mesmo os que não possuem relação com os conteúdos já consumidos. No entanto, técnicas de filtragem colaborativa possuem suas próprias limitações, também abordadas na literatura (Lee, 2001; Burke, 2002; Adomavicius; Tuzhilin, 2005), que são descritas a seguir.

- Problema de esparcidade de avaliações: Para sistemas de filtragem colaborativa, o número de avaliações disponíveis obtidas dos usuários é pequeno se comparado com o número necessário para prover recomendações confiáveis. Um problema crítico desses sistemas é a maneira de estimar novas avaliações a partir de um número pequeno de avaliações existentes. Na prática, sistemas comerciais, como *Amazon.com* devem avaliar grandes conjuntos de dados onde os usuários podem ter avaliado menos de 1% dos itens existentes (Sarwar et al., 2001).

A eficiência dos sistemas baseados em filtragem colaborativa depende da disponibilidade de uma grande quantidade de avaliações de usuários. Quando o número de avaliações é esparso, ou seja, quando poucos usuários avaliaram o mesmo item, os sistemas apresentam dificuldades de realizar a recomendação. Pode ser que existam vários itens avaliados por poucos usuários, assim, esses itens seriam recomendados raramente, mesmo que as avaliações obtidas sejam altas. Além disso, se o conjunto de itens sofre alterações constantes, as avaliações mais antigas serão de pouco valor para os novos usuários, que não terão suas avaliações comparadas com as dos usuários existentes. Se o conjunto de itens é grande e os interesses dos usuários esparsos, então a probabilidade de correlação entre usuários é pequena.

---

<sup>1</sup><http://www.amazon.com>

- *Cold-start* - Problema do novo usuário: Os sistemas que adotam técnicas de filtragem colaborativa determinam as preferências dos usuários baseando-se nos itens consumidos por ele. Quando um novo usuário é adicionado ao sistema, ele não possui nenhum consumo, portanto recomendações apropriadas não podem ser realizadas. Devido ao fato das recomendações serem baseadas na comparação entre o usuário alvo e outros usuários, pode-se tornar difícil definir seus interesses, uma vez que o número de avaliações do usuário alvo é pequeno ou inexistente.
- *Cold-start* - Problema do novo item: Este é um problema parecido com o problema do novo usuário. Sistemas de filtragem colaborativa só dependem das preferências dos usuários para fazer recomendações, e não fazem uso das informações dos itens existentes. Portanto, até que um novo item receba avaliações de um número suficiente de usuários, o sistema de recomendação não será capaz de recomendá-lo. Assim, um novo item que ainda não tenha recebido muitas avaliações não será facilmente recomendado. Este problema ocorre quando o número de itens que são adicionados ao sistema é muito grande, uma vez que poucos usuários conseguem avaliar os itens inseridos.
- Problema da ovelha negra: Ocorre com o usuário que possui interesses diferentes se comparado com o restante dos usuários, pois não existem outros usuários com interesses similares, gerando uma recomendação pobre. Sistemas de recomendação colaborativos trabalham melhor para usuários que possam ser agrupados com outros usuários de interesses semelhantes. Entretanto, essa técnica não trabalha muito bem com o usuário “ovelha negra”.

### 4.3 Sistemas de recomendação híbridos

Sistemas de recomendação híbridos são sistemas que combinam técnicas de filtragem baseadas em conteúdo e filtragem colaborativa em uma única ferramenta, buscando evitar os problemas decorrentes de cada abordagem. Sendo assim, os sistemas de recomendação híbridos são desenvolvidos considerando o histórico do usuário e a relação do seu consumo com o de outros usuários.

Diversas técnicas para se trabalhar com sistemas de recomendação híbridos podem ser utilizadas (Burke, 2002; Adomavicius; Tuzhilin, 2005), sendo a técnica descrita por Pazzani (1999) a mais comum. Esta técnica cria perfis de usuários baseados em conteúdos para em seguida detectar similaridades entre os perfis de usuários.

De acordo com Burke (2002), os métodos de recomendação híbridos podem ser classificados como:

- **Sistemas baseados em pesos:** Esses sistemas recomendam itens com pesos individuais, que são computados através da combinação dos resultados obtidos com as técnicas de recomendação baseadas em conteúdo. Esses resultados, geralmente são agrupados por combinações lineares ou esquemas de votos em grupo. A vantagem desse sistema é a recomendação de itens que não tem como base os conteúdos consumidos originalmente. No entanto, o sistema pressupõe que o valor relativo das diferentes técnicas utilizadas seja mais ou menos uniforme em todo conjunto de itens, o que muitas vezes não é verdade.
- **Sistemas baseados em trocas:** Esses sistemas utilizam algum critério para alternar entre as técnicas de recomendação. O benefício desses sistemas é que as recomendações podem ser sensíveis aos pontos fortes e fracos que compõem as técnicas de recomendação. Entretanto, esse método adiciona uma complexidade no processo de recomendação, uma vez que o critério de troca deve ser determinado através de um nível de parametrização.
- **Sistemas híbridos mistos:** Esses sistemas apresentam as recomendações geradas por diferentes técnicas de recomendação agrupadas, como por exemplo através de uma lista com os itens gerados por técnicas diferentes. A vantagem desses métodos é que eles exploram os benefícios das técnicas de recomendação baseadas em conteúdo e baseadas em filtragem colaborativa. Esses métodos exigem uma classificação dos itens, ou a seleção da melhor recomendação, portanto, é necessária a utilização de alguma técnica de priorização de itens.
- **Sistemas híbridos baseados na combinação de características:** Esses sistemas mesclam as recomendações baseadas em conteúdo e as baseadas em filtragem colaborativa tratando as informações do sistema de filtragem colaborativa simplesmente como recursos adicionais associados a cada item, e utilizando a recomendação baseada em conteúdo sobre o conjunto de dados aumentado. Um benefício desse método é que ele utiliza os dados da recomendação colaborativa sem depender exclusivamente dela, reduzindo a sensibilidade das recomendações para o número de avaliações.
- **Sistemas cascadeados:** Estes sistemas trabalham com um processo sequencial de fases, no qual o primeiro sistema de recomendação gera um conjunto “grosseiro”

de itens. Em seguida, o segundo sistema de recomendação é iniciado com a lista previamente gerada como sendo o conjunto de itens que podem ser recomendados, e gera uma lista refinada com os itens que serão recomendados. A vantagem dessa técnica é que ela evita utilizar o segundo sistema em itens que são muito diferentes ou que são mal avaliados e podem nunca ser recomendados. Fazendo isso, esses sistemas de recomendação são mais eficientes computacionalmente do que, por exemplo, os sistemas baseado em itens, que tratam de todos os itens.

- Sistemas de recomendação de meta-nível: Esses sistemas combinam duas técnicas de recomendação usando o modelo inteiro gerado por um, não somente a saída, como entrada para o outro. A vantagem desses modelos, especialmente para a abordagem colaborativa baseada em conteúdo, é que os resultados do modelo baseado em conteúdo são uma representação compacta dos interesses do usuário, e a segunda etapa da recomendação (filtragem colaborativa) pode trabalhar com maior facilidade sobre esse conjunto de informações compactadas do que com os dados brutos iniciais.
- Sistemas de recomendação baseados no aumento dos recursos: Esses sistemas, de forma semelhante aos sistemas em cascata, utilizam um processo de fases. A primeira técnica de recomendação produz uma classificação ou avaliação de cada item. Em seguida, o segundo sistema de recomendação explora as informações obtidas para enriquecer as entradas do seu processo de recomendação. É importante notar que essa abordagem é diferente do sistema em cascata, pois nos sistemas em cascata as saídas do primeira técnica de recomendação não influenciam a segunda. A vantagem desses métodos é que eles fornecem um modo de melhorar o desempenho das técnicas de recomendação principais, enriquecendo as entradas sem alterar o modelo interno.

Um exemplo desse tipo de sistema é o TiVo (Ali; van Stam, 2004), utilizado para realizar a recomendação de conteúdo televisivo. Adota a técnica baseada em item e um módulo Bayesiano de filtragem baseada em conteúdo. Os conteúdos televisivos são representados através de seus gêneros, atores, diretores e palavras-chave. Os interesses dos usuários são definidos de forma explícita, em uma escala que varia de  $[-3,+3]$ . Os perfis dos usuários são enviados para um servidor externo que se encarrega de gerar as recomendações.

## 4.4 Sistemas de recomendação baseados em semântica

Sistemas híbridos solucionam problemas das abordagens baseadas em conteúdo e baseadas em filtragem colaborativa, conforme explicado na Seção 4.3. Porém, realizar filtragem colaborativa é muitas vezes difícil ou até impraticável. Especialmente no ambiente de TVD, soluções híbridas são difíceis de serem implementadas, devido ao grande número de usuários.

Como uma alternativa aos sistemas híbridos, foram criados alguns sistemas baseados em semântica (Naudet et al., 2008; Blanco-Fernández et al., 2008), que exploram técnicas da *Web Semântica* para realizar a recomendação de conteúdo.

Esses sistemas utilizam ontologias para representar os conteúdos disponíveis na programação da TV, de forma que as informações semânticas dos conteúdos possam ser utilizadas. Além das ontologias, também são utilizadas redes semânticas, que relacionam os conteúdos através de suas informações. Por fim, um processamento semântico é realizado sobre a rede gerada, a fim de descobrir os conteúdos que podem ser recomendados.

Os trabalhos de Naudet et al. (2008) e Blanco-Fernández et al. (2008) motivaram o desenvolvimento de um sistema de recomendação com abordagem semântica para o SBTVD, o SeReS. Este sistema utiliza técnicas semânticas para realizar recomendações aos usuários do SBTVD, conforme é descrito no Capítulo 5.

Abordagens que utilizam processamento semântico conseguem suprir limitações apresentadas pelos sistemas baseados em conteúdo e baseados em filtragem colaborativa, devido às técnicas empregadas para realizar recomendações. A seguir são apresentadas algumas características dessas abordagens que permitem solucionar, ao menos em parte, as limitações das abordagens tradicionais.

Para suprir a limitação de poucas informações disponíveis dos conteúdos, que gera uma análise restrita, informações semânticas são inseridas na representação de cada conteúdo disponível, o que permite uma análise mais profunda desses conteúdos. Estas informações também são utilizadas para encontrar vínculos entre conteúdos, permitindo que a recomendação realizada seja composta de tipos variados de conteúdo, evitando, assim, a superespecialização.

O problema de se recomendar conteúdos sempre do mesmo tipo é evitado com o processamento semântico, pois através das informações de cada conteúdo é possível encontrar similaridades entre programas diferentes, o que evita a recomendação de um mesmo tipo

de conteúdo já consumido pelo usuário.

Para solucionar o problema do novo usuário (*cold-start*), os sistemas baseados em semântica consideram as informações disponíveis nos conteúdos consumidos por este usuário. Mesmo que ele possua pouco consumo, os conteúdos possuem informações que podem ser relacionadas com outros conteúdos, possibilitando uma recomendação que seja de interesse do usuário.

Quando um novo conteúdo é adicionado ao sistema, ele não possui nenhum consumo, porém possui informações que o relacionam com outros conteúdos, dessa forma, ele pode ser recomendado, mesmo sendo um conteúdo novo.

Um usuário que possui interesses diferentes e/ou exóticos é classificado como “ovelha negra” nos sistemas de recomendação tradicionais e pode não ter uma recomendação muito satisfatória, devido a pouca semelhança com outros usuários. Os sistemas que utilizam processamento semântico conseguem recomendar conteúdos para este usuário, mesmo ele possuindo interesses diferentes, pois utilizam diversas informações sobre o conteúdo para realizar buscas, o que faz com que relações entre os conteúdos disponíveis sejam encontradas.

Observa-se, portanto, que a utilização de técnicas semânticas conseguem suprir várias limitações dos sistemas tradicionais, permitindo que as recomendações sejam realizadas de forma a surpreender o usuário. Por este motivo, esta abordagem foi escolhida para ser utilizada no desenvolvimento do SeReS.

## 4.5 Considerações finais

Os sistemas de recomendação são ferramentas importantes para a descoberta de conhecimento em ambientes nos quais o perfil do usuário é levado em consideração. É possível utilizar esses sistemas para realizar a recomendação de conteúdo para os mais variados tipos de usuários.

Os sistemas baseados em conteúdo levam em consideração o que o usuário consumiu, ou seja, realiza a recomendação baseando-se no seu histórico de consumo. Já a abordagem de filtragem colaborativa leva em consideração o consumo de vários usuários e cria grupos para que usuários com interesses semelhantes recebam recomendações indicadas por outros usuários.

Visando um melhor aproveitamento das duas abordagens foram criados os sistemas



híbridos, nos quais são utilizadas técnicas mescladas dos dois sistemas, buscando, assim, suprir as deficiências dos dois tipos de sistemas de recomendação. Porém, em ambientes de TVD a utilização da filtragem colaborativa é difícil, muitas vezes até impraticável.

Buscando otimizar as recomendações em ambientes de TVD, sistemas baseados em semântica são utilizados, melhorando as recomendações e obtendo resultados próximos aos gerados pelos sistemas baseados em filtragem colaborativa. Os sistemas baseados em semântica utilizam técnicas semânticas, como ontologias, redes semânticas e ativação semântica para melhorar o processo de recomendação. Além disso, esse tipo de sistema consegue suprir algumas limitações dos sistemas tradicionais, pois utilizam informações mais completas e detalhadas dos conteúdos.

O SeReS, sistema proposto nesta dissertação, utiliza uma abordagem baseada em processamento semântico. Os resultados apresentados nos Capítulos 5 e 6 demonstram a efetividade dessa abordagem na recomendação de conteúdo para a TVD.

## 5 Recomendação de conteúdo baseada em processamento semântico

Os sistemas de recomendação de conteúdo desenvolvidos para o SBTVD (Alves, 2008; Ávila; Zorzo, 2009; Lucas; Zorzo, 2009), por serem baseados em conteúdo, fornecem recomendações pouco efetivas, uma vez que levam em consideração apenas atributos sintáticos comuns entre os programas televisivos. Por outro lado, as recomendações baseadas em filtragem colaborativa, apesar de serem efetivas para produzir o efeito “surpresa” na recomendação, também apresentam limitações relacionadas à escalabilidade e privacidade, conforme discutido na Seção 5.5.

O trabalho proposto nesta dissertação busca produzir resultados próximos aqueles obtidos pelos sistemas baseados em filtragem colaborativa, sem, no entanto, ter que lidar com os problemas trazidos por este tipo de abordagem. Para tanto, utiliza conceitos da área de *Web Semântica* visando construir um sistema de recomendação baseado em processamento semântico, denominado SeReS: *Semantic-based Recommender System*.

Para construir o SeReS, o primeiro passo foi definir uma ontologia de domínio capaz de representar o domínio dos programas do SBTVD. Tomando como base os conteúdos consumidos pelo usuário e os programas disponíveis na grade de programação, o SeReS produz, para cada usuário, uma rede semântica. Nesta rede, os nós são compostos pelos programas da grade semanticamente expandidos com conteúdo obtido a partir de *Websites* que disponibilizam informação sobre filmes, séries e demais programas televisivos, tais como o IMDB e o TheTVDB.com. Utilizando técnicas de ativação semântica (*Semantic Spreading*) (Collins; Loftus, 1975; Preece, 1981), o SeReS é capaz de descobrir programas semanticamente relacionados com outros que o usuário consumiu no passado. O resultado desse processamento é a geração de um perfil de usuário, contendo informações que podem ser diretamente utilizadas para realizar recomendação. Este perfil, expresso na linguagem XML, pode também ser usado por outras aplicações. Neste Capítulo, é descrito um sistema externo capaz de realizar filtragem colaborativa com base no perfil produzido,

mostrando que é possível tornar o SeReS um sistema de recomendação híbrido.

Este Capítulo encontra-se organizado da seguinte maneira: a Seção 5.1 aborda o processo de desenvolvimento da ontologia criada a fim de modelar a programação disponível no SBTVD. A Seção 5.2 apresenta a rede semântica criada a partir da ontologia definida. Na Seção 5.3 é apresentado como o perfil do usuário é gerado, o processamento desse perfil permite fornecer recomendações instantâneas ao usuário. A Seção 5.4 descreve o processo de ativação semântica. A Seção 5.5 discute uma possível extensão do SeReS a fim de torná-lo um sistema híbrido. Para tanto, propõe um servidor externo capaz de receber os perfis, processá-los utilizando uma abordagem de filtragem colaborativa e retornar as recomendações a cada usuário. A Seção 5.6 apresenta trabalhos relacionados, discutindo as diferenças e semelhanças do SeReS com outros sistemas de recomendação. Finalmente a Seção 5.7 traz as considerações finais do Capítulo.

## 5.1 Ontologia proposta

Com o intuito de modelar os conteúdos disponíveis nas grades de programação das emissoras, foi desenvolvida uma ontologia para mapear os conteúdos e, assim, possibilitar a recomendação de conteúdo utilizando instâncias dessa ontologia.

A ontologia foi criada através do software Protégé utilizando-se a linguagem de representação OWL-DL, e é composta por um conjunto de classes, atributos e relacionamentos. A escolha da linguagem OWL se deu devido ao fato desta linguagem permitir o processamento de informações na ontologia, e também por permitir que se realize inferências nas instâncias. Um exemplo dessa funcionalidade é a determinação de atores e diretores. Todos os integrantes de conteúdos (atores, diretores ou apresentadores) são representados por uma instância da classe *Person*. Através de uma hierarquia de classes é determinado se essa pessoa é um ator, um diretor ou um apresentador. Como existem casos de pessoas que possuem mais de um papel na ontologia, a inferência permite que se classifique essa pessoa através dessa hierarquia. A hierarquia define as seguintes assertivas:

Um *Actor* é uma *Person* e atua em algum conteúdo.

Um *Director* é uma *Person* e dirige algum conteúdo.

Um *Presenter* é uma *Person* e apresenta algum conteúdo.

Essas assertivas, na ontologia, são definidas através de descritores lógicos, conforme exemplo a seguir.

$$cnt : Person(?x) \wedge cnt : hasActors(?y, ?x) \rightarrow cnt : actInContent(?x, ?y)$$

Essa regra define que se  $?x$  é uma  $cnt:Person$  e  $?y$  possui ( $cnt:hasActors()$ ) o ator  $?x$ , então  $?x$  atua ( $cnt:actInContent()$ ) em  $?y$ . Esses tipos de regras permitem que se determine o papel de um conceito na ontologia.

Para a construção da ontologia foram seguidos os passos recomendados pelo método 101 (Noy; McGuinness, 2001), descrito na Seção 3.1.2. A seguir, são apresentadas as etapas realizadas e o que foi gerado em cada uma delas.

- Definição do domínio e escopo: Como o trabalho é utilizado no SBTVD, foi definido o domínio da TVD, focando o escopo nos conteúdos, uma vez que o sistema de recomendação trabalha com os programas disponíveis.
- Reutilização de ontologias: Foram estudadas algumas ontologias existentes para o ambiente de TVD (Naudet et al., 2008; Blanco-Fernández et al., 2008), utilizadas como base para a criação da ontologia proposta, mas nenhuma foi reutilizada na íntegra.
- Enumeração dos itens: Nesta fase foram relacionados todos os termos considerados importantes para a ontologia, incluindo os tipos de conteúdos e os gêneros existentes.
- Definição de classes e hierarquia: Após a definição dos termos foram definidas as classes da ontologia seguindo a abordagem *top-down*, na qual as classes mais genéricas foram definidas primeiro para em seguida se definir as subclasses.
- Definição de propriedades das classes: A definição das propriedades foi realizada levando em consideração a norma NBR 15603-2 (ABNT, 2008a), que define quais informações devem ser enviadas durante a transmissão.
- Valores das propriedades: Após as definições das propriedades, foi realizada a definição dos valores de cada uma delas, considerando restrições, valores possíveis, tipos de valores e cardinalidade das propriedades.
- Criação de instâncias: O último passo foi a criação de instâncias para validar o modelo e realizar os testes da ontologia.

As classes criadas dizem respeito aos tipos de conteúdos existentes, aos gêneros a que cada conteúdo pode pertencer e aos principais componentes de cada conteúdo (atores, diretores e assunto). A Figura 5.1 apresenta o conjunto de classes da ontologia representada pelo software Protégé.

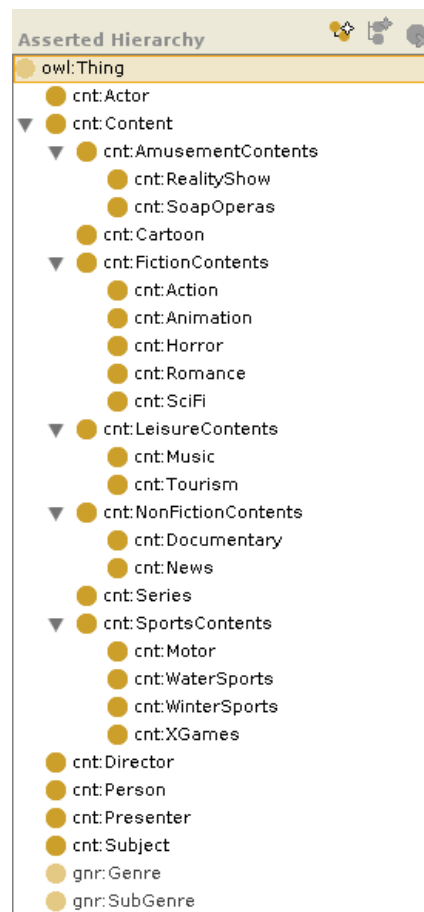


Figura 5.1: Conjunto de classes da ontologia

Essa representação mostra a hierarquia das classes existentes na ontologia. Diversos tipos de conteúdos estão disponíveis na grade de programação da TV, para uma melhor representação desses conteúdos foi utilizada esta hierarquia. Através desta separação de conteúdos é possível ao sistema descobrir informações a respeito de um conteúdo, por exemplo, o conteúdo “*CNN World Report*” é classificado como sendo da classe “*cnt:News*”, o que permite ao sistema determinar que este conteúdo é do tipo “*cnt:NonFictionContents*”. Essas classificações auxiliam no processo de recomendação, pois podem agrupar conteúdos que pertencem à mesma classe.

Para facilitar a localização e o modo de referenciar as classes no arquivo OWL, é possível a utilização de prefixos, por exemplo, *cnt* e *gnr*, apresentados na Figura 5.1. Os prefixos utilizados correspondem à URI (*Uniform Resource Identifier*) da ontologia, que permitem o seu compartilhamento. A Figura 5.2 apresenta os prefixos utilizados pela ontologia desenvolvida nesta dissertação. Cada URI corresponde a um conjunto de classes que pode ser utilizado para se trabalhar com a ontologia.

Alguns prefixos são padronizados nos arquivos OWL, como *owl* (linha 6), *rdf* (linha

3) e *rdf-s* (linha 13), que representam os recursos disponíveis das linguagens OWL, RDF e RDF-*Schema*. O Protégé insere um prefixo próprio: *protege* (linha 4), e a ontologia desenvolvida também possui seu próprio prefixo, no caso: *cnt* (linha 8). Ontologias externas que são utilizadas em conjunto com a ontologia desenvolvida devem ser importadas, como é o caso das ontologias *genre* (linha 17) e *category* (linha 18), que representam, respectivamente, os gêneros e subgêneros, e a categoria de cada conteúdo.

```

1 <?xml version="1.0"?>
2 <rdf:RDF
3   xmlns:rdf="http://www.w3.org/1999/02/22-rdf-syntax-ns#"
4   xmlns:protege="http://protege.stanford.edu/plugins/owl/protege#"
5   xmlns:xsp="http://www.owl-ontologies.com/2005/08/07/xsp.owl#"
6   xmlns:owl="http://www.w3.org/2002/07/owl#"
7   xmlns:ctg="http://www.owl-ontologies.com/category.owl#"
8   xmlns:cnt="http://www.owl-ontologies.com/content.owl#"
9   xmlns:sqwrl="http://sqwrl.stanford.edu/ontologies/built-ins/3.4/sqwrl.owl#"
10  xmlns:xsd="http://www.w3.org/2001/XMLSchema#"
11  xmlns:swrl="http://www.w3.org/2003/11/swrl#"
12  xmlns:swrlb="http://www.w3.org/2003/11/swrlb#"
13  xmlns:rdfs="http://www.w3.org/2000/01/rdf-schema#"
14  xmlns:swrla="http://swrl.stanford.edu/ontologies/3.3/swrla.owl#"
15  xml:base="http://www.owl-ontologies.com/content.owl">
16 <owl:Ontology rdf:about="">
17   <owl:imports rdf:resource="http://www.owl-ontologies.com/genre.owl"/>
18   <owl:imports rdf:resource="http://www.owl-ontologies.com/category.owl"/>
19   <owl:imports rdf:resource="http://swrl.stanford.edu/ontologies/3.3/swrla.owl"/>
20   <owl:imports rdf:resource="http://sqwrl.stanford.edu/ontologies/built-ins/3.4/sqwrl.owl"/>
21 </owl:Ontology>

```

Figura 5.2: Prefixos das ontologias

As classes desenvolvidas e o significado de cada uma delas na ontologia são apresentados na Tabela 5.1. É importante ressaltar que somente as classes de nível mais alto são apresentadas, uma vez que o número de classes existentes na ontologia é grande. Todas as classes em negrito representam algum tipo de conteúdo, e são subclasses de *cnt:Content*.

Tabela 5.1: Classes da ontologia e suas descrições

Classe	Descrição
<i>cnt:Content</i>	Descreve todos os conteúdos disponíveis na programação
<b><i>cnt:Cartoon</i></b>	Representa os desenhos animados
<b><i>cnt:AmusementContent</i></b>	Representa os conteúdos que são para divertimento
<b><i>cnt:FictionContent</i></b>	Representa os conteúdos fictícios, como filmes de ação, horror, etc.
<b><i>cnt:NonFictionContent</i></b>	Descreve os programas que não são fictícios como jornais e documentários
<b><i>cnt:LeisureContent</i></b>	Descreve os conteúdos dedicados ao lazer
<b><i>cnt:SportsContent</i></b>	Utilizado para representar todos os conteúdos esportivos
<i>cnt:Subject</i>	Assuntos aos quais os conteúdos pertencem
<i>cnt:Person</i>	Qualquer pessoa envolvida com um conteúdo (ator, diretor, apresentador)
<i>cnt:Actor</i>	Instância de <i>Person</i> que atua em algum conteúdo
<i>cnt:Director</i>	Instância de <i>Person</i> que dirige algum conteúdo
<i>cnt:Presenter</i>	Instância de <i>Person</i> que apresenta algum conteúdo
<i>gnr:Genre</i>	Define o gênero do conteúdo, baseado na NBR 15603-2 (ABNT, 2008a)
<i>gnr:SubGenre</i>	Define o subgênero do conteúdo, baseado na NBR 15603-2 (ABNT, 2008a)

As classes *gnr:Genre* e *gnr:SubGenre* foram definidas seguindo a norma brasileira NBR 15603-2 (ABNT, 2008a), e são utilizadas para classificar os conteúdos. As classes *cnt:Actor*, *cnt:Director* e *cnt:Presenter* são utilizadas para representar as pessoas que trabalham em algum conteúdo. Todas as instâncias dessas classes também são instâncias da classe *cnt:Person*.

A definição de todas as classes e dos atributos de cada uma delas foi baseada na norma brasileira NBR 15603-2 (ABNT, 2008a), que define os metadados que devem ser enviados pela emissora, e em trabalhos (Naudet et al., 2008; Blanco-Fernández et al., 2008) que também utilizam ontologias para o tratamento de conteúdos para TVD. A principal idéia dessa ontologia é representar cada conteúdo com o máximo de informações para que seja possível realizar uma recomendação mais precisa para o telespectador.

Cada uma das classes foi modelada de forma a permitir que as informações coletadas das bases disponíveis na Internet fossem aproveitadas ao máximo, o que permite uma melhor representação do conteúdo. A Figura 5.3 mostra o conteúdo “*Batman Returns*” com suas informações. O gênero e subgênero foram atribuídos de acordo com a especificação NBR 15603-2 (ABNT, 2008a), as outras informações foram coletadas das bases na Internet.

Figura 5.3: Conteúdo *Batman Returns* e suas informações coletadas

Cada conteúdo existente é representado por uma instância da ontologia, que contém todas as características do conteúdo, conforme visto na Figura 5.3, fazendo com que seja possível utilizar essas informações para realizar a recomendação. Além disso, o sistema

é capaz de realizar relacionamentos entre as instâncias, fazendo com que seja possível encontrar semelhanças entre os conteúdos. As informações de cada instância são utilizadas pelo SeReS para criar a rede semântica e relacionar conteúdos. Este processo é descrito na Seção 5.2.

As instâncias criadas se referem aos conteúdos transmitidos e aos conteúdos que estão disponíveis na grade de programação da TV. As informações sobre esta grade são enviadas pela emissora juntamente com o conteúdo transmitido, e devem informar a programação dos próximos 8 dias (ABNT, 2008a), assim o STB possui acesso a essas informações, tornando os dados disponíveis para aplicações que estão sendo executadas sobre o *middleware*. A geração de novas instâncias ocorre uma vez por semana (sexta-feira), ou seja, os conteúdos que são utilizados no processo de recomendação são os que serão transmitidos na semana seguinte.

Para exemplificar o uso da ontologia, a Figura 5.4 apresenta algumas classes e algumas instâncias que representam conteúdos transmitidos pela emissora. É importante notar que os conteúdos pertencem a classes diferentes, o que permite uma melhor organização e uma melhor filtragem com relação aos conteúdos. Esta separação é importante para realizar a recomendação e para se trabalhar com a rede semântica.

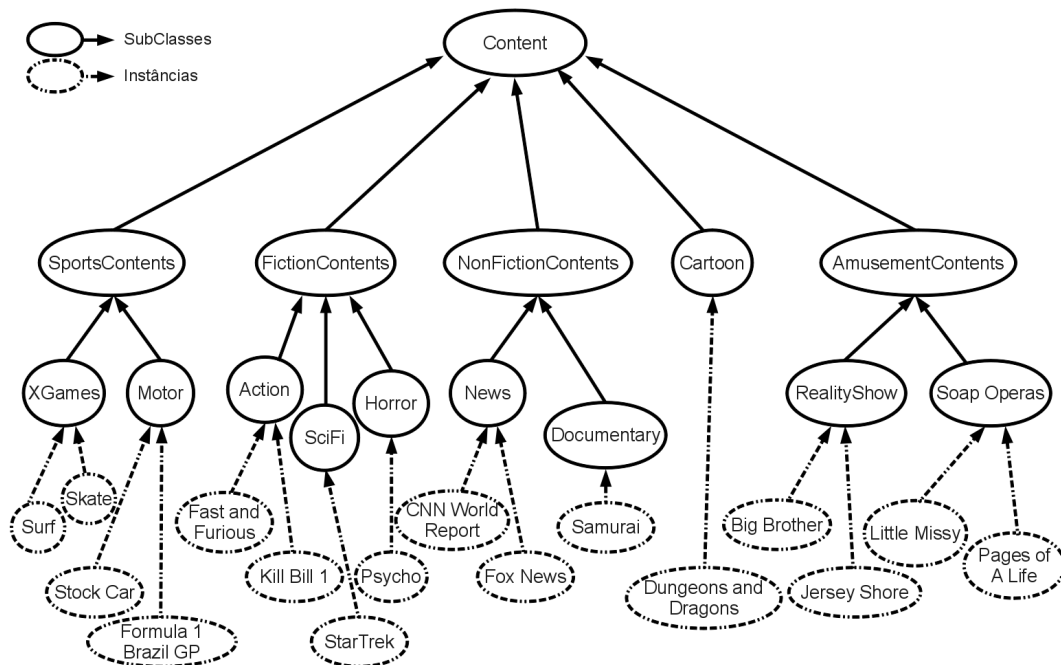


Figura 5.4: Parte da ontologia com instâncias criadas (Silva; Baldochi, 2010)



## 5.2 Construção da rede semântica

A rede semântica é construída com base na programação da TV, e contém as instâncias de conteúdos que estão disponíveis para consumo. Essa rede é gerada uma vez por semana (sexta-feira), logo após a criação das instâncias dos conteúdos. Dessa forma, toda semana a rede gerada para um usuário será diferente.

Os conteúdos que compõem a rede são os disponíveis na programação da TV e são baseados no consumo do usuário. A partir deste consumo, o processo de ativação semântica será realizado, possibilitando assim inferir algumas preferências do telespectador. Para exemplificar uma rede semântica criada, a Figura 5.5 apresenta instâncias e relacionamentos entre elas. Todos as instâncias na rede são baseadas na ontologia desenvolvida.

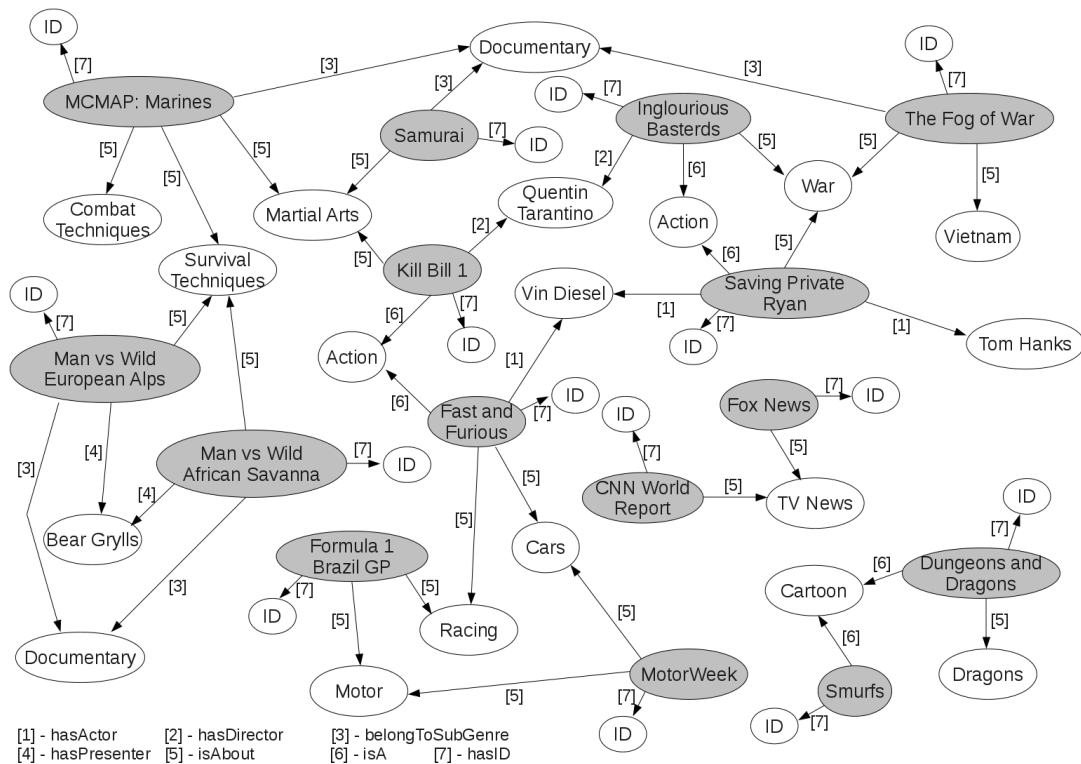


Figura 5.5: Parte da rede semântica utilizada (Silva; Baldochi, 2010)

Os conteúdos possuem diversos atributos como assunto (*isAbout*), tipo de conteúdo (*isA*), atores (*hasActor*) e outros. Esses atributos são ativados quando o processo de ativação semântica é iniciado. Esse processo considera os conteúdos consumidos pelo usuário, sendo que cada conteúdo consumido ativa vários outros itens que integram a rede e possuem relação com o item consumido, permitindo assim que interesses do usuário possam ser inferidos.

No início do processo, cada conteúdo consumido possui um valor de ativação de acordo

com o tempo de consumo do usuário. Após a atribuição do valor inicial ao conteúdo, o processo de ativação de outros itens ocorre. Eles recebem um valor baseado no valor de ativação do item que os ativou somado ao peso do relacionamento. Por exemplo, quando um usuário assiste o filme “*Kill Bill - Volume 1*”, o valor inicial de ativação para este conteúdo é 1.0, em seguida, este filme vai ativar outros itens, como o diretor “*Quentin Tarantino*”, a atriz “*Uma Thurman*”, o ator “*David Carradine*”, o assunto “*Martial Arts*”, entre outros. Esses itens ativados irão ativar outros itens que são relacionados, por exemplo, o filme “*Inglourious Basterds*”, que possui relação com o diretor ativado anteriormente, e o documentário “*Samurai: Behind the blade*”, que possui relação com o assunto “*Martial Arts*”. A partir das ativações e dos valores de ativação encontrados, os conteúdos que possuírem os maiores valores serão recomendados para o usuário.

Cada item que pode ser recomendado possui relações com os itens já ativados, sendo assim, cada um deles receberá um valor de ativação que representará o quão próximo do interesse do usuário o conteúdo se encontra. A forma de se determinar o interesse do usuário por um conteúdo é apresentada na seção 5.3.

Cada item ativado tem influência do elemento que o ativou em seu valor de ativação, portanto, um item pode ser mais valorizado do que outro, uma vez que ele pode receber ativações de diversos outros itens. Por exemplo, um diretor que trabalhou em dois filmes consumidos por um usuário terá influência desses dois filmes em seu valor de ativação, o que representa um interesse maior por esse diretor. A Figura 5.6 exemplifica como um item recebe influência de outros itens.




Figura 5.6: Incidência de valores de ativação sobre um item (Silva; Baldochi, 2010)

Observando a Figura 5.6 nota-se que vários itens ( $P_1, P_2, P_3, P_4, P_n$ ) podem influenciar o valor de ativação de um único item ( $I$ ). Dessa forma, o valor de ativação do item  $I$  será alterado para um valor maior, indicando um possível maior interesse do usuário por

esse item. O cálculo do valor de ativação de cada item é representado pela Equação 5.1 (Hussein; Ziegler, 2008).

$$P_j(t+1) = P_j(t) + O_i * w_{ij} * a \quad (5.1)$$

na qual  $P_j(t)$  é o valor de ativação que o item  $j$  possui no instante  $t$ . Caso seja a primeira vez que o item é ativado, esse valor é zero.  $O_i$  corresponde ao valor de ativação do item  $i$  que ativou  $j$ ,  $w_{ij}$  é o peso do relacionamento entre  $i$  e  $j$  e  $a$  é um fator de atenuação que pode variar de 1% a 50%. Generalizando a Equação 5.1, obtém-se a seguinte Equação

$$P_I = \sum_{j=0}^n P_I(j) + O_j * w_{jI} * a \quad (5.2)$$

na qual  $P_I$  é o valor de ativação do item  $I$ ,  $P_I(j)$  é o valor de ativação atual do item,  $O_j$  é o valor de ativação do item que ativou  $I$ ,  $w_{jI}$  é o peso do relacionamento entre o elemento  $j$  e o item  $I$  e  $n$  é o número de elementos que estão ligados ao item  $I$ .

Os pesos dos relacionamentos foram obtidos de forma empírica, baseados em resultados da literatura (Roth, 1999; Hussein; Ziegler, 2008; Hussein; Neuhaus, 2010) e em um estudo realizado pelo Datafolha (Datafolha, 2008). Este estudo teve como foco os hábitos de consumo voltados para o mercado de entretenimento. Seus resultados foram valiosos para determinar a relevância dos atributos de um programa de TV, especialmente quando os filmes são considerados. Baseado nessas informações, os pesos dos relacionamentos foram definidos, conforme apresentado na Tabela 5.2. Utilizando os resultados dos estudos de Hussein e Ziegler (2008), adotou-se um fator de atenuação de 5%. Como os itens não tem seus valores de ativação zerados a cada iteração do algoritmo, o fator de atenuação funciona como um mecanismo de envelhecimento, atenuando o valor de ativação dos itens cada vez que eles são ativados.

Tabela 5.2: Pesos utilizados para os relacionamentos

Relacionamento	Peso
<i>hasDirector</i>	0,30
<i>directContent</i>	0,30
<i>isAbout</i>	0,25
<i>belongToGenre</i>	0,20
<i>hasPresenter</i>	0,20
<i>presentsContent</i>	0,20
<i>hasActor</i>	0,15
<i>actIn</i>	0,15
<i>belongToSubGenre</i>	0,10

### 5.3 Geração do perfil do usuário

O objetivo do perfil do usuário é determinar suas preferências, para que novos programas, relacionados com o seu consumo, sejam recomendados. Toda programação recebida pelo STB possui informações sobre o programa transmitido e também informações sobre os próximos programas que serão transmitidos (ABNT, 2008a), sendo assim é possível registrar tudo que o usuário está consumindo. Esse processo de registro é responsável por armazenar todas as informações de consumo do usuário em um arquivo de *log*, que é utilizado para gerar seu perfil.

Um dos principais problemas encontrados na geração do perfil do usuário é determinar o seu grau de interesse por um conteúdo. Em geral, os telespectadores não querem avaliar os programas de forma explícita, até mesmo pela dificuldade de interação através do controle remoto. Para solucionar este problema, foi utilizado um método implícito para se calcular o interesse do usuário por um conteúdo, no qual o grau de interesse do usuário ( $I_i$ ) é calculado através da relação entre o tempo de consumo do conteúdo ( $T_c$ ) e o tempo de duração total do conteúdo ( $T_t$ ), conforme ilustra a Equação 5.3.

$$I_i = \frac{T_c}{T_t} \quad (5.3)$$

Para se criar o perfil do usuário, os conteúdos foram adicionados em uma fila de prioridade organizada de forma que os conteúdos com maior índice de interesse estão no início da fila, ou seja, os programas que possuírem os maiores  $I_i$  possuirão maior prioridade do que os outros. Essa abordagem permite um controle mais flexível sobre os conteúdos que serão utilizados no processo de ativação.

Cada perfil gerado está associado ao STB que recebe as informações das emissoras, portanto as preferências encontradas não são associadas a um usuário específico, mas sim ao STB em questão.

Baseado em cada conteúdo consumido, o processo de ativação semântica adiciona ao perfil gerado itens que possuem relação com o consumo, fazendo com que cada perfil tenha uma relação de itens e níveis de ativação que correspondem ao nível de interesse do usuário para cada item.

Os perfis produzidos podem ser utilizados para gerar recomendação instantânea ao usuário, e também podem ser enviados para outras aplicações, como, por exemplo, um servidor de recomendação externo ao STB, para realização da filtragem colaborativa.

Os perfis são armazenados em arquivos XML e contém as seguintes informações: ID do STB; programas consumidos; atores, diretores e apresentadores dos conteúdos consumidos; relação dos assuntos de interesse do usuário e relação de conteúdos recomendados, todos com seus respectivos níveis de ativação. A Figura 5.7 apresenta um exemplo de consumo e recomendação para um usuário  $u$ .

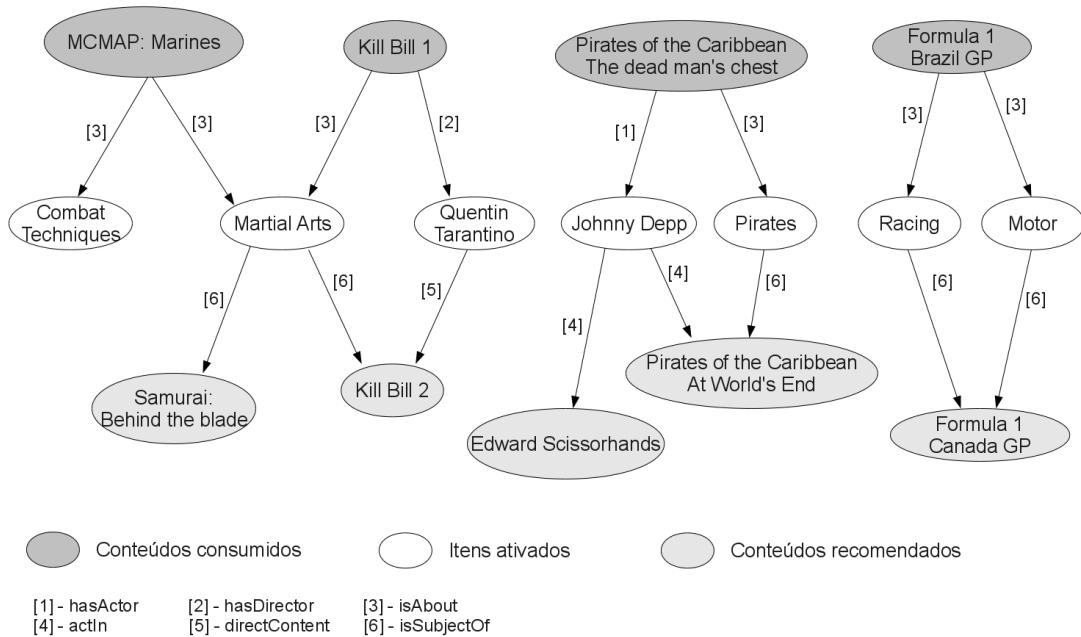


Figura 5.7: Exemplo de consumo e recomendação para o usuário  $u$

Como pode-se observar na Figura 5.7, o usuário  $u$  consumiu quatro conteúdos, *MCMAP: Marines*, *Kill Bill - Volume 1*, *Pirates of the Caribbean - The dead man's chest* e *Formula 1 - Brazil GP*. Esses conteúdos fazem parte do perfil de  $u$ , como pode ser observado nas linhas 4, 6, 9 e 12 da Figura 5.8. Esta Figura apresenta o arquivo XML correspondente ao perfil de  $u$ .

A partir dos conteúdos consumidos, alguns itens foram ativados, conforme apresentado na Figura 5.7. Tais itens correspondem a atores, diretores e assuntos, e fazem parte do perfil de  $u$ . Esses itens estão representados nas linhas 16 (*Quentin Tarantino*), 34 (*Johnny Depp*), 38 (*Martial Arts*), 40 (*Combat Techniques*), 42 (*Motor*), 44 (*Racing*) e 48 (*Pirates*) da Figura 5.8, que ilustra o perfil do usuário  $u$  como um arquivo XML.

O processo de ativação continua percorrendo a rede, até atingir os conteúdos recomendados, que são representados pelas linhas 52 (*Kill Bill - Volume 2*), 55 (*Pirates of the Caribbean - At world's end*), 58 (*Formula 1 - Canada GP*), 64 (*Samurai: Behind the blade*) e 72 (*Edward Scissorhands*) do perfil do usuário.

Esse exemplo apresenta apenas uma parte dos itens ativados para o usuário, sendo que

outros itens são ativados, e outros conteúdos são recomendados, como pode-se observar na Figura 5.8.

```

1 <Profile>
2   <STB_ID>837768919</STB_ID>
3   <Content_Consumed>
4     <title>MCMAP: Marines</title>
5     <activation_level>1.0</activation_level>
6     <title>Kill Bill - Volume 1</title>
7     <activation_level>0.8</activation_level>
8     <title>
9       Pirates of the Caribbean - The dead Man's Chest
10    </title>
11    <activation_level>0.3</activation_level>
12    <title>Fórmula 1 - Brazil GP</title>
13    <activation_level>0.4</activation_level>
14  </Content_Consumed>
15  <Directors>
16    <name>Quentin Tarantino</name>
17    <activation_level>0.074</activation_level>
18    <name>Gore Verbinski</name>
19    <activation_level>0.059</activation_level>
20  </Directors>
21  <Actors>
22    <name>Lucy Liu</name>
23    <activation_level>0.066</activation_level>
24    <name>David Carradine</name>
25    <activation_level>0.066</activation_level>
26    <name>Uma Thurman</name>
27    <activation_level>0.066</activation_level>
28    <name>Orlando Bloom</name>
29    <activation_level>0.056</activation_level>
30    <name>Tom Hollander</name>
31    <activation_level>0.056</activation_level>
32    <name>Keira Knightley</name>
33    <activation_level>0.056</activation_level>
34    <name>Johnny Depp</name>
35    <activation_level>0.056</activation_level>
36  </Actors>
37  <Subjects>
38    <name>MartialArts</name>
39    <activation_level>0.0824</activation_level>
40    <name>CombatTechniques</name>
41    <activation_level>0.08</activation_level>
42    <name>Motor</name>
43    <activation_level>0.074</activation_level>
44    <name>Racing</name>
45    <activation_level>0.062</activation_level>
46    <name>Cars</name>
47    <activation_level>0.062</activation_level>
48    <name>Pirates</name>
49    <activation_level>0.059</activation_level>
50  </Subjects>
51  <Recommended_Contents>
52    <title>Kill Bill - Volume 2</title>
53    <activation_level>0.0559</activation_level>
54    <title>
55      Pirates of the Caribbean - At World's End
56    </title>
57    <activation_level>0.0539</activation_level>
58    <title>Fórmula 1 - Canada GP</title>
59    <activation_level>0.0534</activation_level>
60    <title>Stock Car</title>
61    <activation_level>0.0534</activation_level>
62    <title>Muay Thai</title>
63    <activation_level>0.053</activation_level>
64    <title>Samurai: behind the blade</title>
65    <activation_level>0.053</activation_level>
66    <title>MotorWeek</title>
67    <activation_level>0.0526</activation_level>
68    <title>Wanted</title>
69    <activation_level>0.0519</activation_level>
70    <title>Charlie and the Chocolate Factory</title>
71    <activation_level>0.0504</activation_level>
72    <title>Edward Scissorhands</title>
73    <activation_level>0.0504</activation_level>
74  </Recommended_Contents>
75 </Profile>

```

Figura 5.8: Arquivo XML com o perfil do usuário  $u$

Como pode ser visto na Figura 5.8, cada item no perfil do usuário possui um nível de ativação, representado no arquivo pela *tag* `<activation_level>`. Esse valor é calculado pela Equação 5.2, levando em consideração todos os itens que possuem relação com o item ativado.

O nível de ativação dos itens consumidos é dado pela Equação 5.3, e representa o interesse do usuário por aquele item. Por exemplo, o usuário  $u$  se mostra muito interessado no documentário *MCMAP: Marines*, pois possui um nível de ativação igual a 1,0, como pode ser visto na linha 5 da Figura 5.8, porém, o mesmo usuário não mostra muito interesse pelo filme *Pirates of the Caribbean - The dead man's chest*, que possui um nível de ativação igual a 0,3, resultado apresentado na linha 11. Esses valores iniciais são responsáveis pelos níveis de ativação dos outros itens, pois é a partir deles que o processo de ativação semântica determina os níveis de interesse do usuário.

## 5.4 Ativação semântica

Na Seção 5.3 foi explicado como o SeReS gera o perfil do usuário e a forma como os itens recebem o nível de ativação a partir do consumo do usuário. Nesta Seção será explicado o algoritmo utilizado para percorrer a rede semântica e ativar os itens de interesse do usuário.

Existem diversos algoritmos para se trabalhar com ativação semântica, conforme descrito em Huang, Chen e Zeng (2004). O algoritmo selecionado para este trabalho foi o *Branch-and-bound* (Huang; Chen; Zeng, 2004; Hussein; Neuhaus, 2010).

Os níveis de ativação dos itens não são zerados a cada iteração do algoritmo, o que permite que um mesmo item seja ativado várias vezes, demonstrando, assim, um maior interesse do usuário por esse item. O algoritmo é dividido em duas fases distintas: a inicialização e a execução.

Inicialização:

Antes da execução do processo de ativação, é necessário inicializar a rede semântica. Este processo pode ser dividido em três fases:

1. Os pesos dos relacionamentos ( $w_{ij}$ ) são atribuídos de acordo com os pesos definidos para o contexto da aplicação. Para o SeReS, os pesos utilizados são apresentados na Tabela 5.2. Cada item na rede ( $I$ ) possui seu nível de ativação igual a zero. Quando um item é ativado, ele tem seu nível alterado.
2. Os itens consumidos pelo usuário são os primeiros itens a serem ativados na rede, e cada um deles recebe o seu nível de ativação de acordo com a Equação 5.3.
3. Os itens ativados são então inseridos em uma fila de prioridade ( $PQ$ ) por ordem decrescente, na qual os itens de maior interesse estão nas primeiras posições da fila.

Após a inicialização, o algoritmo entra em um processo de repetição recursivo, no qual os itens ativados são inseridos na fila de prioridade e a partir deles outros itens são ativados. Esse processo termina quando uma condição de parada é atingida ou até que a fila de prioridade esteja vazia. A condição utilizada pelo SeReS para encerrar o processo é atingir o segundo nível de itens a partir do item ativado inicialmente, conforme exemplificado na Figura 5.9. Os passos a serem realizados na fase de execução são descritos a seguir.

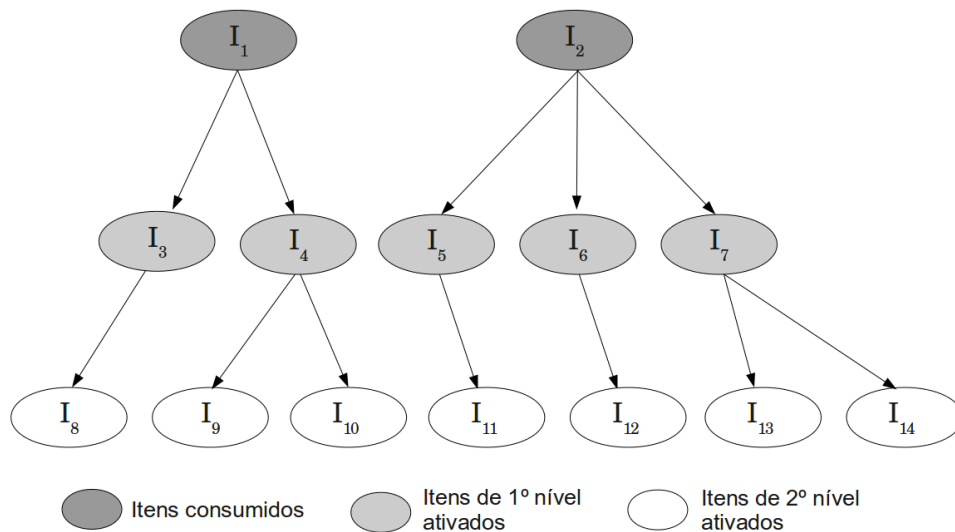


Figura 5.9: Ativação de itens até o 2º nível da rede semântica

1. O primeiro item da fila de prioridade é retirado, ou seja, o item com o maior nível de ativação é o primeiro a ser processado.
2. O nível de ativação deste item é então passado a todos os itens adjacentes a ele, até que o segundo nível da rede seja atingido. Cada item ativado pode ser adjacente de um ou mais itens, o que vai aumentar o seu nível de ativação. O cálculo final do nível de ativação é dado pela Equação 5.2.
3. Os itens ativados são então inseridos na fila de prioridade, com exceção dos itens de segundo nível que estabelecem o final do processo.

Quando todos os itens são retirados da fila de prioridade, o processo do algoritmo é encerrado e todos os itens ativados possuem um nível de ativação que representa o interesse do usuário por eles.

De posse de todos os itens de interesse do usuário, é gerado o arquivo XML com seu perfil. Com o perfil, o SeReS pode realizar a recomendação instantânea ao usuário. Além disso, o perfil pode ser enviado para um servidor externo para que seja realizada a recomendação por filtragem colaborativa.

Um pseudo-código do algoritmo é apresentado na Figura 5.10.



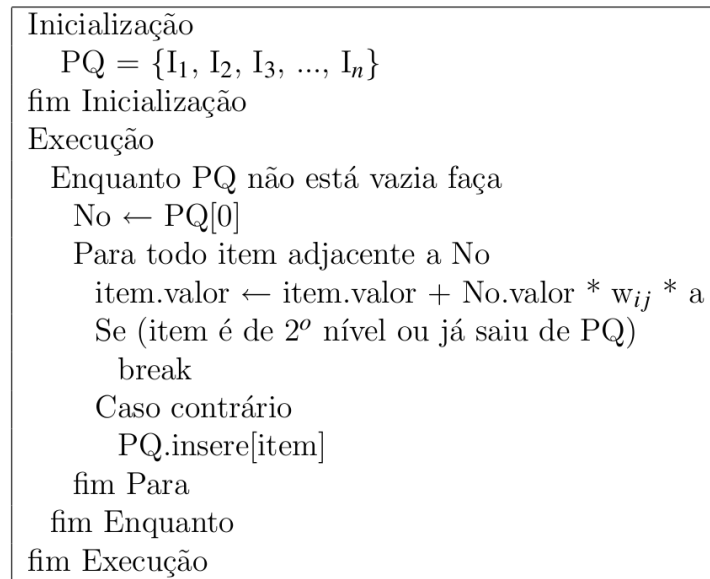


Figura 5.10: Pseudo-código do algoritmo de ativação semântica

## 5.5 Integração de filtragem colaborativa ao SeReS

Durante o desenvolvimento do SeReS, observou-se a possibilidade de integrá-lo a um sistema externo capaz de realizar filtragem colaborativa, transformando o SeReS em um sistema de recomendação híbrido. Esta Seção apresenta uma proposta de integração de um sistema de filtragem colaborativa ao SeReS, o que permite uma recomendação baseada no consumo de outros usuários. A Figura 5.11 apresenta a arquitetura de funcionamento do SeReS trabalhando em conjunto com um servidor externo.

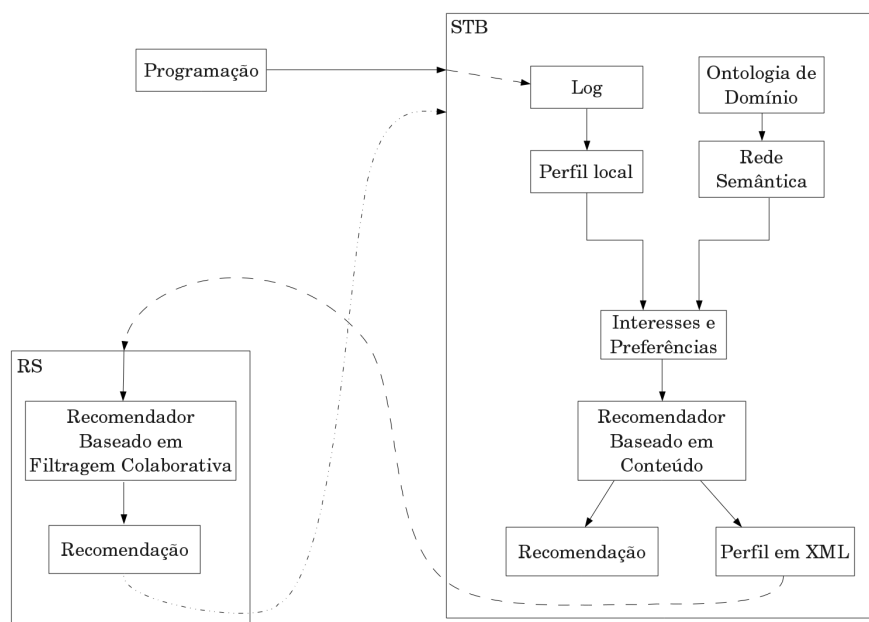


Figura 5.11: Arquitetura do sistema

Pode-se observar na Figura 5.11 que o SeReS pode realizar a recomendação diretamente ao usuário, ou então enviar o arquivo XML para o servidor externo.

Na abordagem híbrida, cada STB envia o arquivo XML correspondente ao perfil do usuário para o servidor externo. Com os perfis em um único servidor, é possível agrupar perfis semelhantes e a partir daí recomendar conteúdos que outros usuários consumiram e gostaram. Como os grupos formados possuem semelhanças, é de se esperar que os interesses e gostos dos membros desses grupos sejam similares também. Por esse motivo é possível realizar a recomendação de um conteúdo consumido por outro usuário, porém com as mesmas características de preferências.

Um estudo de integração foi realizado em um trabalho final de graduação (TFG) (Dias, 2010), e auxilia na proposta de tornar o SeReS um sistema de recomendação híbrido. Para realização deste estudo, foram criados vários perfis de usuários pelo SeReS para que o processo de filtragem colaborativa fosse testado. Os resultados deste estudo são discutidos a seguir.

No servidor externo, os arquivos XML recebidos dos STBs são processados, de forma que informações interessantes para o sistema sejam extraídas. Para realizar este processamento foi desenvolvido um programa utilizando a linguagem Java e a linguagem de consulta XPath<sup>1</sup>. Para armazenamento dos arquivos foi utilizado o banco de dados eXist<sup>2</sup>.

O XPath é uma linguagem que explora a estrutura e o aninhamento dos arquivos XML a fim e permitir a busca de informações nesses arquivos.

Devido a necessidade de se armazenar uma quantidade grande de perfis de usuários, Dias (2010) adotou o banco de dados eXist para essa função, uma ferramenta que permite realizar consultas nos arquivos XML armazenados de forma rápida e simples.

O processo de recomendação é composto por três atividades: agrupamento dos usuários similares; aplicação de um limiar para selecionar os usuários mais similares; e a recomendação dos conteúdos.

Conforme descrito na Seção 4.2, existem algumas técnicas que podem ser utilizadas para agrupar os itens. No trabalho de Dias (2010), a correlação de Pearson foi adotada para agrupar os usuários. Essa medida de similaridade é calculada para cada par de usuários, utilizando os níveis de ativação dos itens comuns aos dois usuários que compõem o par, obtendo como resultado um valor para a intensidade de semelhança entre eles. Os

---

<sup>1</sup><http://www.w3.org/TR/xpath/>

<sup>2</sup><http://exist.sourceforge.net/>

valores de similaridade variam entre zero e um, e quanto mais próximos esses valores estiverem de um, maior a semelhança entre os usuários.

Para realizar o agrupamento são selecionados os usuários que obtiveram as maiores medidas de similaridade, essa seleção é realizada aplicando-se um limiar de 30% no resultado para garantir uma melhor seleção. Com este valor é possível eliminar os usuários que possuem baixa similaridade.

Um dos testes realizados por Dias (2010) foi selecionar um usuário de forma aleatória, no caso o usuário com ID 579265740, como usuário alvo da recomendação. Sua pontuação para os atores é apresentada na Tabela 5.3.

Tabela 5.3: Avaliações do usuário 579265740 para os atores (Dias, 2010)

Ator	Avaliação	Ator	Avaliação
Winona_Ryder	6,53	Sean_Finn	6,4
Tyler_Perry	6,4	Kristina_West	6,4
Brad_William_Henke	6,4	Bryan_Finn	6,4
Anton_Yelchin	6,8	Gabriel_Byrne	6,4
Bruce_Greenwood	6,0	Rebecca_Toolan	6,4
Clifton_Collins_Jr	5,8	Robin_Collins	6,4
Chris_Spinelli	6,4	Lara_Robinson	6,4
Ben_Cross	7,0	Anna_Anderson	6,4
Karl_Urban	6,4	Nicolas_Cage	6,4
Jennifer_Morrison	5,5	Simon_J_Smith	6,2
Zachary_Quinto	7,4	John_Lithgow	6,2
Rachel_Nichols	6,6	Cameron_Diaz	6,2
Leonard_Nimoy	6,4	Chris_Miller	6,2
Eric_Cabana	5,9	Peter_Dennis	6,2
Zoe_Saldana	6,4	Mike_Myers	6,2
John_Chow	6,4	Eddie_Murphy	6,2
Simon_Pegg	6,4	Michael_Chiklis	5,8
Diora_Baird	6,4	Jessica_Alba	5,8
David_Adams	6,4	Ioan_Gruffudd	5,8
Kate_Robbins	6,4	Chris_Evans	5,8
Mary_Wickes	6,4	Richard_Gere	5,0
Marco_Roy	5,9	Ralph_Bellamy	5,0
Susan_Sarandon	6,3	Julia_Roberts	5,0
Sarah_Strange	6,4	Laura_San_Giacomo	5,0
Janie_Woods-Morris	6,5	Jason_Alexander	5,0
Christian_Bale	6,4		

Após a aplicação do coeficiente de Pearson para agrupamento dos usuários, é encontrada a relação de usuários que possuem alguma similaridade com o usuário alvo. Essa medida só considera os usuários que possuem pelo menos dois itens em comum. Como resultado foram selecionados 13 usuários como similares, com o uso do limiar de 30%, somente os 4 primeiros são utilizados. A Tabela 5.4 apresenta a relação de usuários selecionados e os valores dados para cada item similar ao usuário alvo.

Tabela 5.4: Usuários selecionados para formarem o grupo (Dias, 2010)

ID	Item similar	Avaliação
677347267	Lara_Robinson	5,2
	Anna_Anderson	5,2
	Nicolas_Cage	5,2
	Simon_J_Smith	5,0
	John_Lithgow	5,0
	Cameron_Diaz	5,0
	Chris_Miller	5,0
	Peter_Dennis	5,0
	Mike_Myers	5,0
	Eddie_Murphy	5,0
1435994381	Winona_Ryder	7,0
	Nicolas_Cage	5,4
1510596415	Winona_Ryder	5,6
	Jessica_Alba	5,2
665012629	Jennifer_Morrison	5,2
	Jessica_Alba	5,6

A partir dos usuários similares, é possível realizar a recomendação. Para isso foi utilizada uma média ponderada entre os coeficientes de similaridade dos usuários e os valores de avaliação dos itens avaliados por esses usuários e não consumidos pelo usuário alvo. Como resultado foram obtidos 54 atores, porém, aplicando o limiar de 30% somente os 16 primeiros foram selecionados. Os atores selecionados são apresentados na Tabela 5.5.

Tabela 5.5: Atores selecionados para aplicar a recomendação (Dias, 2010)

Atores selecionados	Pontuação final	Atores selecionados	Pontuação final
Tom_Hanks	7,00	Robert_Barton	7,00
Paul_Garcia	7,00	Henry_Thomas	7,00
Edward_Burns	7,00	Tom_Sherry	7,00
Barry_Pepper	7,00	Drew_Barrymore	7,00
Michelle_Pfeiffer	7,00	Person_86	7,00
Michael_Keaton	7,00	Johnny_Depp	6,45
Danny_Devito	7,00	Gillian_Anderson	6,4
Christopher_Walken	7,00	David_Duchovny	6,4
Michael_Gough	7,00	Alan_Fudge	6,3
Vincent_Schiavelli	7,00	Stuart_Lancaster	6,3

A forma de cálculo da pontuação apresentada na Tabela 5.5 é dada pela Equação 5.4, na qual  $S$  é o somatório da pontuação dada por cada usuário selecionado ao item  $i$ , multiplicada pelo seu coeficiente de similaridade e  $SS$  é o somatório de todas as similaridades dos usuários que avaliaram o item  $i$ .

$$\frac{S_i}{SS_i} \quad (5.4)$$

Dias (2010) esclarece que o resultado apresentado na Tabela 5.5 mostra apenas os valores encontrados para os atores, porém é possível encontrar valores para diretores, apresentadores, assuntos e outros de forma similar. Cada um dos itens gera uma lista com os itens e seu valores; esses itens são então comparados com um arquivo disponível da base de dados. Este arquivo contém as informações referentes a cada ator, diretor, apresentador, assunto etc. A Figura 5.12 apresenta um trecho desse arquivo.

```

-<Contents>
  -<Directors>
    -<Director>
      <Director_Name>Quentin_Tarantino</Director_Name>
    -<Works>
      <Title>Kill Bill - Volume 2</Title>
      <Title>Sin City</Title>
      <Title>Inglourious Basterds</Title>
      <Title>Kill Bill - Volume 1</Title>
    </Works>
  </Director>
  -<Director>
    <Director_Name>Tim_Burton</Director_Name>
  -<Works>
    <Title>Charlie and the Chocolate Factory</Title>
    <Title>Edward Scissorhands</Title>
    <Title>Batman Returns</Title>
  </Works>
</Director>
- <Director>
  <Director_Name>Dominic_Sena</Director_Name>
  -<Works>
    <Title>60 Seconds</Title>
  </Works>
</Director>
- <Director>

```

Figura 5.12: Trecho do arquivo com informações sobre os atores, diretores etc. (Dias, 2010)

A partir da lista de atores (Tabela 5.5) é realizado um comparativo com o arquivo XML representado na Figura 5.12 e gerada a relação de conteúdos que podem ser recomendados. Neste exemplo, os conteúdos recomendados são: *Saving Private Ryan*, *Batman Returns*, *Personal Effects*, *What Lies Beneath*, *The Prince of Egypt*, *The Russia House*, *E. T. - The Extra-Terrestrial*, *Charlie's Angels*, *Pirates of the Caribbean - Dead Man's Chest*, *Charlie and the Chocolate Factory*, *Edward Scissorhands*, *Pirates of the Caribbean - At World's End*, *Pirates of the Caribbean - The Curse of the Black Pearl*, *X-Files*.

Após a geração da lista de recomendação pelo servidor externo, é criado um arquivo XML com essa listagem. Esse arquivo é enviado ao STB para que os conteúdos possam ser sugeridos ao usuário. Todo o processo de análise de similaridades e agrupamento dos usuários é realizado semanalmente, evitando assim que valores semelhantes sejam obtidos devido a falta de tempo para modificação dos perfis dos usuários.

O estudo realizado por Dias (2010) mostra que é possível a integração do SeReS a um servidor externo que realiza filtragem colaborativa, fazendo com que o SeReS atue como um sistema híbrido. Porém, é necessário um estudo bem detalhado para a realização deste processo, pois o envio dos perfis para um servidor externo acarreta alguns problemas relacionados à escalabilidade, esparcidade de interesses disponíveis e privacidade dos usuários.

O número de usuários de TV no Brasil é muito grande (IBGE, 2009), gerando assim milhões de perfis de usuário, que serão enviados para o servidor de recomendação. Tratar milhões de perfis a fim de se encontrar similaridades entre eles é um trabalho que exige uma capacidade de processamento muito grande.

O sistema funciona bem para poucos perfis, conforme demonstrado por Dias (2010), mas conforme o número de perfis aumenta, a carga de processamento também é aumentada, pois o coeficiente de Pearson é aplicado a cada par de usuários, o que implica em uma quantidade muito grande de pares.

O número elevado de perfis também gera uma dificuldade de se encontrar usuários com interesses semelhantes. A quantidade de conteúdos disponíveis é muito grande, bem como a quantidade de conteúdos consumidos pelos usuários. Isto pode fazer com que os perfis existentes sejam muito esparços, não permitindo que o sistema encontre similaridades entre eles.

Por fim, o problema da privacidade do usuário também deve ser levado em consideração, uma vez que dados do comportamento do usuário serão enviados para um servidor externo. Muitas vezes, os usuários não querem que seu perfil de consumo seja divulgado. A privacidade do usuário é um dos problemas mais críticos neste tipo de sistema.

## 5.6 Trabalhos relacionados

Esta Seção apresenta alguns trabalhos que possuem relação com a proposta desta dissertação. Cada trabalho trata de uma abordagem diferente, mas possui alguma relação com o SeReS. Alguns tratam de sistemas de recomendação para TVD e outros da utilização de ontologias.

Naudet et al. (2008) apresentam um sistema de recomendação que foi desenvolvido para realizar filtragem em conteúdos de TV oferecidos para dispositivos móveis. O sistema de recomendação é todo baseado em ontologias, que são utilizadas para formalizar os

interesses dos usuários e o conteúdo televisivo.

O desenvolvimento do trabalho foi realizado sobre o padrão DVB-H<sup>3</sup> (*Digital Video Broadcasting - Handheld*), que é o padrão de TVD para dispositivos móveis adotado na Europa.

Para possibilitar a recomendação foram desenvolvidos dois módulos para integração ao sistema: o módulo de recomendação e o módulo de perfis. O módulo de recomendação é responsável por realizar as recomendações ao usuário, enquanto o módulo de perfis trata de perfis dos usuários.

O sistema funciona através da integração entre o módulo de recomendação, o módulo de perfis e o conjunto de ontologias. A recomendação é realizada através do processamento de dados do usuário e dos descritores dos conteúdos, assim uma lista com os possíveis conteúdos que podem ser de interesse do usuário são apresentados a ele.

O perfil do usuário é constantemente atualizado através do módulo de perfis, que fica monitorando todas as ações do usuário durante sua interação com o sistema. O módulo utiliza dois mecanismos para geração dos perfis: explícito e implícito. No modo explícito, o usuário informa ao sistema suas preferências e interesses através de um servidor *Web*. Na forma implícita, o sistema monitora o usuário e atualiza seu perfil através de sua interação com a programação.

Uma das semelhanças do SeReS com este trabalho é a utilização de módulos para tratar da recomendação e dos perfis do usuário. Outra semelhança é a utilização de ontologias para descrever os conteúdos. A principal diferença entre os sistemas é o padrão de TVD adotado, uma vez que a pesquisa aborda o padrão europeu (DVB-H) e o SeReS trabalha com o padrão brasileiro (SBTVD). Outra diferença é o escopo dos dispositivos a serem utilizados. Os autores da pesquisa trabalharam com dispositivos móveis, enquanto o SeReS é focado nos STBs, ou seja, dispositivos fixos nas residências dos telespectadores.

Blanco-Fernández et al. (2008) propõem uma arquitetura de recomendação de conteúdo para o ambiente de TVD através da utilização de ontologias e ativação semântica. A proposta trabalha com recomendação baseada em conteúdo, na qual conteúdos já consumidos ativam itens iniciais que por sua vez ativam outros itens relacionados.

A proposta utiliza uma ontologia para descrever os conteúdos disponíveis na TV e suas características, sendo assim cada conteúdo possui ligações com outros itens. Após o levantamento de todos os itens, outros conteúdos que possuem ligações com os itens

---

<sup>3</sup><http://www.dvb-h.org/>

ativados podem ser recomendados ao usuário.

Este trabalho apresenta uma grande semelhança com o SeReS, devido a utilização de uma ontologia, uma rede semântica e o processo de ativação semântica. A diferença é que o SeReS gera um perfil do usuário em XML que permite o intercâmbio com outras aplicações, possibilitando, por exemplo, transformar o SeReS em um sistema híbrido, conforme o estudo de Dias (2010) descrito na Seção 5.5.

No trabalho de Ávila e Zorzo (2009) é apresentado um sistema de recomendação para o SBTVD que utiliza a recomendação baseada no histórico do usuário, ou seja, todo conteúdo a ser recomendado tem relação com os programas que o usuário já consumiu.

Os autores propõem uma extensão ao *middleware* Ginga do SBTVD: o módulo *RecommenderTV*. Este módulo é implementado no *Common Core* do *middleware*, e tem como responsabilidade armazenar, tratar, processar e recomendar conteúdo para o telespectador.

O código fonte do *middleware* é escrito na linguagem C/C++, sendo assim o módulo *RecommenderTV* foi desenvolvido nessa linguagem para que fosse possível sua integração ao *middleware*. O processo de mineração de dados é realizado através do pacote Weka (*Waikato Environment for Knowledge Analysis*), que é desenvolvido em Java. Para permitir a comunicação entre o módulo inserido no *middleware* e o pacote Weka, os autores utilizaram um conjunto de APIs chamado JNI (*Java Native Interface*) que permite a comunicação entre as linguagens C/C++ e Java.

No desenvolvimento do *RecommenderTV*, todo o processamento e armazenamento das informações é realizado no STB, sendo o armazenamento realizado através do Sqlite, uma biblioteca escrita em linguagem C que implementa uma base de dados SQL (*Structured Query Language*). Essa biblioteca foi integrada com os módulos do *middleware* e com o módulo de mineração de dados do pacote Weka, o que forneceu uma eficiência ao sistema de recomendação.

A semelhança entre o *RecommenderTV* e o SeReS é a proposta de integração do módulo de recomendação com o *middleware* Ginga, com a diferença da técnica utilizada para recomendar conteúdos, uma vez que o *RecommenderTV* utiliza a técnica de recomendação baseada no histórico do usuário enquanto o SeReS utiliza processamento semântico para realizar recomendação.

Outra diferença é a forma de armazenamento, o sistema *RecommenderTV* utiliza uma base de dados SQL para armazenar os dados, enquanto o SeReS armazena os dados dire-



tamente em arquivos OWL, que são representações ontológicas dos conteúdos, e arquivos XML para armazenar o perfil dos usuários.

Lucas e Zorzo (2009) apresentam o sistema de recomendação chamado RePTVD, um sistema utilizado para realizar recomendação de conteúdo para multiusuários implementado no SBTVD. O sistema é baseado no armazenamento de histórico dos usuários, assim realiza recomendação considerando o que o usuário já consumiu.

O sistema utiliza o pacote Weka para realizar a mineração dos dados e armazenar as informações em arquivos ARFF (*Attribute Relation File Format*), formato de arquivo próprio do pacote Weka.

Os metadados dos programas, enviados pela emissora junto com o conteúdo, são utilizados para traçar o perfil do usuário. Estes metadados são transportados através das tabelas EIT e SDT, definidas em (ABNT, 2008a) para informar ao STB as características do conteúdo transmitido.

A implementação do sistema foi realizada em Java, utilizando a API JavaTV. Esta API permite que se trabalhe com aplicações Xlets e oferece facilidades para o desenvolvimento de aplicações para TVD.

As diferenças entre o RePTVD e o SeReS são a forma de implementação, o modo de tratamento das informações dos usuários e conteúdos e o modo de armazenamento dos perfis. Primeiro, o SeReS tem a finalidade de permitir aplicações Java e NCL, diferente do RePTVD que só trabalha com aplicações Java; no SeReS as informações de conteúdo e dos usuários são processadas através do uso de ontologias, já no RePTVD são processadas pelo pacote Weka, que armazena as informações em arquivos; por fim o armazenamento dos perfis no RePTVD é realizado em arquivos ARFF, enquanto que no SeReS o armazenamento é realizado em arquivos XML.

## 5.7 Considerações finais

Sabendo que os sistemas desenvolvidos para recomendação de conteúdo no SBTVD são pouco efetivos, pelo fato de utilizarem técnicas baseadas somente no histórico do usuário, a implementação de um sistema que explora informações semânticas dos conteúdos melhora significativamente o processo de recomendação.

Visando atender essa necessidade de melhora no processo de recomendação, este Capítulo apresentou o SeReS, um sistema de recomendação de conteúdo que utiliza proces-

samento semântico. Com base no consumo do usuário, este processamento permite que relações semânticas entre os conteúdos consumidos sejam descobertas, a fim de se determinar os interesses do usuário. A partir desses interesses, novos conteúdos são recomendados ao usuário.

O SeReS é executado no STB, o que permite que as recomendações sejam realizadas localmente, ou seja, todo processamento é realizado pelo próprio STB, porém é possível integrar o SeReS a um servidor externo que implemente filtragem colaborativa, o que pode auxiliar no processo de recomendação. Essa integração deve ser realizada de forma cuidadosa, pois é necessário considerar os problemas de escalabilidade e privacidade dos usuários, conforme detalhado na Seção 5.5.

Por fim, é importante salientar que o SeReS emprega técnicas modernas e robustas para recomendação de conteúdos, o que permite que a recomendação seja mais efetiva e não previsível.

## 6 SeReS: Testes e proposta de implementação no ambiente Ginga

Para validar o SeReS, e mostrar sua eficácia em recomendar conteúdos, este Capítulo apresenta a forma como o SeReS foi implementado, alguns testes realizados sobre esta implementação e os resultados obtidos. A implementação apresentada mostra os recursos utilizados e a forma como foi realizada a aplicação.

Visando tornar o SeReS um sistema integrado ao Ginga, é proposta uma extensão ao EPG (*Electronic Program Guide*) de Moreno, Soares Neto e Soares (2009), no qual é possível a inserção de módulos que permitem ao SeReS auxiliar no processo de recomendação do EPG.

Este Capítulo está organizado da seguinte forma: a Seção 6.1 apresenta o processo de desenvolvimento do SeReS, abordando as tecnologias utilizadas para sua implementação e seu funcionamento. Na Seção 6.2 é apresentada uma proposta de integração do SeReS no Ginga. Por fim, a Seção 6.3 traz as considerações finais sobre o Capítulo.

### 6.1 Desenvolvimento do SeReS

O SeReS foi desenvolvido utilizando a linguagem Java, o *framework* Jena (Carroll et al., 2004) para a persistência das instâncias da ontologia em um banco de dados, e o banco de dados *AllegroGraphServer* que é utilizado para armazenamento das triplas RDF. Para a busca nas ontologias foi utilizado a linguagem SPARQL<sup>1</sup>, que permite a recuperação de dados diretamente nas triplas armazenadas no banco. As *queries* em SPARQL foram implementadas através do Jena na linguagem Java.

Os *logs* do usuário são armazenados em arquivos texto e são utilizados para determinar o perfil local do usuário, contendo informações de seu consumo. O programa utiliza o perfil

---

<sup>1</sup><http://www.w3.org/TR/rdf-sparql-query/>

local para determinar os interesses do usuário juntamente com o processamento da rede semântica, gerando ao final o perfil do usuário em um arquivo XML.

O processamento da rede semântica foi realizado utilizando-se um programa em Java que tem como entrada o perfil local do usuário. O algoritmo para processamento da rede semântica é o *Branch-and-bound*, apresentado na Seção 5.4. Após a execução desse processo, é gerado uma relação de interesses do usuário e dos conteúdos que podem ser recomendados a ele. Também é gerado o arquivo XML que armazena essas informações.

Para realizar a validação da recomendação através da ativação semântica foram realizados alguns experimentos simulando o consumo de alguns usuários. Para estes experimentos foram criadas instâncias de conteúdos e perfis de usuários, uma vez que a transmissão das informações pela emissora ainda não está disponível. Os experimentos visam demonstrar que, independente do consumo do usuário, através da ativação semântica é possível recomendar conteúdos que o usuário desconhecia, ou seja, conteúdos que não eram esperados pelo usuário.

Para exemplificar a aplicação, foi tomado um perfil aleatório, no caso o usuário que possui o STB 1834935888, para se realizar a recomendação. O consumo deste usuário é composto pelos conteúdos *Scuba Diving*, *Avatar*, *Mr. & Mrs. Smith* e *Wanted*, mostrando que este usuário possui interesse em três filmes e um documentário. A Figura 6.1 apresenta parte da rede semântica gerada para este usuário a fim de ilustrar o processo de ativação semântica.

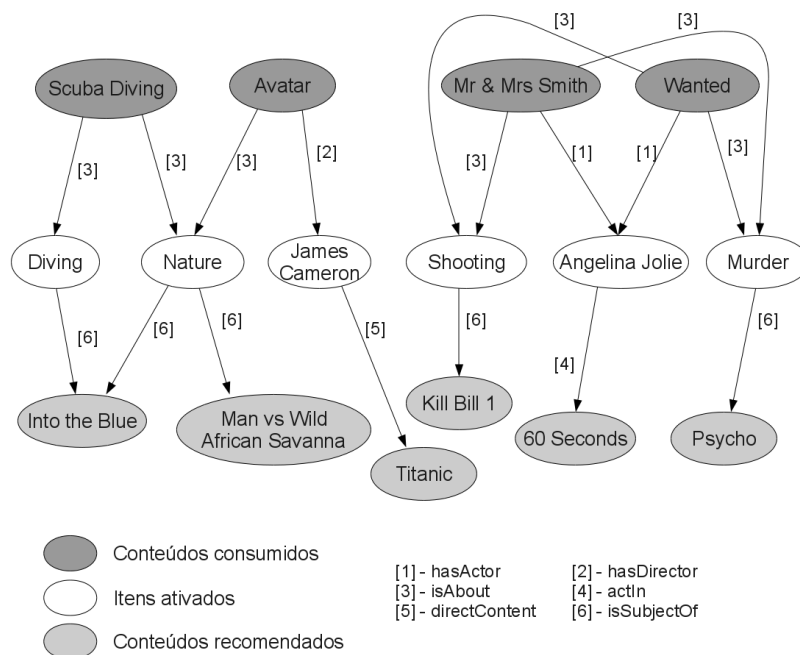


Figura 6.1: Trecho da rede semântica para o usuário 1834935888

A partir dos conteúdos consumidos pelo usuário, foi possível descobrir alguns de seus interesses, uma vez que, através da ativação semântica, itens como atores, diretores, apresentadores e assuntos, entre outros, foram atingidos na rede semântica, conforme mostrado na Figura 6.1 através dos relacionamentos [1]-*hasActor*, [2]-*hasDirector* e [3]-*isAbout*. Alguns itens ativados para este usuário são apresentados na Tabela 6.1.

Tabela 6.1: Itens ativados diretamente para o usuário 1834935888

Tipo	Item	Tipo	Item
Diretor	Doug_Liman	Ator	Dileep_Rao
Diretor	James_Cameron	Ator	Sam_Worthington
Diretor	Timus_Bekmambetov	Ator	Stephen_Lang
Ator	Angelina_Jolie	Ator	Morgan_Freeman
Ator	Brad_Pitt	Ator	James_McAvoy
Ator	Adam_Brody	Assunto	Shooting
Ator	Vince_Vaughn	Assunto	Murder
Ator	Joel_Moore	Assunto	Spionage
Ator	Laz_Alonso	Assunto	Ecology
Ator	Giovanni_Ribisi	Assunto	Nature
Ator	Cch_Pounder	Assunto	Extraterrestrial
Ator	Michelle_Rodriguez	Assunto	Aliens
Ator	Sigourney_Weaver	Assunto	Diving
Ator	Zoe_Saldana	Assunto	Ocean

Esse itens ativarão outros itens, que são os conteúdos disponíveis para recomendação, como pode ser observado na Figura 6.1 pelos relacionamentos [4]-*actIn*, [5]-*directContent* e [6]-*isSubjectOf*. Quando esses itens são atingidos, o processo de ativação chega ao seu fim, e todos os itens de interesse do usuário receberam um valor de ativação. Em seguida, é elaborada uma fila de prioridade em ordem decrescente com os conteúdos que podem ser recomendados. Os primeiros itens da fila indicam os conteúdos que possuem um vínculo maior com os interesses do usuário, sendo portanto os primeiros a serem recomendados. A Figura 6.2 apresenta um trecho do perfil do usuário 1834935888 com os conteúdos recomendados e seus respectivos valores de ativação.

Tomando o trecho da rede semântica apresentado na Figura 6.1, com foco nos conteúdos recomendados, é possível associá-los ao perfil do usuário, apresentado na Figura 6.2. O filme “*Into the Blue*” é apresentado na linha 83, o documentário “*Man vs Wild - African Savanna*” aparece na linha 103, e todos os outros conteúdos também estão inseridos no arquivo XML que representa o perfil do usuário.

Para explicar o porque desses conteúdos serem recomendados, é possível realizar uma associação entre os itens ativados e os conteúdos recomendados. Por exemplo, o filme

```

74 <Recommended_Contents>
75 <title>Knowing</title>
76 <activation_level>0.053</activation_level>
77 <title>E. T. - The Extra-Terrestrial</title>
78 <activation_level>0.053</activation_level>
79 <title>X-Files</title>
80 <activation_level>0.053</activation_level>
81 <title>Alien: Ressurrection</title>
82 <activation_level>0.0525</activation_level>
83 <title>Into the Blue</title>
84 <activation_level>0.052</activation_level>
85 <title>Titanic</title>
86 <activation_level>0.052</activation_level>
87 <title>The Russia House</title>
88 <activation_level>0.0519</activation_level>
89 <title>Charlie's Angels</title>
90 <activation_level>0.0519</activation_level>
91 <title>Kill Bill - Volume 1</title>
92 <activation_level>0.0519</activation_level>
93 <title>Kill Bill - Volume 2</title>
94 <activation_level>0.0519</activation_level>
95 <title>Psycho</title>
96 <activation_level>0.0514</activation_level>
97 <title>60 Seconds</title>
98 <activation_level>0.051</activation_level>
99 <title>Inglourious Basterds</title>
100 <activation_level>0.0505</activation_level>
101 <title>Star Trek</title>
102 <activation_level>0.0505</activation_level>
103 <title>Man vs Wild - African Savanna</title>
104 <activation_level>0.0505</activation_level>
105 <title>Fast and Furious</title>
106 <activation_level>0.0505</activation_level>
107 </Recommended_Contents>
108 </Profile>

```

Figura 6.2: Trecho do perfil do usuário 1834935888 com os conteúdos recomendados

“*Into the Blue*” foi recomendado ao usuário porque ele apresenta relações com os assuntos “*Diving*” e “*Nature*”, que foram ativados como de interesse do usuário, conforme apresentado na Tabela 6.1; já o filme “*60 seconds*” foi recomendado pois apresenta relação com a atriz “*Angelina Jolie*”. Todos os conteúdos recomendados apresentam relações com os conteúdos consumidos e surpreendem o usuário, pois podem ser dos mais variados tipos. Por exemplo, o usuário pode consumir um filme e ter como recomendação um documentário, ou um desenho animado.

Os resultados obtidos mostram que diversos conteúdos recomendados estão relacionados com os consumos dos usuários, independente do tipo de programa (filme, telejornal, documentário). Estes resultados indicam que o SeReS é capaz de recomendar conteúdos que o usuário não espera, melhorando sua satisfação em relação ao sistema.

Todas as informações referentes aos conteúdos são definidas na ontologia, na qual cada instância possui as informações que são utilizadas para se encontrar os relacionamentos entre os conteúdos. Dois exemplos de instâncias e suas características são apresentados na Figura 6.3, onde (6.3a) apresenta características do filme “*Avatar*” e (6.3b) características do filme “*Wanted*”.

cnt:Avatar	
cnt:hasDirector =	cnt:James_Cameron
cnt:isAbout =	cnt:Aliens
	cnt:Extraterrestrial
	cnt:Nature
	...
cnt:belongsToCategory =	ctg:adventure
	ctg:action
	ctg:animation
cnt:hasActors =	cnt:Stephen_Lang
	cnt:Sam_Worthington
	cnt:Dileep_Rao
	...
cnt:Script =	James Cameron
...	

(a) Avatar

cnt:Wanted	
cnt:hasDirector =	cnt:Timus_Bekmambetov
cnt:isAbout =	cnt:Murder
	cnt:Shooting
cnt:belongsToCategory =	ctg:action
cnt:hasActors =	cnt:Angelina_Jolie
	cnt:James_McAvoy
	cnt:Morgan_Freeman
cnt:Script =	Chris Morgan
	Michael Brandt
	Derek Haas
...	

(b) Wanted

Figura 6.3: Características dos filmes *Avatar* e *Wanted*

É importante notar que o consumo do usuário é armazenado no STB, de forma que quando novos conteúdos forem consumidos, todo o processo de recomendação é realizado levando em consideração os novos consumos mais os consumos já registrados. Dessa forma, novos itens podem ser ativados na rede semântica, ocasionando uma recomendação diferente. O processo de recomendação ocorre três vezes por semana, uma vez que o consumo do usuário é alterado cada vez que ele assiste a TV, portanto é necessário considerar no seu perfil esse novo consumo.

## 6.2 Proposta de integração no Ginga

Este trabalho buscou investigar uma abordagem mais efetiva para a recomendação de conteúdo para o SBTVD. Parte significativa do trabalho transcorreu antes que houvessem implementações de referência minimamente estáveis de vários módulos do *middleware* Ginga. Dessa forma, buscou-se simular o ambiente descrito nas especificações do SBTVD (ABNT, 2008a; LAViD; Telemidia, 2009), sobretudo no que diz respeito à geração e ao processamento dos metadados que caracterizam os programas de TV. Foi neste cenário que o SeReS foi construído (Silva; Baldochi, 2010).

Mais recentemente, com a publicação de trabalhos que caracterizam o funcionamento de um Guia Eletrônico de Programação (EPG) integrado ao Ginga (Moreno; Soares Neto; Soares, 2009; Maia; Leite; Batista, 2010), tornou-se viável o desenvolvimento de módulos que permitam integrar o SeReS ao *middleware* Ginga.

Esta Seção discute uma proposta de integração do SeReS ao ambiente Ginga, apoiado no EPG proposto por Moreno, Soares Neto e Soares (2009).

Um EPG é caracterizado como uma aplicação que apresenta para o usuário informações sobre os conteúdos e serviços disponíveis na grade de programação da TV (Morris; Smith-Chaigneau, 2005). Eles são responsáveis por processar e exibir as informações recebidas das emissoras.

Moreno, Soares Neto e Soares (2009) propõem um tipo específico de EPG, chamado de Aplicação de Guia Eletrônico (EGA) e as informações que são apresentadas por essa aplicação são chamadas de Informação do Guia Eletrônico (EGI). Os autores afirmam que as EGAs podem apresentar os metadados da programação de forma adaptada, ou seja, de acordo com o perfil do usuário.

A arquitetura proposta pelos autores é dividida em módulos, utiliza as linguagens NCL e LUA no seu desenvolvimento e é integrada ao Ginga-NCL. Alguns componentes do sistema são residentes no *middleware*, enquanto outros são recebidos a partir dos meios de transmissão.

A arquitetura do EGA proposto é dividido em oito módulos, conforme apresentado na Figura 6.4. O processo de geração do EGI é dividido em duas fases: *feeding* e *production*. Na fase de *feeding*, as informações que serão processadas e apresentadas pelo EGI são obtidas e transformadas em estruturas internas chamadas de *Service Data*, que então são passadas para a fase de produção (*production*). Nesta fase, uma estrutura chamada *Electronic Guide Document* (EGD) é criado para ser apresentado pelo EGD *player*, provido pelo *middleware*.

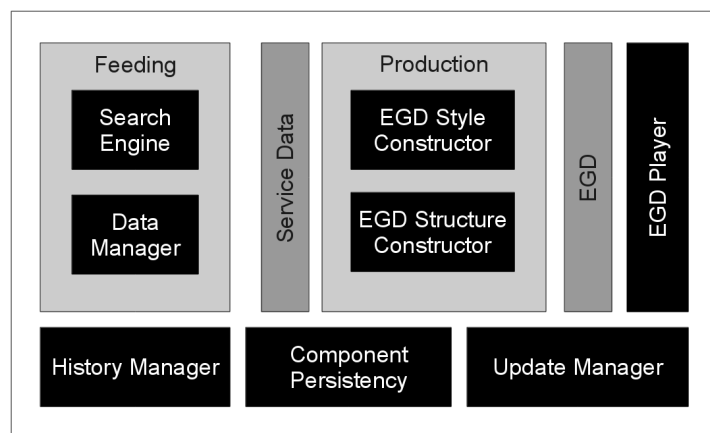


Figura 6.4: Arquitetura do EGA proposta por Moreno, Soares Neto e Soares (2009)

Segundo os autores, os componentes da arquitetura proposta possuem as seguintes



funcionalidades:

- *Search Engine*: Responsável por coletar as informações recebidas das emissoras.
- *Data Manager*: Controla a *Search Engine* e processa as informações coletadas, adicionando-as à estrutura *Service Data*.
- Estrutura *Service Data*: Lista de informações de serviços processadas em um formato interno do EGA. Apresenta as informações sobre eventos.
- *History Manager*: Armazena informações sobre o histórico do usuário, permitindo que essas informações sejam utilizadas por outras aplicações, por exemplo, um sistema de recomendação.
- *EGD Style Production*: Responsável por criar os estilos de apresentação que serão utilizados para exibir as informações extraídas da estrutura *Service Data*.
- *EGD Structure Constructor*: Responsável por organizar, estruturar e relacionar conteúdos para serem apresentados.
- *EGD Player*: Processa o EGD gerado e o exibe para o usuário.
- *Update Manager*: Responsável por manter as versões dos componentes e receber requisições para atualizá-los.
- *Component Persistency*: Responsável por persistir qualquer informação de atualização dos componentes.

É possível realizar uma extensão neste modelo de forma a inserir o SeReS neste EPG, permitindo assim que os programas apresentados ao usuário sejam de seu interesse. Para isso é necessário adicionar novos módulos à arquitetura proposta por Moreno, Soares Neto e Soares (2009). A Figura 6.5 apresenta uma proposta de arquitetura desse sistema.

Os novos módulos inseridos no EPG são responsáveis por gerar o perfil do usuário (*Profile Manager*), criar as instâncias da ontologia a partir dos dados recebidos da emissora (*Ontology Manager*) e realizar a recomendação (*Recommender*).

Para gerar o perfil do usuário, o módulo *Profile Manager* deve se comunicar com o módulo *History Manager*, dessa forma ele consegue acessar todas as informações sobre o consumo do usuário, possibilitando assim gerar seu perfil. Este módulo deve trabalhar em conjunto com o módulo ontológico, para que ao final do processo o perfil do usuário seja

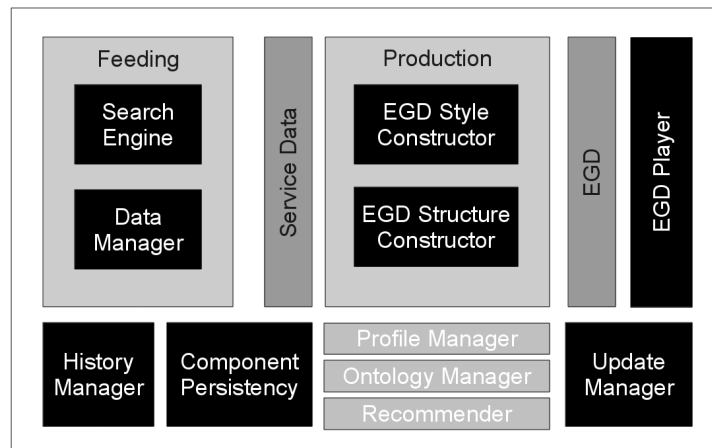


Figura 6.5: Arquitetura do EPG com o SeReS integrado

gerado em um arquivo XML com todos os interesses do usuário e com todos os conteúdos consumidos e recomendados para ele.

O módulo ontológico (*Ontology Manager*) é responsável por criar as instâncias dos conteúdos consumidos pelo usuário e conteúdos disponíveis na programação para que o EPG possa sugerir esses conteúdos ao usuário. Para realizar essa ação, o módulo ontológico deve ter acesso ao módulo *History Manager*, para obter as informações sobre o consumo do usuário, e acessar também a estrutura *Service Data* para obter informações sobre os conteúdos que estão disponíveis na grade da programação das emissoras.

Outras funções do módulo ontológico são a criação da rede semântica a partir das instâncias geradas e a realização do processo de ativação semântica nesta rede. Este módulo deve se comunicar com o módulo *Profile Manager* para informá-lo dos interesses do usuário e dos conteúdos que serão recomendados a ele.

Por fim, o módulo de recomendação (*Recommender*) é responsável por realizar a recomendação ao usuário, tendo como base o perfil em XML gerado pelo módulo *Profile Manager*. Este módulo deve passar as informações dos conteúdos a serem recomendados para o *EGD Structure Constructor*, no processo de produção, para que a lista de conteúdos sugerida seja exibida pelo *EGD Player*.

A arquitetura com as extensões propostas deve possibilitar a integração do SeReS ao EPG proposto por Moreno, Soares Neto e Soares (2009), melhorando a qualidade dos conteúdos sugeridos ao usuário e permitindo que os conteúdos de interesse sejam selecionados de uma forma mais rápida do que através da busca tradicional pelos canais.

## 6.3 Considerações finais

Este Capítulo apresentou a abordagem utilizada para realizar a implementação do SeReS, as tecnologias utilizadas e uma proposta de integração do sistema no *middleware* Ginga.

O SeReS foi desenvolvido utilizando a linguagem Java, integrado ao *framework* Jena, que também é baseado em Java, e permite que se manipule ontologias de uma forma facilitada, pois disponibiliza APIs que permitem essa manipulação. A utilização desta ferramenta permitiu trabalhar com as instâncias da ontologia de uma maneira simples e prática, pois é possível persistir as informações em um banco de dados, realizar buscas nessa base e manipular as informações.

O banco de dados *AllegroGraphServer* auxiliou no armazenamento das instâncias, uma vez que esse banco foi desenvolvido para armazenar triplas RDF, não sendo necessário modificar a forma de representação da ontologia, pois todos os relacionamentos e informações da ontologia são representados através de triplas.

A utilização da linguagem XML para representar os perfis dos usuários se mostrou adequada, pois facilita o intercâmbio de informações entre aplicações e não consome muita banda para ser transferido, uma vez que o arquivo é composto somente por texto.

Os testes realizados simulando os consumos dos usuários mostraram que a utilização da ontologia e da rede semântica, juntamente com o processo de ativação semântica melhoraram a descoberta de interesses dos usuários, pois permitiram que informações dos conteúdos consumidos fossem descobertas. Os resultados obtidos com esses interesses apresentaram sugestões de conteúdos de tipos variados, bem como conteúdos relacionados ao consumo do usuário, evitando que conteúdos iguais aos consumidos fossem recomendados. Esses resultados mostraram que o SeReS é um sistema que realiza recomendações que surpreendem o usuário, facilitando a procura por conteúdos relevantes.

Por fim, uma proposta de integração do SeReS ao *middleware* Ginga foi apresentada, na qual o SeReS pode ser adicionado ao EPG desenvolvido por Moreno, Soares Neto e Soares (2009). Este EPG tem a função de facilitar a busca por programas na grade de programação da TV. Com o auxílio do SeReS, a recomendação pode ser melhor personalizada de acordo com o perfil do usuário.

## 7 Conclusão

O interesse do consumidor em ter produtos e serviços de entretenimento digital disponíveis no ambiente doméstico tem motivado o desenvolvimento de novos sistemas de televisão capazes de atender tal demanda. Os desafios de pesquisa associados ao desenvolvimento desses sistemas são expressivos, seja na transmissão de grandes volumes de dados multimídia, ou na integração de diferentes tipos de conteúdo numa mesma plataforma (canais de TV com conteúdo da *Web*, por exemplo). Uma característica desses novos sistemas é a abundância de informações, que traz uma sobrecarga ao usuário, lhe impedindo de desfrutar plenamente do vasto conteúdo disponível.

Nota-se, portanto, que além dos desafios já conhecidos nas áreas de telecomunicações e processamento multimídia, a TVD traz também desafios relativos ao consumo do conteúdo disponibilizado. Esses desafios têm sido tratados com o desenvolvimento de aplicações que executam em dispositivos atrelados aos aparelhos de televisão, chamados *set top boxes*. As aplicações desenvolvidas visam, sobretudo, fornecer ao usuário facilidades para gerenciar o volume imenso de conteúdo disponibilizado diariamente. Uma tendência cada vez mais presente nesses sistemas é a personalização, que leva em consideração as características e preferências do usuário a fim de prover serviços que facilitem sua interação com o sistema, criando uma forma de apresentar o sistema de televisão de uma maneira mais individualizada a cada usuário (Blanco-Fernández et al., 2006; Ávila; Zorzo, 2009; Hölbling; Pleschgatterinig; Kosch, 2010). Neste cenário, os sistemas de recomendação, largamente utilizados na *Web*, ganham importância especial, uma vez que objetivam identificar o usuário, suas preferências e necessidades, para, então, prover-lhe serviços customizados.

A literatura reporta esforços no sentido de prover personalização ao ambiente do SBTVD (Alves, 2008; Ávila; Zorzo, 2009; Lucas; Zorzo, 2009). Esses trabalhos exploram abordagens de recomendação baseadas na proximidade sintática entre conteúdos consumidos pelo usuário e outros conteúdos disponíveis para consumo, o que resulta em recomendações previsíveis. Por outro lado, trabalhos desenvolvidos para outros ambientes de TVD (Naudet et al., 2008; Blanco-Fernández et al., 2008), reportaram resultados bem

melhores através da utilização de ontologias capazes de explorar o domínio dos programas da TVD. Influenciado pelo bom desempenho desses sistemas, este trabalho propôs o desenvolvimento do SeReS - *Semantic-based Recommender System*, ou Sistema de Recomendação baseado em Semântica, cuja proposta é explorar a proximidade semântica entre os diferentes programas disponíveis na TVDi a fim de permitir uma recomendação de conteúdo menos previsível, e que seja efetiva para encontrar o relacionamento entre programas que não possuem atributos sintáticos em comum.

O desenvolvimento do SeReS teve início com a definição de uma ontologia capaz de representar o domínio dos programas do SBTVD. Tomando como base a norma NBR 15603-2 (ABNT, 2008a) e os trabalhos de Naudet et al. (2008) e Blanco-Fernández et al. (2008), foi definida uma ontologia de domínio para o ambiente do SBTVD. O SeReS, com base nessa ontologia e no consumo de programas por parte do usuário, processa a grade de programação enriquecendo os conteúdos disponíveis com metadados obtidos a partir de *Websites*, tais como o IMDB e o TheTVDB.com. Em seguida, produz uma rede semântica cujos nós são os programas consumidos pelo usuário juntamente com outros programas disponíveis na grade de programação. Então, utilizando técnicas de ativação semântica (*Semantic Spreading*) (Collins; Loftus, 1975; Preece, 1981), o SeReS é capaz de descobrir programas relacionados com outros consumidos pelo usuário no passado, através de relacionamentos semânticos. O resultado desse processamento é a geração de um perfil de usuário, contendo informações que podem ser diretamente utilizadas para realizar recomendação. Este perfil, expresso na linguagem XML, pode também ser usado por outras aplicações, tais como aplicações que realizam propaganda direcionada.

## 7.1 Resultados e contribuições

Durante o desenvolvimento do SeReS, foram geradas algumas contribuições relevantes para pesquisas relacionadas com o SBTVD, entre elas, vale destacar:

- A ontologia desenvolvida com base na norma NBR 15603-2. Com a conclusão do trabalho, a ontologia desenvolvida está sendo publicamente disponibilizada. Espera-se que a mesma venha a ser utilizada por outros trabalhos que explorem processamento semântico no ambiente do SBTVD.
- O processo de enriquecimento semântico dos programas disponíveis na grade de programação, usando informação publicamente disponível na *Web*, em sites como o

IMDB e o TheTVD.com. Este processo pode ser utilizado por outros trabalhos que necessitem de informações referentes à programação da TV.

- O algoritmo para processamento da rede semântica, descrito na Seção 5.4.
- O perfil do usuário gerado em XML com seus interesses. Este perfil pode ser utilizado por outros trabalhos que realizam o processamento de informações de usuários tomando como base seu consumo e seus interesses.

Finalmente, é importante frisar os bons resultados obtidos nos experimentos realizados. Diferentemente dos outros sistemas já desenvolvidos para o SBTVD, os experimentos demonstram que o SeReS é capaz de realizar recomendações de conteúdos relevantes ao usuário, sem que esses conteúdos apresentem atributos sintáticos comuns. Em geral, tais recomendações não são superespecializadas, o que traz mais efetividade ao processo de recomendação. Os resultados obtidos nos experimentos são semelhantes com os reportados por Naudet et al. (2008) e Blanco-Fernández et al. (2008), mostrando que abordagens baseadas em processamento semântico são mais efetivas para a recomendação de conteúdo, especialmente no domínio da TVD.

## 7.2 Trabalhos futuros

Com o objetivo de incentivar a pesquisa envolvendo ontologias e sistemas de recomendação, e para permitir que melhorias sejam implementadas em sistemas já existentes, a seguir são apresentadas algumas sugestões para trabalhos futuros.

1. Na Seção 6.2 deste trabalho foi apresentada uma proposta de integração do SeReS em um modelo de EPG definido por Moreno, Soares Neto e Soares (2009). Um possível trabalho a ser realizado é a implementação desta proposta, embutindo o SeReS neste EPG personalizável.
2. Existem aplicações que podem explorar os perfis XML gerados pelo SeReS. Aplicações que trabalham com propaganda direcionada, por exemplo, podem fazer uso desses perfis, e relacionar as propagandas disponíveis com os interesses do usuário.
3. Sistemas que utilizam os interesses do usuário para realizar recomendação precisam conhecer os níveis de interesse do usuário por um determinado item. Esta tarefa não é simples, uma vez que o usuário pode consumir diferentes conteúdos, demonstrando

seu interesse por vários itens relacionados com os conteúdos consumidos. Formas de se determinar o nível de interesse do usuário por cada item também podem ser exploradas em novas pesquisas.

4. Uma maneira de se determinar os pesos dos relacionamentos de forma automática também pode ser desenvolvida, uma vez que a definição dos pesos foi efetuada de forma empírica. A automatização do processo pode considerar a forma como os itens se relacionam na rede semântica, e então verificar quais os relacionamentos são mais importantes.

## Referências Bibliográficas

- ABNT. *ABNT NBR 15603-2: Televisão digital terrestre - Multiplexação e serviços de informação (SI) Parte 2: Estrutura de dados e definições da informação básica de SI*. Rio de Janeiro, RJ, Agosto 2008.
- ABNT. *ABNT NBR 15606-2:2007 - Televisão digital terrestre - Codificação de dados e especificações de transmissão para radiodifusão digital Parte 2: Ginga-NCL para receptores fixos e móveis - Linguagem de aplicação XML para codificação de aplicações*. Rio de Janeiro, RJ, Agosto 2008.
- ABNT. *ABNT NBR 15606-5:2008 - Televisão digital terrestre - Codificação de dados e especificações de transmissão para radiodifusão digital Parte 5: Ginga-NCL para receptores portáteis - Linguagem de aplicação XML para codificação de aplicações*. Rio de Janeiro, RJ, Agosto 2008.
- ABNT. *ABNT/CEET-00:001.85 - Televisão digital terrestre - Codificação de dados e especificações de transmissão digital - Parte 4: Ginga-J - Ambiente para a execução de aplicações procedurais. (Versão Draft 05/2008)*. Rio de Janeiro, RJ, Maio 2008.
- 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*, IEEE Computer Society, Los Alamitos, CA, EUA, v. 17, p. 734–749, 2005. ISSN 1041-4347.
- Ali, K.; van Stam, W. Tivo: making show recommendations using a distributed collaborative filtering architecture. In: *KDD '04: Proceedings of the tenth ACM SIGKDD international conference on Knowledge discovery and data mining*. New York, NY, EUA: ACM, 2004. p. 394–401. ISBN 1-58113-888-1.
- Alves, L. G. P. *CollaboraTVware: Uma infra-estrutura ciente de contexto para suporte a participação colaborativa no cenário da tv digital interativa*. Dissertação (Mestrado) — Escola Politécnica da Universidade de São Paulo, São Paulo, 2008.
- Antoniou, G.; van Harmelen, F. *A semantic web primer*. 2nd. ed. Cambridge, Massachusetts: The MIT Press, 2008.
- ARIB. *ARIB STD-B24 Version 5.2 Volume 2 Data coding and transmission specification for digital broadcasting*. Japão, Fevereiro 2008.
- Aroyo, L.; Bellekens, P.; Bjorkman, M.; Houben, G.-J.; Akkermans, P.; Kaptein, A. Sensee framework for personalized access to tv content. In: *Interactive TV: a shared experience*. Alemanha: Springer Berlin / Heidelberg, 2007, (Lecture Notes in Computer Science, v. 4471/2007). p. 156–165.
- ATSC. *Advanced Television System Committee*. 2009. Disponível em <http://www.atsc.org/>. Último acesso: Novembro de 2010.



- Ávila, P. M.; Zorzo, S. D. A personalized tv guide system: an approach to interactive digital television. In: *SMC'09: Proceedings of the 2009 IEEE international conference on Systems, Man and Cybernetics*. Piscataway, NJ, EUA: IEEE Press, 2009. p. 2122–2127. ISBN 978-1-4244-2793-2.
- Billsus, D.; Pazzani, M. J. A personal news agent that talks, learns and explains. In: *Proceedings of the 3rd annual conference on Autonomous Agents*. New York, NY, EUA: ACM, 1999. (AGENTS '99), p. 268–275. ISBN 1-58113-066-X.
- Billsus, D.; Pazzani, M. J. User modeling for adaptive news access. *User Modeling and User-Adapted Interaction*, Springer Netherlands, v. 10, p. 147–180, 2000. ISSN 0924-1868.
- Blanco-Fernández, Y.; Pazos-Arias, J.; Gil-Solla, A.; Ramos-Cabrer, M.; Lopez-Nores, M. Providing entertainment by content-based filtering and semantic reasoning in intelligent recommender systems. *IEEE Transactions on Consumer Electronics*, v. 54, n. 2, p. 727–735, Maio 2008. ISSN 0098-3063.
- Blanco-Fernández, Y.; Pazos-Arias, J. J.; Nores, M. L.; Solla, A. G.; Cabrer, M. R. Avatar: an improved solution for personalized tv based on semantic inference. *IEEE Transactions on Consumer Electronics*, v. 52, n. 1, p. 223–231, Fevereiro 2006.
- Breitman, K. K. *Web semântica: a internet do futuro*. Rio de Janeiro, RJ: LTC Editora, 2005.
- Burke, R. Hybrid recommender systems: Survey and experiments. *User Modeling and User-Adapted Interaction*, Springer Netherlands, v. 12, p. 331–370, 2002. ISSN 0924-1868.
- Burke, R. Hybrid web recommender systems. In: *The adaptive web: methods and strategies of web personalization*. Alemanha: Springer-Verlag, 2007. (Lecture Notes in Computer Science, v. 4321), p. 377–408. ISBN 978-3-540-72078-2.
- Carroll, J. J.; Dickinson, I.; Dollin, C.; Reynolds, D.; Seaborne, A.; Wilkinson, K. Jena: implementing the semantic web recommendations. In: *Proceedings of the 13th international World Wide Web conference on Alternate track papers & posters*. New York, NY, EUA: ACM, 2004. (WWW Alt. '04), p. 74–83. ISBN 1-58113-912-8.
- Cesar, P.; Chorianopoulos, K. Interactivity and user participation in the television lifecycle: creating, sharing, and controlling content. In: *UXTV '08: Proceeding of the 1st international conference on designing interactive user experiences for TV and video*. New York, NY, EUA: ACM, 2008. p. 125–128. ISBN 978-1-60558-100-2.
- Chorianopoulos, K.; Lekakos, G. Learn and play with interactive tv. *Computers in Entertainment*, ACM, New York, NY, EUA, v. 5, n. 2, p. 4, 2007. ISSN 1544-3574.
- Coelho, A. S. S. *ProfileTV: Um sistema de gerenciamento de perfis em TVDi*. Dissertação (Mestrado) — Universidade Federal de Pernambuco, 2008.
- Collins, A. M.; Loftus, E. F. A spreading-activation theory of semantic processing. *Psychological Review*, v. 82, n. 6, p. 407–428, Novembro 1975.
- Corcho, O.; Fernández-López, M.; Gómez-Pérez, A. Methodologies, tools and languages for building ontologies. where is their meeting point? *Data & Knowledge Engineering*, v. 46, n. 1, p. 41–64, 2003. ISSN 0169-023X.
- Das, A. S.; Datar, M.; Garg, A.; Rajaram, S. Google news personalization: scalable online collaborative filtering. In: *WWW '07: Proceedings of the 16th international conference on World Wide Web*. New York, NY, EUA: ACM, 2007. p. 271–280. ISBN 978-1-59593-654-7.

- Datafolha. *Hábitos de consumo no mercado de entretenimento*. Agosto 2008. Disponível em [http://sedcmrj.locaweb.com.br/pesquisa/pesquisa\\_habitos\\_consumo\\_agos\\_to2008.pdf](http://sedcmrj.locaweb.com.br/pesquisa/pesquisa_habitos_consumo_agos_to2008.pdf). Último acesso: Novembro de 2010.
- Decker, S.; Melnik, S.; van Harmelen, F.; Fensel, D.; Klein, M.; Broekstra, J.; Erdmann, M.; Horrocks, I. The semantic web: the roles of xml and rdf. *IEEE Internet Computing*, v. 4, n. 5, p. 63–73, Setembro 2000. ISSN 1089-7801.
- Deshpande, M.; Karypis, G. Item-based top-n recommendation algorithms. *ACM Transactions on Information Systems (TOIS)*, v. 22, n. 1, p. 143–177, Janeiro 2004. ISSN 1046-8188.
- Dias, J. M. *Aplicação de filtragem Colaborativa na recomendação de conteúdo para TV digital*. Monografia (Ciência da Computação) – Universidade Federal de Itajubá, 2010.
- DVB. *DVB - Digital Video Broadcasting*. 2009. Disponível em <http://www.dvb.org/>. Último acesso: Novembro de 2010.
- ETSI. *ETSI TS 102 543 V1.1.1 - Digital Video Broadcasting (DVB); Globally Executable MHP (GEM) Specification 1.2*. França, Março 2008.
- Fensel, D. *Ontologies: A silver bullet for knowledge management and electronic commerce*. 2nd. ed. Alemanha: Springer, 2004.
- Fensel, D.; van Harmelen, F.; Horrocks, I.; McGuinness, D. L.; Patel-Schneider, P. F. Oil: an ontology infrastructure for the semantic web. *IEEE Intelligent Systems*, v. 16, n. 2, p. 38–45, Março 2001. ISSN 1541-1672.
- Fernández, M.; Perez, A. G.; Juristo, N. Methontology: from ontological art towards ontological engineering. In: *Proceedings of the AAAI97 Spring Symposium*. Stanford, EUA: Stanford University, 1997. p. 33–40.
- Gómez-Pérez, A.; Corcho, O. Ontology languages for the semantic web. *IEEE Intelligent Systems*, v. 17, n. 1, p. 54–60, Janeiro 2002. ISSN 1541-1672.
- Gruber, T. R. A translation approach to portable ontology specifications. *Knowledge Acquisition*, Academic Press Ltd., London, UK, UK, v. 5, n. 2, p. 199–220, 1993. ISSN 1042-8143.
- Grüninger, M.; Fox, M. Methodology for the design and evaluation of ontologies. In: *IJCAI'95, Workshop on Basic Ontological Issues in Knowledge Sharing*. Montreal, Quebec, Canada: AAAI Press, 1995.
- Gutiérrez, I. C. *Exploiting the conceptual space in hybrid recommender systems: semantic-based approach*. Tese (Doutorado) — Universidad Autonoma de Madrid, Outubro 2008.
- Hartley, R. T.; Barnden, J. A. Semantic networks: visualizations of knowledge. *Trends in Cognitive Sciences*, v. 1, n. 5, p. 169–175, 1997. ISSN 1364-6613.
- Heflin, J.; Hendler, J.; Luke, S. *SHOE: A knowledge representation language for internet applications*. Maryland, EUA, 1999.
- Hölbling, G.; Pleschgatterrig, M.; Kosch, H. PersonalTV. *Multimedia Tools Appl.*, Kluwer Academic Publishers, Hingham, MA, EUA, v. 46, n. 2-3, p. 259–288, 2010. ISSN 1380-7501.
- Horrocks, I. Daml+oil: A reason-able web ontology language. In: *Advances in Database Technology - EDBT 2002*. Alemanha: Springer Berlin / Heidelberg, 2002, (Lecture Notes in Computer Science, v. 2287). p. 103–116.

- Horrocks, I.; Patel-Schneider, P. F.; van Harmelen, F. From shiq and rdf to owl: the making of a web ontology language. *Web Semantics: Science, Services and Agents on the World Wide Web*, v. 1, n. 1, p. 7–26, 2003. ISSN 1570-8268.
- Huang, Z.; Chen, H.; Zeng, D. Applying associative retrieval techniques to alleviate the sparsity problem in collaborative filtering. *ACM Transactions on Information Systems*, ACM, New York, NY, EUA, v. 22, p. 116–142, Janeiro 2004. ISSN 1046-8188.
- Huang, Z.; Zeng, D.; Chen, H. A comparison of collaborative-filtering recommendation algorithms for e-commerce. *IEEE Intelligent Systems*, v. 22, n. 5, p. 68–78, Setembro 2007. ISSN 1541-1672.
- Hussein, T.; Neuhaus, S. Explanation of spreading activation based recommendations. *Semantic Models for Adaptative Interactive (SEMAIS)*, 2010.
- Hussein, T.; Ziegler, J. Adapting web sites by spreading activation in ontologies. In: *Proceedings of the International Workshop on Recommendation and Collaboration (ReColl)*. New York, NY, EUA: ACM, 2008.
- IBGE. *Pesquisa Nacional por Amostra de Domicílios 2008-2009*. 2009. Disponível em [http://www.ibge.gov.br/home/estatistica/populacao/trabalhoerendimento/pnad2009/tabelas\\_pdf/sintese\\_ind\\_6\\_4.pdf](http://www.ibge.gov.br/home/estatistica/populacao/trabalhoerendimento/pnad2009/tabelas_pdf/sintese_ind_6_4.pdf). Último acesso: Novembro de 2010.
- ITU. *H.761: Nested context language (NCL) and Ginga-NCL for IPTV services*. Abril 2009. Disponível em <http://www.itu.int/rec/T-REC-H.761>. Último acesso: Novembro de 2010.
- Johnson-Laird, P. N.; Herrmann, D. J.; Chaffin, R. Only connections: A critique of semantic networks. *Psychological Bulletin*, v. 96, n. 2, p. 292–315, 1984. ISSN 0033-2909.
- Jones, D.; Bench-Capon, T.; Visser, P. Methodologies for ontology development. In: *IT & Knows information technologies and knowledge systems*. Viena, Áustria: OCG, 1998. p. 62–75.
- Karp, P. D.; Chaudhri, V. K.; Thomere, J. *XOL: An XML-Based Ontology Exchange Language*. Agosto 1999. Disponível em <http://www.ai.sri.com/~pkarp/xol/xol.html>. Último acesso: Novembro de 2010.
- Korenus, T.; Laurikkala, J.; Juhola, M. On principal component analysis, cosine and euclidean measures in information retrieval. *Information Sciences*, v. 177, n. 22, p. 4893–4905, 2007. ISSN 0020-0255.
- LAViD. *LAViD. Laboratório de aplicações de vídeo digital*. 2009. Disponível em <http://www.lavid.ufpb.br/>. Último acesso: Novembro de 2010.
- LAViD; Telemidia. *Ginga digital TV middleware specification*. 2009. Disponível em <http://www.ginga.org.br/>. Último acesso: Novembro de 2010.
- Lee, W. S. Collaborative learning and recommender systems. In: *ICML '01: Proceedings of the Eighteenth International Conference on Machine Learning*. San Francisco, CA, EUA: Morgan Kaufmann Publishers Inc., 2001. p. 314–321. ISBN 1-55860-778-1.
- Linden, G.; Smith, B.; York, J. Amazon.com recommendations: Item-to-item collaborative filtering. *IEEE Internet Computing*, IEEE Computer Society, Los Alamitos, CA, EUA, v. 7, p. 76–80, 2003. ISSN 1089-7801.
- Lucas, A. S.; Zorzo, S. D. Personalização para televisão digital utilizando a estratégia de sistema de recomendação para ambientes multiusuários. *27º Simpósio brasileiro de redes de computadores e sistemas distribuídos*, p. 641–654, 2009.

- Maia, P. P. C.; Leite, J.; Batista, T. Mypersonal-epg: Um epg personalizável e com suporte à recomendação. In: *XVI Simpósio Brasileiro de Sistema Multimídia e Web*. Porto Alegre, RS: Sociedade Brasileira de Computação, 2010. p. 51–58.
- McGuinness, D. L.; Fikes, R.; Hendler, J.; Stein, L. A. Daml+oil: an ontology language for the semantic web. *IEEE Intelligent Systems*, v. 17, n. 5, p. 72–80, Setembro 2002. ISSN 1541-1672.
- Montez, C.; Becker, V. *TV Digital Interativa: conceitos, desafios e perspectivas para o Brasil*. 2. ed. Florianópolis: Ed. da UFSC, 2005.
- Moreno, M. F.; Soares Neto, C. S.; Soares, L. F. G. Adaptable software components in an electronic program/service guide application architecture for context aware guide presentation. *International Journal of Advanced Media and Communication*, v. 3, n. 4, p. 351–364, 2009.
- Morris, S.; Smith-Chaigneau, A. *Interactive TV Standards*. EUA: Elsevier, 2005. ISSN 0-240-80666-2.
- Naudet, Y.; Aghasaryan, A.; Toms, Y.; Senot, C. An ontology-based profiling and recommending system for mobile tv. In: *SMAP '08: Proceedings of the 2008 Third International Workshop on Semantic Media Adaptation and Personalization*. Washington, DC, EUA: IEEE Computer Society, 2008. p. 94–99. ISBN 978-0-7695-3444-2.
- Nelson, M. R. We have the information you want, but getting it will cost you!: held hostage by information overload. *Crossroads*, ACM, New York, NY, EUA, v. 1, n. 1, p. 11–15, 1994. ISSN 1528-4972.
- Noy, N. F.; McGuinness, D. L. *Ontology Development 101: A Guide to Creating Your First Ontology*. Stanford, EUA, 2001.
- Oliveira, M.; Cunha, P. R. F. Implementing the brazilian digital tv. In: *22ème Congrès DNAC: De Nouvelles Architectures pour les Communications*. Paris, França: DNAC, 2008.
- Pazzani, M. J. A framework for collaborative, content-based and demographic filtering. *Artificial Intelligence Review*, Springer Netherlands, v. 13, p. 393–408, 1999. ISSN 0269-2821.
- Pinto, H. S.; Martins, J. P. Ontologies: How can they be built? *Knowledge and Information Systems*, Springer London, v. 6, p. 441–464, 2004. ISSN 0219-1377.
- Preece, S. E. *A spreading activation network model for information retrieval*. Tese (Doutorado), Champaign, IL, EUA, 1981.
- Reategui, E. B.; Cazella, S. C. Sistemas de recomendação. In: V Encontro Nacional de Inteligência Artificial. *XXV Congresso da Sociedade Brasileira de Computação*. São Leopoldo, RS: Sociedade Brasileira de Computação, 2005. p. 306–348.
- República, P. da. *Decreto Nº 4.901*. 2003. Diário Oficial da União de 26 de novembro de 2003, p. 7. Disponível em [http://www.planalto.gov.br/ccivil\\_03/decreto/2003/D4901.htm](http://www.planalto.gov.br/ccivil_03/decreto/2003/D4901.htm). Último acesso: Novembro de 2010.
- República, P. da. *Decreto Nº. 5.820*. 2006. Diário Oficial da União de 30 de junho de 2006, p. 51. Disponível em [http://www.planalto.gov.br/ccivil\\_03/\\_Ato2004-2006/2006/Decreto/D5820.htm](http://www.planalto.gov.br/ccivil_03/_Ato2004-2006/2006/Decreto/D5820.htm). Último acesso: Novembro de 2010.
- Richer, M. S.; Reitmeier, G.; Gurley, T.; Jones, G. A.; Whitaker, J.; Rast, R. The atsc digital television system. In: *Proceedings of the IEEE*. EUA: IEEE, 2006. v. 94, n. 1, p. 37–43. ISSN 0018-9219.

- Rodrigues, R. F.; Soares, L. F. G. Produção de conteúdo declarativo para tv digital. *Anais do Seminário Integrado de Software e Hardware (SEMISH)*, 2006.
- Roth, V. Content-based retrieval from digital video. *Image and Vision Computing*, v. 17, n. 7, p. 531–540, 1999. ISSN 0262-8856.
- Sarwar, B.; Karypis, G.; Konstan, J.; Reidl, J. Item-base collaborative filtering recommendation algorithms. *Proceedings of the 10th International conference on World Wide Web*, p. 285–295, 2001.
- Schafer, J. B.; Konstan, J.; Riedi, J. Recommender systems in e-commerce. In: *EC '99: Proceedings of the 1st ACM conference on Electronic commerce*. New York, NY, EUA: ACM, 1999. p. 158–166. ISBN 1-58113-176-3.
- Serpa, D. R.; Chaves, A. A.; Corrêa, F. de A.; Lorena, L. A. N. Problemas de agrupamentos: Uma abordagem via pesquisa em vizinhança variável (vns). In: *X Workshop dos Cursos de Computação Aplicada do INPE. Anais do X Workshop dos Cursos de Computação Aplicada do INPE*. São José dos Campos, SP: INPE, 2010.
- Silva, G.; Baldochi, L. A. A semantic-based recommender system for the sbtvd. In: *Proceedings of the IADIS International Conference Applied Computing 2010*. Timisoara, Romênia: IADIS Press, 2010. p. 111–118.
- Simons, R. F. *Semantic networks: Their computation and use for understanding english sentences*. Austin, Texas, EUA, Maio 1972.
- Soares, L.; Moreno, M.; Costa, R. de R.; Moreno, M. Towards the convergence of digital tv systems. *Journal of Internet Services and Applications*, Springer London, v. 1, p. 69–79, 2010. ISSN 1867-4828.
- Soares, L. F. G.; Rodrigues, R. F.; Moreno, M. F. Ginga-ncl: the declarative environment of the brazilian digital tv system. *Journal of the Brazilian Computer Society*, v. 12, n. 4, p. 37–46, 2007. ISSN 0104-6500.
- Souza Filho, G. L.; Leite, L. E. C.; Batista, C. E. C. F. Ginga-j: The procedural middleware for the brazilian digital tv system. *Journal of the Brazilian Computer Society*, v. 12, n. 4, p. 47–56, 2007. ISSN 0104-6500.
- Sowa, J. F. Semantic networks. In: Shapiro, S. C. (Ed.). *Encyclopedia of Artificial Intelligence*. New York, NY, EUA: John Wiley & Sons, 1987.
- Studer, R.; Benjamins, V. R.; Fensel, D. Knowledge engineering: Principles and methods. *Data & Knowledge Engineering*, v. 25, n. 1-2, p. 161–197, 1998. ISSN 0169-023X.
- Takada, M.; Saito, M. Transmission system for isdb-t. In: *Proceedings of the IEEE*. EUA: IEEE, 2006. p. 251–256. ISSN 0018-9219.
- Telemidia. *Laboratório TeleMídia*. 2009. Disponível em <http://www.telemidia.puc-rio.br/pt/index.html>. Último acesso: Novembro de 2010.
- Terveen, L.; Hill, W. Beyond recommender systems: helping people help each other. *HCI in the new millenium Addison Wesley*, Citeseer, n. 1, p. 487–509, 2001.
- Uschold, M.; Grüninger, M. Ontologies: principles, methods, and applications. *Knowledge Engineering Review*, v. 11, n. 2, p. 93–155, 1996.

Xu, J.; Zhang, L.-J.; Lu, H.; Li, Y. The development and prospect of personalized tv program recommendation systems. In: *Proceedings of Fourth International Symposium on Multimedia Software Engineering*. Newport Beach, California, EUA: IEEE, 2002. p. 82–89.

Yang, C.-S.; Wang, P.-C.; Lin, C.-L.; Hou, T.-W. Personalized idtv program in multimedia home platform. *22nd International Conference on Advanced Information Networking and Applications - Workshops*, p. 473–476, Março 2008.