

UNIVERSIDADE FEDERAL DE SÃO CARLOS  
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM  
CIÊNCIA DA COMPUTAÇÃO

Personalização para Televisão Digital utilizando a estratégia de  
Sistema de Recomendação para ambientes multiusuário

Adriano dos Santos Lucas

São Carlos-SP  
Junho/2009

Adriano dos Santos Lucas

Personalização para Televisão Digital utilizando a estratégia de  
Sistema de Recomendação para ambientes multiusuário

*DISSERTAÇÃO DE MESTRADO APRESENTADA  
AO PROGRAMA DE PÓS-GRADUAÇÃO EM  
CIÊNCIA DA COMPUTAÇÃO DO CENTRO DE  
CIÊNCIAS EXATAS E DE TECNOLOGIA DA  
UNIVERSIDADE FEDERAL DE SÃO CARLOS  
COMO PARTE DOS REQUISITOS PARA  
OBTENÇÃO DO TÍTULO DE MESTRE EM  
CIÊNCIA DA COMPUTAÇÃO, ÁREA DE  
CONCENTRAÇÃO: SISTEMAS DISTRIBUÍDOS E  
REDES.*

Orientador:  
Prof. Dr. Sergio Donizetti Zorzo

São Carlos-SP  
Junho/2009

**Ficha catalográfica elaborada pelo DePT da  
Biblioteca Comunitária da UFSCar**

L933pt

Lucas, Adriano dos Santos.

Personalização para televisão digital utilizando a estratégia de sistema de recomendação para ambientes multiusuário / Adriano dos Santos Lucas. -- São Carlos : UFSCar, 2010.  
83 f.

Dissertação (Mestrado) -- Universidade Federal de São Carlos, 2009.

1. Sistemas de recomendação. 2. Televisão digital. 3. Privacidade e personalização. I. Título.

CDD: 003.7 (20<sup>a</sup>)

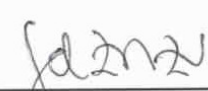
**Universidade Federal de São Carlos**  
**Centro de Ciências Exatas e de Tecnologia**  
**Programa de Pós-Graduação em Ciência da Computação**


“Personalização para Televisão Digital utilizando  
a estratégia de Sistema de Recomendação  
para Ambientes Multi-usuário”

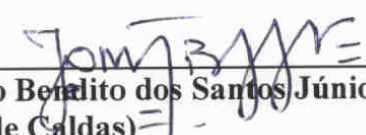
**ADRIANO DOS SANTOS LUCAS**

Dissertação de Mestrado apresentada ao  
Programa de Pós-Graduação em Ciência da  
Computação da Universidade Federal de São  
Carlos, como parte dos requisitos para a  
obtenção do título de Mestre em Ciência da  
Computação

**Membros da Banca:**

  
\_\_\_\_\_  
**Prof. Dr. Sérgio Donizetti Zorzo**  
(Orientador - DC/UFSCar)

  
\_\_\_\_\_  
**Prof. Dr. Luis Carlos Trevelin**  
(DC/UFSCar)

  
\_\_\_\_\_  
**Prof. Dr. João Benedito dos Santos Júnior**  
(PUC-Poços de Caldas)

São Carlos  
Junho/2009

*Dedico esta dissertação primeiramente a Deus, que por meio da sua eterna misericórdia me sustentou e me deu forças para concluir mais essa etapa da minha vida. Posteriormente aos meus pais Silas e Dolores, irmãos Aduino e Andréia, pelo incentivo e apoio. Aos amigos, professores e orientador. Enfim, a todos que participaram deste momento da minha vida que com a graça de Deus está se completando.*

## **AGRADECIMENTOS**

Agradeço a Deus por sempre estar ao meu lado e que nessa etapa da minha vida me deu vitórias e me confortou nos momentos de adversidades. Se não fosse por Ele, não teria superado essa etapa. Por isso, toda a honra e toda a glória sejam dadas a Ele.

Agradeço à minha família, em especial aos meus pais Silas e Dolores. Diz o ditado “toda mãe é igual, só muda de endereço”, mas minha mãe e meu pai são diferentes e únicos, eu os amo. Eles não mediram esforços e mesmo não podendo, sempre davam um jeito de me ajudar financeiramente e também com conselhos. Ao meu irmão Adauto por sempre apoiar os meus estudos e à minha irmã Andréia, que não mediu esforços e me ajudou muito. Por ser professora de inglês, foi providencial nas confecções dos artigos. Se não fosse você querida irmã, esta etapa teria sido muito mais difícil.

Ao meu orientador Sérgio Donizetti Zorzo, que me confiou fazer esse mestrado e sempre acreditou em mim.

Aos meus amigos de laboratório e preciso citá-los, pois cada um foi fundamental na convivência como família neste período do mestrado. Quero agradecer a duas pessoas que são amigos tão chegados como irmãos, Filipe e Thiago. Também gostaria de agradecer aos amigos de laboratório Cláudio, Mariana, Erlon, Danilo, David, e aos novos alunos Ricardo e Jesus. Além desses, gostaria de mencionar os amigos Rafael Miami, Thiago Siqueira, Ana Paula e Kamila. Eu arrisquei citar os nomes e caso tenha esquecido algum, deixo aqui meu muito obrigado.

A Tia Verinha, sempre sorridente e de bem com a vida. A Cristina, que em todo o período do mestrado teve paciência para nos agüentar, a cada vez que íamos entregar ou pedir documentos.

Ao pessoal do Sob Controle – Grupo de jovens da Primeira Igreja Batista de Marília, em especial ao futuro médico e grande homem de Deus Fábio Araujo Pereira e o Rubens Goulart Domingues (Rubinho) pessoa ungida de Deus, que quando eu estava com problemas e desanimado, me sustentaram em oração.

Ao meu amigo de graduação Rodrigo Fogaça Miguel. Fomos parceiros na época da graduação e mesmo nos separando, sempre nos falamos e trocamos conselhos. Obrigado pela sua amizade e pela força para continuar e concluir essa etapa.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Capes), pelo apoio financeiro para o desenvolvimento deste trabalho.

À Financiadora de Estudos e Projetos (FINEP), que financiou o projeto N° 01.07.0110.00, “Avaliação do Middleware Ginga”.

Enfim, agradeço a todos que, direta ou indiretamente, contribuíram para a realização deste trabalho. Muito obrigado por toda a ajuda e compreensão.

*“Ainda que a minha mente e o meu corpo enfraqueçam, Deus é minha força ele é tudo o  
que sempre preciso”  
Salmo 73,26*

*“Não são os grandes homens que transformam o mundo, mas os homens fracos nas mãos  
do grande Deus.”  
Pastor Domingos Jardim da Silva*

*"Se você encontrar um caminho sem obstáculos ele provavelmente não o levará a lugar  
nenhum".  
Frank A. Clark*



## Resumo

O sistema de Televisão Digital (TVD) proporciona aumento da oferta de conteúdo, ganhos em qualidade de vídeo e áudio e possibilidades de serviços e aplicações em relação ao sistema tradicional. Dentre as possibilidades de aplicações para esta tecnologia, destacam-se os sistemas capazes de realizar recomendações de conteúdos conforme o interesse dos telespectadores, denominados sistemas de recomendação. Estes oferecem um serviço diferenciado de personalização, além de ser uma possível solução para a sobrecarga de informação causada pela grande oferta de conteúdo, a qual dificulta a busca e localização de programas de interesse do telespectador. A personalização de conteúdo deve considerar o ambiente multiusuário, ou seja, a presença de diversos telespectadores que utilizam o mesmo receptor. Assim, este trabalho apresenta um sistema de recomendação para ambientes multiusuário, o RePTVD (Recomendação Personalizada para Televisão Digital) que recomenda conteúdo de acordo com os padrões de comportamento de uso da televisão e possui arquitetura residente no *Set-top Box*. Para isso, foi utilizada a coleta implícita e armazenamento de informações, em seguida a mineração de dados com adoção do algoritmo Apriori e finalmente a filtragem de informação. A associação destas técnicas resultou no processo de recomendação apresentado, o qual aborda todos os passos necessários para efetuar a recomendação de conteúdo. A implementação da proposta foi realizada como prova de conceito e para isso, foi utilizada a API Java TV por ser uma linguagem específica para TVD e evidenciar a portabilidade do sistema. Além disso, foram observadas características do padrão brasileiro que tem o Ginga como *middleware*, o qual é responsável pela execução de aplicações. A avaliação foi feita por um experimento, no qual foram utilizados dados fornecidos pelo IBOPE referentes ao comportamento de visualização de seis domicílios coletados durante quatorze dias. Os resultados obtidos indicaram a eficácia e qualidade da implementação do sistema RePTVD.

## **Abstract**

*The Digital Television system (TVD) increases the content offer, the audio and video quality and the possibility of services and applications when compared to traditional systems. Among the possibilities of application for this technology, we can highlight the systems able to perform recommendations of content according to the viewer's interests, these systems are called recommendation systems. Besides offering a different personalization service, the recommendation systems can be a solution to the information overload caused by offering possible content, what makes difficult the search and localization of programs according to the viewer's interest. Multiuser environment must be taken into account when offering the TVD viewer content personalization, that is, many viewers using the same receptor. This dissertation presents a recommendation system for multiuser environments, the RePTVD (Personalized Recommendation for Digital Television), with its architecture in the Set-top Box. The RePTVD aims at recommending content according to the behavior standards implicitly found when using the television. Therefore, information was implicitly collected and stored, data mining was performed using Apriori algorithm and finally information was filtered. A composition of these stages was presented using a recommendation process which approaches all the necessary steps to perform the content recommendation. Due to the fact that this is a specific language to TVD and aiming the system portability, API Java TV was used to implement the proposal as a concept proof. Besides that, we could note Brazilian-standard characteristics which have Ginga as the middleware responsible for the applications performance. The evaluation was performed through a test in which data provided by IBOPE Brazilian institute was used concerning the viewing behavior from six houses collected during 14 days. The results indicated the efficiency and quality of RePTVD system implementation.*

## **Lista de Abreviaturas e Siglas**

8-VSB: 8 Level - Vestigial Side Band Modulation  
ABNT: Associação Brasileira de Normas Técnicas  
ACAP-X: Advanced Common Application Platform  
ANN: Artificial Neural Networks  
API: Application Programming Interface  
Arff: Attribute-Relation File Format  
ARIB: Association of Radio Industries and Businesses  
ATSC: Advanced Television Systems Committee  
AVC: Advanced Video Coding  
BPN: Back Propagation Network  
BML: Broadcast Markup Language  
CDC: Connected Device Configuration  
COFDM: Coded Orthogonal Frequency Division Multiplexing  
CSS: Cascading Style Sheets  
DASE: Digital Applications Software Environment  
DAVIC: Digital Audio Visual Council  
DSM-CC: Digital Storage Media - Command and Control  
DVB: Digital Video Broadcasting  
EIT: Event Information Table  
EPG: Eletronic Program Guide  
ES: Elementary Stream  
GEM: Globally Executable MHP  
GNU: General Public License  
HAVi: Home Audio Video Interoperability  
HDTV: High-Definition Television  
HTML: HyperText Markup Language  
IA: Inteligência Artificial  
IHC: Interface Humano-Computador  
ISDB: Integrated Services Digital Broadcasting  
ISDB-T: Terrestrial Integrated Services Digital Broadcasting  
ISDTV-T: International Standard for Digital Television Terrestrial  
JPEG: Joint Photographic Experts Group

JVM: Java Virtual Machine  
JME: Java Micro Edition  
KDD: Knowledge Discovery in Database  
LHS: Left Hand Side  
MA - Machine Learning  
MHP: Multimedia Home Platform  
MPEG: Moving Picture Experts Group  
NCL: Nested Context Language  
OCAP: OpenCable Applications Platform  
PDR: Personal Digital Recorder  
PNG: Portable Network Graphics  
PSI: Program Specific Information  
RHS: Right Hand Side  
SBTVD: Sistema Brasileiro de Televisão Digital  
SDT: Service Description Table  
SDTV: Standard Definition Television  
SI: Service Information  
STB: Set-top Box  
TDT: Time and Date Table  
TS: Transport Stream  
TV: Televisão  
TVD: Televisão Digital  
TVDI: Televisão Digital Interativa  
Weka: Waikato Environment for Knowledge Analysis  
XML: eXtensible Markup Language  
XHTML: eXtensible Hypertext Markup Language.

## Lista de figuras

Figura 1 - Modelo de referência em blocos de um sistema de TVD genérico (CAVALCANTI, 2005) .....	6
Figura 2 - Comparação entre os sistemas de televisão digital .....	7
Figura 3 - Arquitetura do modelo de referência do ISDTV-T (COMUNIDADE GINGA, 2009).....	9
Figura 4 - Arquitetura Ginga (ABNT NBR 15606-5, 2008) .....	10
Figura 5 - Arquitetura Ginga Common-Core (COMUNIDADE GINGA, 2009) .....	10
Figura 6 - Arquitetura Ginga-J e ambiente de execução (SOUZA <i>et al.</i> , 2007) .....	12
Figura 7 - Relacionamento do GEM com os <i>middlewares</i> (LEITE <i>et al.</i> , 2005).....	13
Figura 8 - APIs verde, amarela e azul do Ginga-J (SOUZA; LEITE; BATISTA, 2007)....	14
Figura 9 – Xlets e Gerente de Aplicações (MONTEZ; BECKER, 2005) .....	16
Figura 10 - Ciclo de vida de um Xlet (FERNANDES; LEMOS; SILVEIRA, 2004) .....	17
Figura 11 - Processo de transmissão e recepção de TVD (BARBOSA; SOARES, 2008)..	18
Figura 12 - Esquema do processo de KDD (FAYYAD; PIATETSKY-SHAPIRO; SMITH, 1996).....	27
Figura 13 - Algoritmo Apriori. ....	32
Figura 14 - Cabeçalho de um arquivo ARFF .....	34
Figura 15 - Informações dos dados de um arquivo ARFF .....	34
Figura 16 – Sequência de execução dos módulos .....	35
Figura 17 - Módulos do sistema RePTVD .....	38
Figura 18 - Extração dos metadados .....	39
Figura 19 - Informações dos telespectadores .....	41
Figura 20 - Descoberta de informações úteis .....	42
Figura 21 - Filtragem de informação .....	42
Figura 22 - Mecanismo do RePTVD .....	43
Figura 23 – Informações sobre o comportamento de visualização armazenado .....	44
Figura 24 - Arquivo com frequência das categorias.....	45
Figura 25 - Regras descobertas pelo algoritmo Apriori .....	48
Figura 26 - Tela inicial do emulador XletView.....	50
Figura 27 - Diagrama de classes do módulo de metadados e armazenamento das informações .....	51

Figura 28 - Arquivo com metadados .....	52
Figura 29 - Diagrama de classes mineração e filtragem de informação.....	53
Figura 30 - Diagrama de classes da interface do sistema.....	54
Figura 31 - Interface inicial do sistema RePTVD .....	55
Figura 32 - Guia de programação de cada canal .....	55
Figura 33 - Lista de recomendações sugeridas.....	56
Figura 34 - Interface de saída do sistema .....	56

## **Lista de Tabelas**

Tabela 1 - Pacotes da API Java TV e suas respectivas funções (SUN, 2006).....	15
Tabela 2 - Exemplo da coleta do comportamento do uso da TV .....	45
Tabela 3 - Cálculo de FSup para os dados da Tabela 2.....	46

## Lista de Gráficos

Gráfico 1- Faixa etária dos membros dos grupos de telespectadores.....	58
Gráfico 2 - Divisão do sexo em relação ao grupo .....	58
Gráfico 3 - Classe social.....	58
Gráfico 4 - Grau de instrução do chefe da casa.....	59
Gráfico 5 - Precisão do RePTVD .....	60
Gráfico 6 - Precisão do RePTVD na primeira semana.....	60
Gráfico 7 - Precisão do RePTVD na segunda semana .....	60
Gráfico 8 - Índice de aceitação na primeira semana.....	61
Gráfico 9 - Índice de aceitação na segunda semana .....	61
Gráfico 10 - Índice de aceitação durante as duas semanas.....	62



# Sumário

<i>Lista de Abreviaturas e Siglas</i>	<i>x</i>
<i>Lista de figuras</i>	<i>xii</i>
<i>Lista de Tabelas</i>	<i>xiv</i>
<b>1</b> <i>Introdução</i>	<b>1</b>
1.1 <b>Objetivos</b>	<b>4</b>
1.2 <b>Motivação</b>	<b>4</b>
1.3 <b>Organização do Trabalho</b>	<b>4</b>
<b>2</b> <i>Televisão Digital</i>	<b>5</b>
2.1 <b>Sistema Brasileiro de Televisão Digital</b>	<b>7</b>
2.2 <b>API Java TV</b>	<b>15</b>
2.3 <b>Transmissão do sinal de TVD</b>	<b>17</b>
<b>3</b> <i>Personalização na Televisão Digital</i>	<b>21</b>
3.1 <b>Sistema de Recomendação</b>	<b>22</b>
3.2 <b>Técnicas de Filtragem aplicadas a Sistema de Recomendação</b>	<b>24</b>
3.2.1 <b>Filtragem Colaborativa</b>	<b>25</b>
3.2.2 <b>Filtragem baseada em conteúdo</b>	<b>25</b>
3.2.3 <b>Filtragem híbrida</b>	<b>26</b>
3.3 <b>Descoberta de Conhecimento</b>	<b>26</b>
3.3.1 <b>Mineração de Dados</b>	<b>28</b>
3.3.2 <b>Regras de associação</b>	<b>30</b>
3.3.3 <b>WEKA</b>	<b>33</b>
<b>4</b> <i>Sistema de Recomendação para ambientes multiusuário</i>	<b>35</b>
4.1 <b>Sistema RePTVD</b>	<b>37</b>
4.1.1 <b>Arquitetura do RePTVD</b>	<b>38</b>
4.1.2 <b>Módulo Metadados</b>	<b>39</b>
4.1.3 <b>Módulo Perfil do Grupo de Telespectadores</b>	<b>40</b>
4.1.4 <b>Módulo Recomendador</b>	<b>41</b>
4.2 <b>Processo de Recomendação</b>	<b>43</b>
<b>5</b> <i>Implementação do Sistema RePTVD</i>	<b>50</b>
<b>6</b> <i>Experimento e Resultados</i>	<b>57</b>
6.1 <b>Descrição do experimento realizado</b>	<b>57</b>
6.2 <b>Resultados</b>	<b>59</b>
<b>7</b> <i>Trabalhos Relacionados</i>	<b>64</b>
7.1 <b>AIMED – Um Sistema de Recomendação Personalizado</b>	<b>64</b>
7.2 <b>The iMEDIA System</b>	<b>65</b>
7.3 <b>TV3P: Um assistente adaptativo para personalização na TV</b>	<b>66</b>

7.4	TV program recommendation for multiple viewers based on user profile merging_	67
7.5	Personalization: Improving Ease-of-Use, Trust and Accuracy of a TV Show Recommender _____	68
7.6	Interactive Television Personalization: From Guides to Programs _____	69
7.7	Unobtrusive Dynamic Modelling of TV Program Preferences _____	70
7.8	FIT-recommending TV programs to family member _____	71
7.9	Observações Finais _____	72
<b>8</b>	<b>Conclusões e Trabalhos Futuros _____</b>	<b>73</b>
	<b>Referências Bibliográficas _____</b>	<b>75</b>

# 1 Introdução

Desde o seu surgimento, a televisão (TV) tem se consolidado como o mais importante meio de comunicação. Com a implantação da televisão digital (TVD), surge uma nova perspectiva em relação ao uso da TV, pois os telespectadores podem interagir com a programação e também com os novos aplicativos que serão disponibilizados. Com estes aplicativos é possível oferecer diversos serviços como compras, acesso ao banco, exibição de publicidade personalizada de acordo com preferências e características do telespectador, armazenamento de informações do telespectador para prover personalização, entre outros (LUCAS; ZORZO, 2009a).

A tecnologia de TVD gera um aumento da oferta de conteúdo devido à possibilidade das emissoras transmitirem simultaneamente mais de um programa. Este aumento faz com que os telespectadores, ao utilizarem esta tecnologia, encontrem uma grande variedade de conteúdos e recebam uma sobrecarga de informação. Os países pioneiros na implantação da TVD enfrentam este problema, o que torna difícil e demorada a procura de programas favoritos (SILVA, 2005).

Para minimizar este problema, revistas impressas e o Guia Eletrônico de Programação (EPG – *Electronic Programm Guide*) são disponibilizados, porém, há perda de tempo na procura dos programas favoritos em ambos os métodos (ZHIWEN; XINGLSHE, 2004). Nesse cenário, a personalização tende a ser uma área de exploração, pois será capaz de identificar os perfis dos telespectadores e fornecer recursos personalizados e aplicações úteis, o que a torna relevante para o domínio da TVD.

Neste contexto, as pesquisas com foco em personalização dedicam-se ao desenvolvimento de sistema de recomendação de conteúdo, o qual é capaz de propor filmes, programas e anúncios publicitários que correspondam aos interesses dos telespectadores (CHORIANOPOULOS, 2008). Além do serviço de personalização, o sistema de recomendação também pode diminuir o problema de sobrecarga de informação ao refinar o conteúdo de forma inteligente. Assim, ajuda os telespectadores ou grupo destes a encontrar conteúdos televisivos que coincidam com as suas preferências.

Os sistemas de recomendação têm sido desenvolvidos para os três sistemas de TVD reconhecidos e adotados no mundo: o americano *Advanced Television System Committee* - ATSC (ATSC, 2006), o europeu *Digital Video Broadcast* - DVD (DVB, 2003) e o japonês

*Integrated Services Digital Broadcasting* - ISDB (ISDB, 1998). Em cada sistema de TVD desenvolvido foram consideradas as questões técnico-econômicas de cada país. No Brasil, a necessidade de padronizar a infra-estrutura de TVD fez com que o projeto SBTVD (Sistema Brasileiro de Televisão Digital) desse origem ao padrão brasileiro ISDTV-T (*International Standard for Digital Television Terrestrial*). No ISDTV-T foi adotada a modulação do padrão japonês ISDB-T (*Terrestrial Integrated Services Digital Broadcasting*) e criado um *middleware* denominado Ginga, no qual os aplicativos interativos serão executados (GINGA, 2008). Assim, é importante o planejamento e desenvolvimento de sistemas de recomendação que considerem as características inerentes ao sistema de TVD, como por exemplo, a forma de transmissão dos dados, o desenvolvimento de interface, a utilização de recursos do *Set-top Box* (STB), entre outros.

Para desenvolver um sistema de recomendação para TVD, é necessário priorizar métodos de modelagem para ambientes multiusuário, já que a TV é essencialmente um meio de informação coletivo e diversos sistemas de recomendação existentes para TVD não o fazem. Chorianopoulos (2008) evidencia a importância do processo de recomendação dentro de grupos, como de amigos e família. Deste modo, é interessante que as recomendações não sejam focadas no perfil de visualização de cada telespectador, mas sim no perfil de visualização do que tem sido visto pelo grupo, buscando distinguir os mesmos (LUCAS; ZORZO, 2009b). Essa característica foi relevada para a concepção da estratégia de personalização utilizada neste trabalho, já que este consiste em um sistema de recomendação de conteúdo para ambientes multiusuário. Sendo assim, os termos “ambiente multiusuário” e “grupo de telespectadores” foram utilizados para denominar um grupo de moradores que utiliza a TVD de um mesmo domicílio.

A maioria dos sistemas de recomendação desenvolvidos para TVD utiliza informações fornecidas pelos telespectadores para uma recomendação mais próxima dos seus interesses. É possível também obter um *feedback* explícito, ou seja, o telespectador pontua e classifica as recomendações, o que torna o sistema intrusivo. Assim, esses sistemas dependem da ação dos telespectadores para configurá-los com as suas preferências caso queiram receber recomendações de conteúdo de seus interesses. Deve-se ressaltar que alguns telespectadores podem não ter afinidade com sistemas computacionais ou simplesmente não querer gastar tempo para configurá-lo com as suas preferências (LUCAS; ZORZO,

2009a). O desafio deste trabalho foi propor uma abordagem que reflita as preferências dos telespectadores de forma totalmente implícita.

Diante disso, apresenta-se o sistema de recomendação RePTVD (Recomendação Personalizada para Televisão Digital) para oferecer personalização na TVD. Este considera as características da TVD como os metadados enviados pela emissora, dispositivos de entrada restritos e grupos de visualização, e pode ser mapeado para que seja acoplado no *middleware* Ginga, assunto que será abordado em seção posterior. O RePTVD oferece recomendações personalizadas de conteúdo para grupos de telespectadores e considera as preferências observadas anteriormente. Estas são coletadas de forma implícita e, a partir de tais informações, o sistema identifica diferentes padrões de comportamento dentro de um grupo e determina as melhores recomendações. Para descobrir os padrões de comportamento no histórico de visualização do grupo e demonstrar a viabilidade do processo de recomendação, utilizou-se a técnica de mineração de dados com uso do algoritmo *Apriori*, sendo esta uma das possibilidades para gerar conhecimento adicional (LUCAS; ZORZO, 2009a).

O propósito do sistema RePTVD não é identificar os membros de um grupo, mas sim os padrões de comportamento e tendências deste. Sendo assim, ao descobrir os padrões, é possível oferecer conteúdo adequado em determinados dias e horários, independente de quem esteja assistindo. Deste modo, o sistema se adapta e recomenda conteúdos seguindo o padrão de comportamento, mesmo com grupos heterogêneos. O RePTVD possui arquitetura local no STB, além de ser baseado somente em dados de cada casa e adaptar-se às práticas familiares.

O sistema é composto por três módulos responsáveis pela coleta e armazenamento de informações dos conteúdos televisivos (Módulo Metadados), coleta e armazenamento de informações dos telespectadores (Módulo Perfil do Grupo de Telespectadores) e descobertas de padrões de comportamento e filtragem de informação (Módulo Recomendador). A seção 4.2 detalha que a interligação destes módulos foi estruturada mediante um processo de recomendação proposto que conduz cada passo às recomendações.

## **1.1 Objetivos**

O objetivo deste trabalho é contribuir com a área de personalização na TVD, evidenciando o desenvolvimento de um novo aplicativo que considera as características inerentes deste domínio. Com este novo aplicativo, o trabalho também objetiva recomendar conteúdos para grupos de telespectadores de acordo com as preferências descobertas no histórico de visualização de cada casa, as quais são coletadas de maneira implícita.

## **1.2 Motivação**

A motivação deste trabalho se dá pelo fato da tecnologia de TVD ser recente no Brasil e estar em fase de implantação. Com isso, as pesquisas na área são relevantes, pois essa tecnologia estará presente em todo país nos próximos anos. Dentre os diversos serviços e aplicações possíveis neste trabalho, destaca-se o sistema de recomendação que, além de contemplar a personalização com o propósito de oferecer um serviço diferenciado, pode atenuar o problema de sobrecarga de informação. Sendo assim, o sistema proposto e sua implementação adéquam-se para tal propósito, além de servir como referência para outras abordagens e implementações.

## **1.3 Organização do Trabalho**

Este trabalho possui 8 capítulos que desenvolvem o assunto proposto.

No capítulo 2, são apresentados os conceitos de TVD, do padrão brasileiro ISDTV-T, da API Java TV e como é realizada a transmissão dos metadados. O capítulo 3 apresenta os conceitos sobre personalização na TVD com ênfase no sistema de recomendação e descoberta de conhecimento. No capítulo 4, são apresentados os passos para oferecer personalização no domínio de TVD e o sistema RePTVD. Também são descritos os módulos que compõem este sistema, sua arquitetura, e também o processo de recomendação. O capítulo 5 mostra como a implementação do sistema RePTVD foi realizada e os resultados da avaliação do sistema são evidenciados no capítulo 6. Alguns trabalhos que possuem intersecção com a proposta são apresentados no capítulo 7. As conclusões e trabalhos futuros são apresentados no capítulo 8.

## 2 Televisão Digital

Durante os últimos 50 anos houve poucas mudanças na TV. Uma delas foi a transição da TV preto e branco para a TV em cores, o que fez os telespectadores comprarem novos aparelhos. Atualmente, outra mudança significativa está acontecendo, a transição da TV convencional para tecnologia digital, que exigirá mais uma vez que novos equipamentos sejam adquiridos, tanto por parte dos emissores como dos telespectadores.

A tecnologia digital, diferentemente da tecnologia analógica que utiliza ondas eletromagnéticas para sua transmissão, utiliza a mesma linguagem dos computadores. Assim, a transmissão se dá pela transformação do som, imagem e dados em um código binário formado pelos dígitos 0 e 1. Desta maneira, esta tecnologia proporciona várias características, dentre elas, melhor qualidade de imagem e som e maior compressão do sinal, permitindo que um canal padrão de TV analógico de 6 MHz (largura de banda utilizada para a transmissão de canais de TV no Brasil) transmita até quatro programas simultaneamente. Isto é possível devido ao fato de não ocorrer interferência entre canais na modulação digital (FERNANDES; LEMOS; SILVEIRA, 2004; MONTEIRO, 2002). Outra característica é que o aparelho digital apresenta um formato diferente, com a tela da TV de 16x9, sendo mais horizontal e próxima ao do cinema. Em contraparte, a atual é mais quadrada, com proporção de 4x3 (FERNANDES; LEMOS; SILVEIRA, 2004).

Além dessas características supracitadas, é relevante destacar que o significado do impacto da TVD vai além da melhora da qualidade de imagem e som e da troca de um sistema de transmissão analógico para o digital. Em relação à difusão analógica, essa tecnologia permite um maior nível de flexibilidade que pode ser evidenciado pela possibilidade de expandir as funções do sistema mediante aplicações desenvolvidas sobre a base de um sistema padrão de referência. Essas aplicações são programas computacionais residentes em um STB ou provenientes de dados multiplexados enviados com áudio e vídeo. Deste modo, a inserção de uma capacidade computacional no STB permite também o surgimento de várias possibilidades de novos serviços, que juntamente com a interatividade, podem ser consideradas as principais características de um sistema de TVD. A interatividade permitirá que o telespectador deixe de ter um papel passivo e passe a ter um papel ativo, podendo, desta forma, atuar com o programa transmitido e agir de maneira que interfira na forma e no conteúdo exibidos na TV (MONTEZ; BECKER, 2005).

Um sistema de TVD é formado por um conjunto de componentes, como pode ser observado na Figura 1, referente à multiplexação e transmissão de sinais (modulação), compressão de áudio e vídeo e camada de abstração de software (*middleware*) que é responsável pela implementação de interatividade e novos serviços.

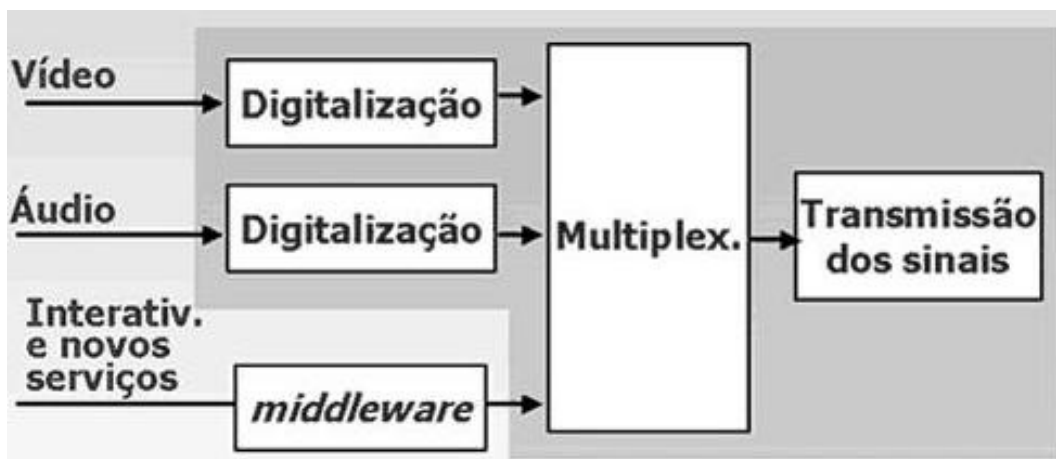


Figura 1 - Modelo de referência em blocos de um sistema de TVD genérico (CAVALCANTI, 2005)

Para cada um dos componentes são definidos padrões e cada sistema de TVD define o seu conjunto de padrões, como pode ser observado na Figura 2. Essa figura foi elaborada para demonstrar também as principais características de cada sistema. No contexto brasileiro, foram desenvolvidas pesquisas nas duas últimas décadas com objetivo de definir uma padronização para a infra-estrutura de TV para a transição do modelo analógico para o digital.

Em 2003, um grupo de estudo foi criado para analisar o assunto e dar um parecer sobre os estudos realizados até aquele momento. Este grupo encerrou suas atividades em novembro do mesmo ano culminando com o Decreto N° 4.901, de 26 de novembro de 2003 que instituiu o Sistema Brasileiro de Televisão Digital (MONTEZ; BECKER, 2005; SBTVD, 2008; DOU, 2003). Com este decreto, as discussões em relação ao padrão de TVD a ser adotado no Brasil se intensificaram e abordou-se a questão da escolha de um padrão estrangeiro já existente ou do desenvolvimento de um padrão nacional. Essa dúvida foi solucionada com o Decreto N° 5.820, de 29 de junho de 2006, e o padrão de sinais do ISDB foi escolhido como base e incorporadas inovações brasileiras, dando origem ao padrão brasileiro chamado ISDTV-T (DOU, 2006). A principal inovação foi a definição de um *middleware* próprio denominado Ginga (GINGA,2008).



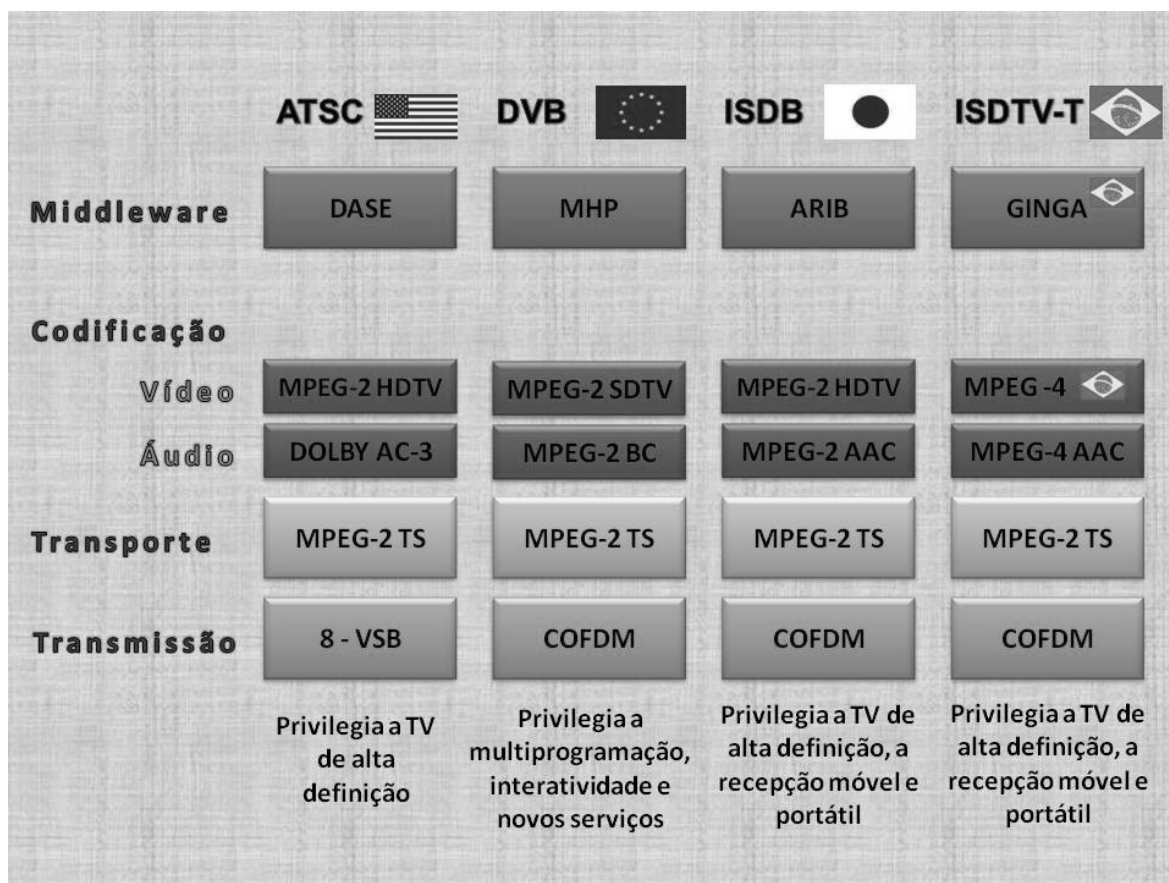


Figura 2 - Comparação entre os sistemas de televisão digital

Devido ao fato da aplicação desenvolvida nesse trabalho evidenciar possibilidades de utilização no ISDTV-T, considerando características deste sistema e também por ser o adotado no Brasil, somente o mesmo será abordado, não sendo relevante abordar os outros sistemas de TVD existentes no mundo.

## 2.1 Sistema Brasileiro de Televisão Digital

O ISDTV-T foi baseado no padrão de TVD japonês ISDB-T (*Terrestrial Integrated Services Digital Broadcasting*) e utiliza sua modulação, porém incorpora inovações brasileiras em relação às camadas de codificação e *middleware*.

Em relação à codificação de vídeo, todos os sistemas de TVD utilizam o MPEG-2 (*Moving Picture Experts Group*) e o Brasil emprega uma técnica de codificação mais recente e eficiente, o MPEG-4 (H.264), também conhecido como MPEG-4 Part 10 ou MPEG-4 AVC (*Advanced Video Coding*) (ISO/IEC 14496-10, 2005). Esta técnica permite manter a qualidade de imagem, porém reduz a taxa de bits, permitindo o uso mais eficiente

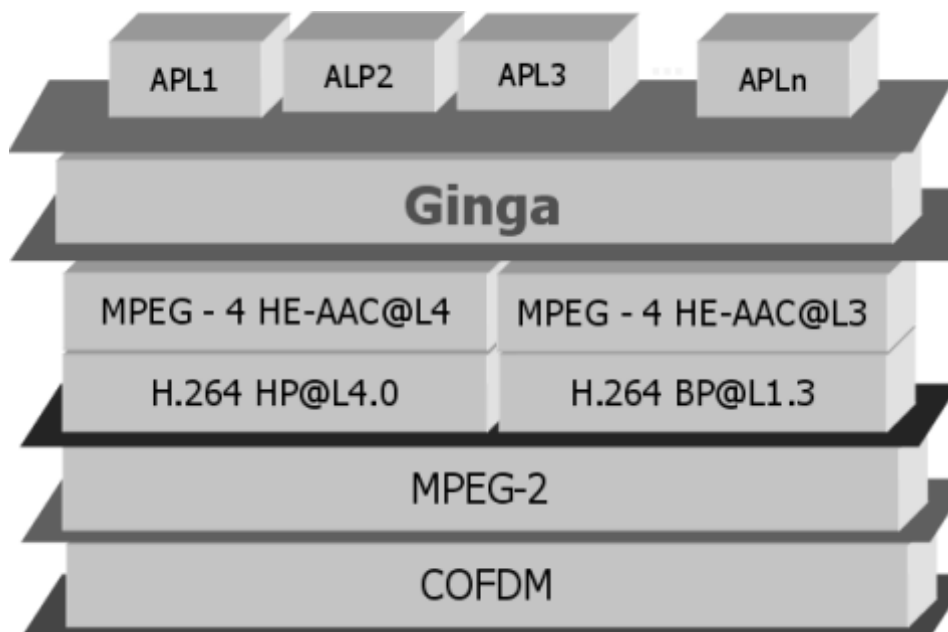
do espectro (MENDES, 2007). Para a compressão de áudio principal de um programa, o ISDTV-T adotou o padrão MPEG-4 (ABNT NBR 15602-2, 2008).

Todos os sistemas utilizam um *middleware*, que é uma camada de software responsável pela gerência dos recursos do terminal de acesso (STB). Este fornece um nível de abstração para que as aplicações possam acessar os recursos de baixo nível, independentemente do fabricante e das características particulares do STB. Deste modo, o uso do *middleware* facilita a portabilidade das aplicações, permitindo que sejam transportadas para qualquer STB que suporte o *middleware* adotado (SOARES; SOUZA, 2007).

O *middleware* é o responsável por interpretar o fluxo de dados vindo das emissoras e extrair as informações necessárias para então, prover a interatividade. Ele costuma ser formado por uma pilha de *software*, que oferece APIs (*Application Programming Interface*) padronizadas e, essas APIs constituem uma plataforma de programação para aplicações interativas.

Os *middlewares* diferem de um sistema para outro e o adotado pelo Brasil, o Ginga, foi desenvolvido por instituições de pesquisas nacionais e está especificado na norma ABNT (ABNT NBR 15606-4, 2008; ABNT NBR 15606-5, 2008; GINGA, 2008). Comparado aos *middlewares* desenvolvidos para os outros sistemas de TVD, algumas características do Ginga são inovadoras e surgiram de dois projetos. Um deles, o FlexTV, foi proposto por Leite *et al.* (2005) e é o responsável pela parte procedural, já o outro, o MAESTRO, foi proposto por Soares (2006) e é o responsável pela parte declarativa. Assim, as inovações brasileiras tornam a especificação do *middleware* mais avançada e adequada à realidade do país.

O Ginga é interposto entre as aplicações e os módulos que formam o ISDTV-T e oferece facilidades em relação ao desenvolvimento de aplicativos para TVD. A Figura 3 ilustra o modelo de referência do ISDTV-T e a disposição do *middleware* Ginga.



**Figura 3 - Arquitetura do modelo de referência do ISDTV-T (COMUNIDADE GINGA, 2009)**

Essa arquitetura tem como objetivo a oferta de serviços de cada camada para a camada superior e conseqüente uso dos serviços oferecidos pela inferior. Sendo assim, as aplicações desenvolvidas para TVD usam a camada do *middleware* Ginga, que conduz toda a comunicação entre a aplicação e os demais serviços das camadas inferiores.

Conforme ilustrado na Figura 4, a arquitetura de implementação de referência do *middleware* Ginga divide-se em três grandes módulos, o Ginga-CC (Ginga-*Common Core* ou Ginga-Núcleo Comum) que especifica um conjunto de funcionalidades comuns, o Ginga-NCL (máquina de apresentação) e o Ginga-J (máquina de execução). Os dois últimos são subsistemas interligados que permitem o desenvolvimento de aplicações seguindo dois paradigmas de programação diferentes. O Ginga-NCL possibilita o desenvolvimento de aplicações declarativas que permitem definir onde e quando uma mídia será apresentada e é baseado em uma linguagem de aplicação XML (*HyperText Markup Language*), chamado NCL (*Nested Context Language*) (NCL, 2008). Já o Ginga-J, utiliza a linguagem Java e deste modo, possibilita o desenvolvimento de aplicativos procedurais, denominados Xlets (SOARES; SOUZA, 2007).

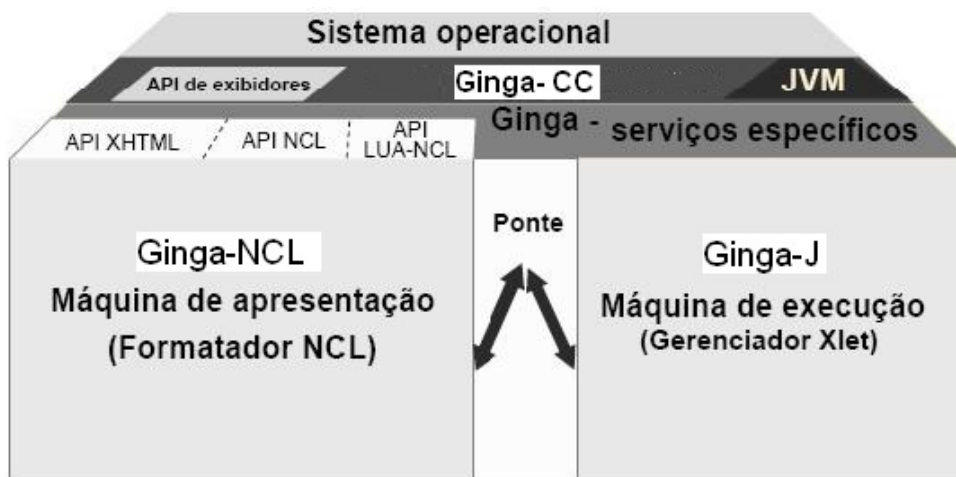


Figura 4 - Arquitetura Ginga (ABNT NBR 15606-5, 2008)

O Ginga-CC fornece suporte para o Ginga-NCL e Ginga-J e tem algumas funções especiais como exibição de vários objetos de mídias, controle do plano gráfico, tratamento do canal de retorno e de dados obtidos do carrossel de objetos DSM-CC (*Digital Storage Media - Command and Control*), entre outras. Este módulo é composto por tipos de decodificadores de conteúdo comum que decodificam e apresentam tipos de conteúdos como PNG (*Portable Network Graphics*), JPEG (*Joint Photographic Experts Group*), MPEG, dentre outros formatos e por procedimentos que obtém conteúdos transportados em fluxos de transporte MPEG-2 TS (*Transport Stream*) e via canal de retorno.

O DSM-CC é adotado no Ginga para conduzir comandos de edição ao vivo em fluxos elementares MPEG-2 TS. O fluxo de eventos DSM-CC e o protocolo de carrossel de objetos DSM-CC são a base para aplicações executadas no Ginga. O Ginga-CC também suporta o conceito de modelos de display gráficos definidos pelo ISDTV-T. A Figura 5 ilustra a arquitetura do Ginga-CC.

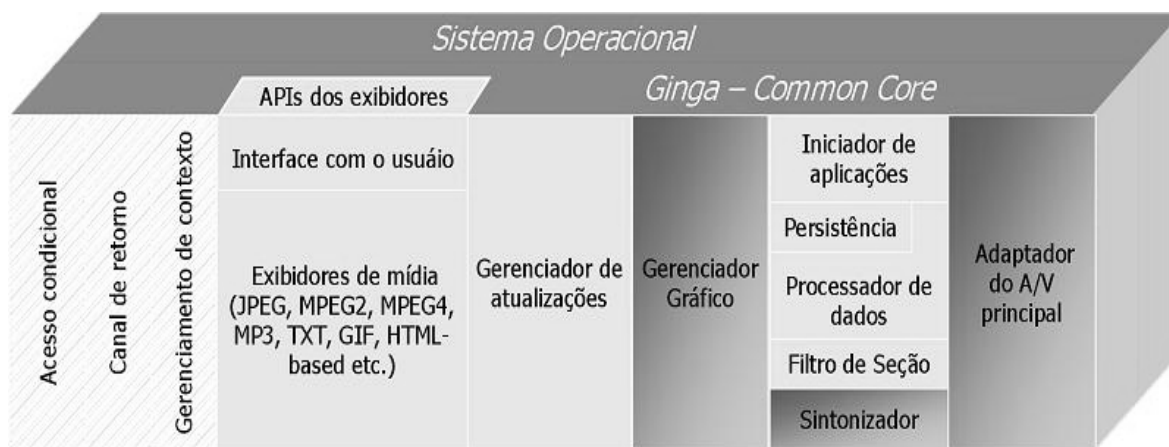


Figura 5 - Arquitetura Ginga Common-Core (COMUNIDADE GINGA, 2009)

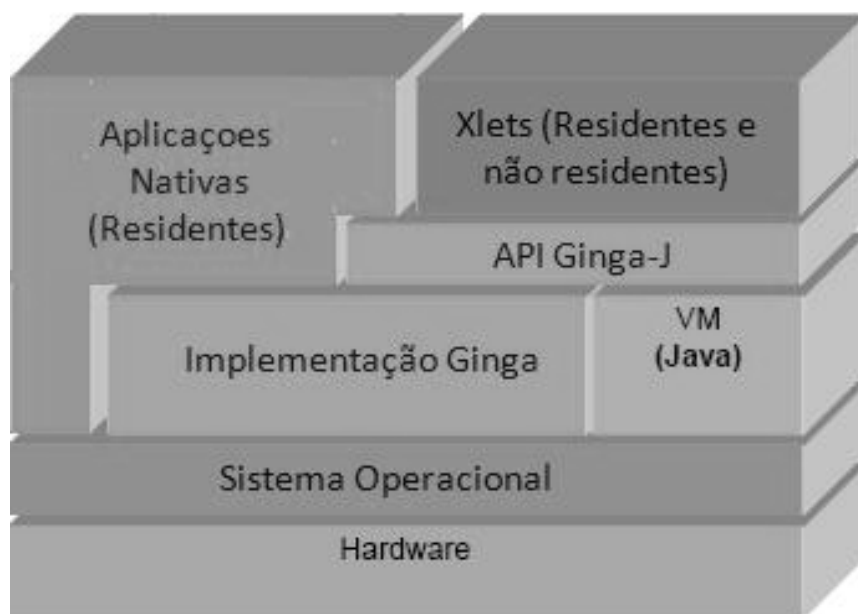
Diferenciando-se dos outros sistemas, uma aplicação para o Ginga não precisa ser totalmente declarativa ou procedural, pois os ambientes de apresentação e execução se complementam por uma ponte de interligação. Sendo assim, uma aplicação declarativa pode referenciar um Xlet, assim como uma aplicação procedural pode referenciar um documento NCL. Então, cada tipo de aplicação Ginga pode se beneficiar das facilidades de ambos os ambientes de aplicação (SOUZA; LEITE; BATISTA, 2007). Cada ambiente de aplicação será descrito abaixo, porém, para o contexto deste trabalho, o ambiente de aplicação procedural tem maior relevância e será abordado com mais detalhes.

A máquina de apresentação que processa o documento NCL tem como componente chave o mecanismo de decodificação do conteúdo informativo, o formatador NCL. Este é responsável por receber um documento NCL e controlar a sua apresentação de forma que sejam respeitados os relacionamentos entre objetos de mídias. A linguagem NCL é considerada uma linguagem de “cola” e não se restringe ou prescreve os tipos de conteúdos de objetos de mídia. Neste sentido, é possível ter objetos de imagens, de vídeo, de áudio, de texto e de execução (Xlet ou Lua) como objeto de mídia NCL.

Outro módulo importante é o de agentes de usuários baseado em XHTML (*eXtensible Hypertext Markup Language*), que inclui uma linguagem de estilo (CSS - *Cascading Style Sheets*), um intérprete ECMAScript e uma máquina Lua, a qual é responsável por interpretar *scripts* Lua. Dependendo da implementação XHTML, o Ginga-NCL pode ser compatível com outros padrões declarativos (SOARES; RODRIGUES; MORENO, 2007).

Para suprir a deficiência dos *middlewares* declarativos dos sistemas de TVD europeu (DVB-HTML), americano (ACAP-X - *Advanced Common Application Platform*) e japonês (BML - *Broadcast Markup Language*), o Ginga-NCL introduziu a linguagem NCL (NCL, 2008). Cada um desses *middlewares* possui uma implementação de uma máquina de apresentação para controle de suas aplicações declarativas, sendo que estas máquinas são navegadores XHTML. Estes possuem problemas, pois o modelo conceitual do HTML é extremamente simples já que privilegia a interatividade ao invés da sincronização e adaptabilidade de conteúdo que são realizadas por *scripts* procedurais (ECMAScripts). Para resolver essa questão, a linguagem NCL é capaz de prover mecanismos de adaptabilidade e sincronização de forma declarativa, sem a necessidade de *scripts* procedurais, como ocorrem em outros *middlewares* (RODRIGUES; MORENO; SOARES, 2006).

A máquina de execução de conteúdo procedural permite que aplicações desenvolvidas na linguagem Java possam ser executadas no STB. Dessa forma, tem como componente chave uma máquina virtual Java (*Java Virtual Machine - JVM*) (SOUZA; LEITE; BATISTA, 2007). O Ginga-J é composto de entidades e recursos de hardware, software do sistema e aplicativos, como ilustra a Figura 6.



**Figura 6 - Arquitetura Ginga-J e ambiente de execução (SOUZA *et al.*, 2007)**

Os Xlets possuem um ciclo de vida próprio e podem ser enviados diretamente pela emissora, sem a necessidade de documentos NCL para dispará-los, já que as classes Java são manipuladas diretamente pela máquina de execução Ginga-J. Sendo assim, a possibilidade de uso de documentos NCL que disparam Xlets deve ser encarada como alternativa para unir as funcionalidades e facilidades de ambas as linguagens e não como método obrigatório. As aplicações Xlets transmitidas (residentes e não residentes) devem sempre utilizar APIs padronizadas fornecidas pelo Ginga-J, como pode ser observado na Figura 6.

Além das aplicações difundidas por *broadcasting*, existe a possibilidade das aplicações serem residentes (Aplicações Nativas Residentes), como ilustrado na Figura 6. As aplicações residentes podem ser implementadas usando funções não padronizadas oferecidas pelo sistema operacional do dispositivo com o Ginga e também incorporar as funcionalidades das APIs da padronização do Ginga-J. O Ginga não tem ciência das aplicações residentes, porém, estas possuem prioridade. (SOUZA; LEITE; BATISTA,

2007). As aplicações residentes incluem, mas não se limitam a *closed caption*, às mensagens do sistema de acesso condicional, aos menus do receptor e ao EPG.

O subsistema Ginga-J foi construído para garantir a compatibilidade com o padrão GEM (*Globally Executable MHP*). Assim, ele inclui as APIs do núcleo do GEM e define outras específicas e únicas para requerimentos particulares brasileiros. O GEM consiste em uma proposta de uma especificação única para *middlewares* de sistemas de TVD, feita pelo grupo DVB. Por ser o padrão de *middleware* mais maduro, o MHP (*Multimedia Home Platform*) foi escolhido como referência para tentar estabelecer a conformidade entre os padrões. O GEM tem sido adotado pelos padrões de *middlewares* dos japoneses (ARIB) e americanos (ATSC, ACAP e OCAP). Para que um *middleware* seja compatível com o padrão GEM, deverá implementar as APIs especificadas por ele. Porém, o GEM não é simplesmente um subconjunto do MHP, pois cada padrão de *middleware* pode usar o GEM de forma personalizada, adicionando extensões e também, colocando restrições na especificação básica (BECKER *et al.*, 2005). A Figura 7 ilustra a compatibilidade dos padrões com a especificação do GEM.

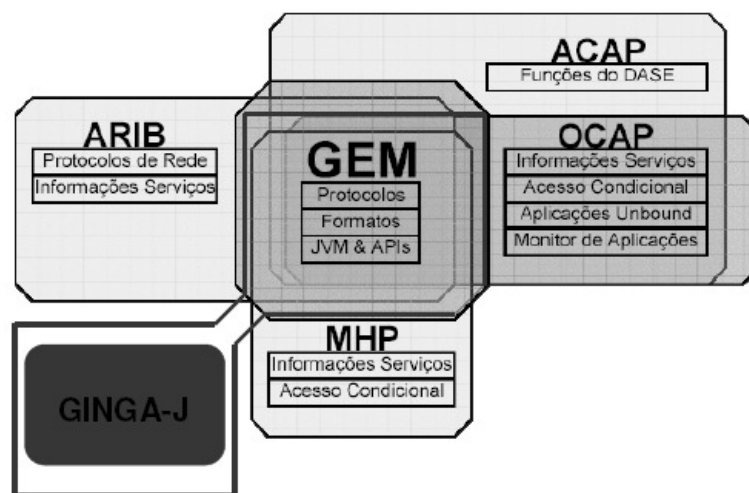
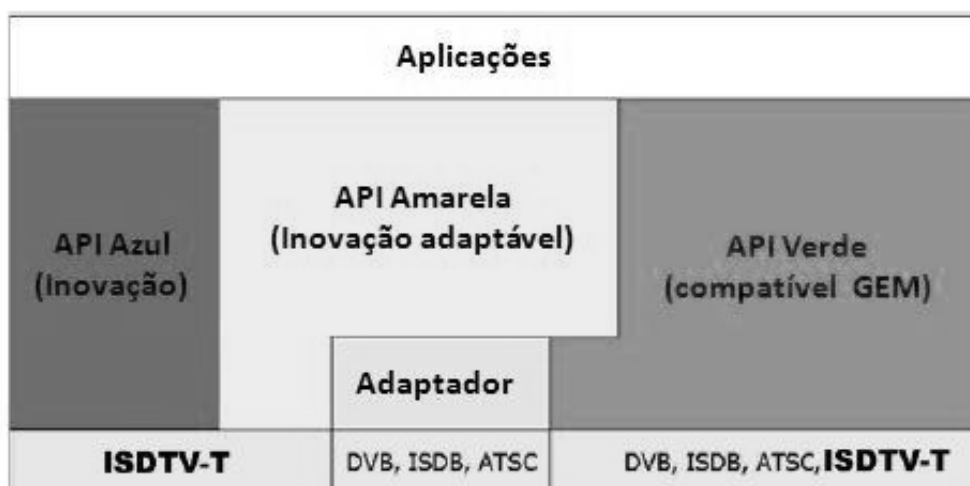


Figura 7 - Relacionamento do GEM com os *middlewares* (LEITE *et al.*, 2005)

A fim de cumprir os requisitos brasileiros específicos e, ao mesmo tempo manter a compatibilidade internacional com as APIs do GEM, o Ginga é composto por três conjuntos de APIs, denominadas azul, amarela e verde, que podem ser observadas na Figura 8.



**Figura 8 - APIs verde, amarela e azul do Ginga-J (SOUZA; LEITE; BATISTA, 2007)**

A API azul é uma inovação que dá suporte às aplicações brasileiras, em especial as de inclusão social. É composta por integração de dispositivo, permitindo ao receptor se comunicar com outros dispositivos através de meios com e sem fio. Também possui uma API multiusuário que permite vários telespectadores interagirem simultaneamente com aplicações de TVD. E por fim, possui uma ponte NCL, permitindo que aplicações Java contenham aplicações NCL. A API amarela, também é uma inovação brasileira, porém pode ser exportada para os outros sistemas, pois utiliza um adaptador. A API verde segue o núcleo comum do padrão GEM e permite que aplicações desenvolvidas seguindo essa API funcionem mundialmente nos *middlewares* compatíveis com GEM. Essa API é composta pelos pacotes do Java TV, DAVIC (*Digital Audio Video Council*), HAVI (*Home Audio Video Interoperability*) e DVB.

A compatibilidade do Ginga-J com o GEM pode não ocorrer, visto que a utilização da API JavaDTV, especificada pela Sun, foi adotada recentemente pelo Fórum SBTVD. A API JavaDTV é um conjunto de APIs, porém, pode ser considerada uma única API do Ginga-J e funcionalmente substitui o GEM. O motivo para adoção da JavaDTV foi devido ao pagamento de *royalties* para utilizar o GEM. Sendo assim, a especificação da JavaDTV consiste em uma plataforma aberta, interoperável e sem cobrança de *royalties*. Essa mudança no Ginga-J está transcorrendo e até o momento da escrita desta dissertação, essa especificação ainda não tinha sido aprovada, pois está no estágio de consulta pública (FORUM SBTVD,2008).



Sendo assim, para desenvolver a aplicação proposta neste trabalho, foi utilizada a API Java TV contida na API Verde do Ginga-J e o ambiente de teste foi realizado em um emulador. Essas soluções foram adotadas por estarem disponíveis no período de desenvolvimento do trabalho. Assim, quando o *middleware* Ginga estiver disponibilizado, será possível realizar adaptações para que os módulos desenvolvidos sejam incorporados como extensões. Para isto, os módulos deverão ser implementados conforme a linguagem do *middleware* e utilizar recursos fornecidos pelo mesmo. Estes módulos oferecerão interfaces para que o sistema de recomendação seja utilizado.

## 2.2 API Java TV

O programa Java que pode ser difundido, recebido e executado remotamente em um STB em conformidade com a biblioteca Java TV, recebe o nome de Xlet. A API Java TV forma a base para um grande número de padrões de TVD. Primeiramente, DVB baseou seu *middleware* MHP para a TVD Européia nessa API. Isso foi posteriormente expandido no GEM para uso em uma variedade de padrões de TVD mundiais, incluindo a OCAP (EUA), ACAP (EUA) e ARIB (Japão), além do *middleware* brasileiro Ginga. A API foi desenvolvida pela *Sun Microsystems* e fornece acesso e funcionalidades em um dispositivo de acesso de TVD. Ela consiste de uma JVM que é hospedada e executada no próprio STB além de várias bibliotecas de códigos reutilizáveis específicos para TVD (FERNANDES; LEMOS; SILVEIRA, 2004; SUN, 2006). Na Tabela 1, são apresentados os pacotes da API Java TV e suas respectivas funções.

**Tabela 1 - Pacotes da API Java TV e suas respectivas funções (SUN, 2006)**

Pacote	Função
javax.tv.graphics	Oferece mecanismos para que os Xlets possam encontrar o <i>container</i> raiz para seus componentes gráficos e disponibiliza mecanismos de controle sobre níveis de transparência.
javax.tv.locator	Fornecer um meio para referenciar dados e recursos acessíveis pela API Java TV.
javax.tv.media	Disponibiliza controles e eventos para o gerenciamento em tempo real de mídias em um ambiente de TV.
javax.tv.net	Fornecer acesso à datagramas IP na <i>stream</i> de transporte.
javax.tv.service	Disponibiliza mecanismos para acesso à informação do serviço (SI) e classes que representam seus elementos.
javax.tv.service.guide	Oferece suporte para guias eletrônicos de programação (EPG).

javax.tv.service.navigation	Fornece suporte para navegação entre serviços e informações hierárquicas de serviços.
javax.tv.service.selection	Disponibiliza mecanismo para selecionar um serviço para apresentação.
javax.tv.service.transport	Oferece informações adicionais sobre os mecanismos de transporte que transmitem os serviços.
javax.tv.util	Fornece suporte a criação e gerenciamento de eventos no tempo.
javax.tv.xlet	Disponibiliza a interface para os aplicativos e o gerenciador de aplicações se comunicarem.

Além de uma API, Java TV é também uma extensão da linguagem Java que está inserida no padrão CDC (*Connected Device Configuration*) / JME (*Java Micro Edition*). Porém, este padrão não define funcionalidades específicas de TV, as quais são incluídas no Java TV que utiliza o padrão JME devido ao pouco recurso de um STB. Neste contexto, certas características da plataforma Java foram excluídas, pois não são adequadas para o ambiente de TVD. Abaixo da camada da Java TV, há um sistema operacional que dá suporte à implementação da JVM e a camada mais abaixo é o receptor de TVD. A API Java TV fornece uma abstração em relação à camada de *hardware*, facilitando o desenvolvimento de aplicações, pois não há preocupação com o ambiente desta camada (FERNANDES; LEMOS; SILVEIRA, 2004). Alguns exemplos de aplicações que utilizam esta plataforma são correio eletrônico, EPG, comércio televisivo e jogos.

Os Xlets não precisam estar previamente armazenados no STB, pois podem ser enviados pelo canal de difusão quando necessários. Para controlar os Xlets, cada STB possui um Gerente de Aplicações (*Application Manager*) instalado. A Figura 9 ilustra a disposição dos Xlets e do gerente de aplicações (FERNANDES; LEMOS; SILVEIRA, 2004; MONTEZ; BECKER, 2005).

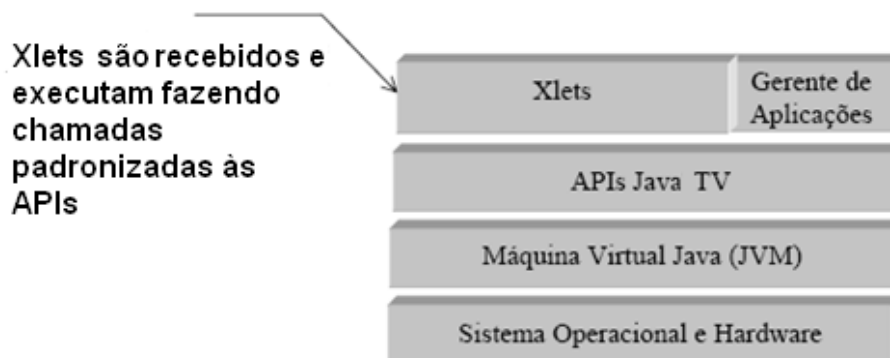


Figura 9 – Xlets e Gerente de Aplicações (MONTEZ; BECKER, 2005)

Um gerente de aplicações lida com quatro estados do ciclo de vida que um Xlet possui, *loaded*, *paused*, *active* e *destroyed*. Todos os Xlet implementam a interface *javax.tv.xlet.Xlet*, que ativa os métodos para sinalizar mudanças de estado da aplicação. Os estados e os métodos suportados pela interface Xlet são ilustrados na Figura 10 (FERNANDES; LEMOS; SILVEIRA, 2004).




Figura 10 - Ciclo de vida de um Xlet (FERNANDES; LEMOS; SILVEIRA, 2004)

O método *start* é utilizado no início pelo gerente de aplicação para instanciação do Xlet, o qual mudará para o estado *Loaded*. Logo após, o método *initXlet* pode ser usado para inicialização do Xlet e neste processo, um objeto *XletContext* é passado para o Xlet para definir o contexto de execução. A notificação de mudanças de estados via mecanismo de *callback* ao gerente de aplicação e a obtenção de propriedades do ambiente de execução são realizadas por este objeto (FERNANDES; LEMOS; SILVEIRA, 2004).

Após a inicialização, o Xlet encontra-se no estado *Paused*, no qual nenhum recurso compartilhado pode ser mantido ou usado. O método *startXlet* é responsável por ativar o Xlet nesse estado, fazendo com que mude para o estado *Active*, no qual ativa suas funcionalidades e oferece serviços. Para retornar ao estado *Paused*, o Xlet utiliza o método *pauseXlet*. O Xlet também pode ser destruído em qualquer estado usando o método *destroyXlet*, liberando então todos os recursos e finalizando a execução (FERNANDES; LEMOS; SILVEIRA, 2004).

### 2.3 Transmissão do sinal de TVD

No sistema de TVD, como já mencionado anteriormente, além da transmissão de áudio e vídeo, é previsto o envio de dados, os quais podem ser utilizados por aplicações interativas. Para efetuar essa transmissão, um sistema de TVD, sendo um sistema típico cliente/servidor, é composto de uma estação transmissora, de um meio físico por onde a transmissão ocorrerá e de um receptor, o STB ou terminal de acesso (FERNANDES;

LEMOS; SILVEIRA, 2004). Várias etapas compõem a transmissão, tais como a codificação, a multiplexação e a modulação, as quais podem ser observadas no lado esquerdo da Figura 11.

Primeiramente, o áudio e vídeo capturados são enviados para os codificadores digitais, que geram os fluxos de bits de vídeo principal e áudio principal, denominados fluxos elementares (*Elementary Stream - ES*). Estes, juntamente com o fluxo de dados, que pode conter aplicações interativas, são multiplexados em seguida em um único sinal, denominado fluxo de transporte (TS). Essa multiplexação, na maioria dos sistemas de TVD incluindo o ISDTV-T, é especificada pelo padrão MPEG-2 Sistemas, mais precisamente, pelo MPEG-2 TS (ISO/IEC 13818-1, 2000). Com a multiplexação realizada, o sinal é modulado para um canal de frequência e transmitido conforme o meio desejado, no caso do sistema terrestre, pelo ar. Visando dar suporte a essa transmissão, a maioria dos padrões de TVD utiliza o protocolo carrossel de objetos DSM-CC, o qual é definido na parte 6 do padrão MPEG-2 (ISO/IEC TR 13818-6, 1998). Esse protocolo é utilizado, pois a sintonização de um fluxo TS específico, ou seja, de um canal específico, pode ocorrer em qualquer instante, o que obriga o envio cíclico dos dados que não tenham relação com a seqüência temporal em um fluxo TS. Deste modo, é garantido um recebimento dos dados independente do instante da sintonização.

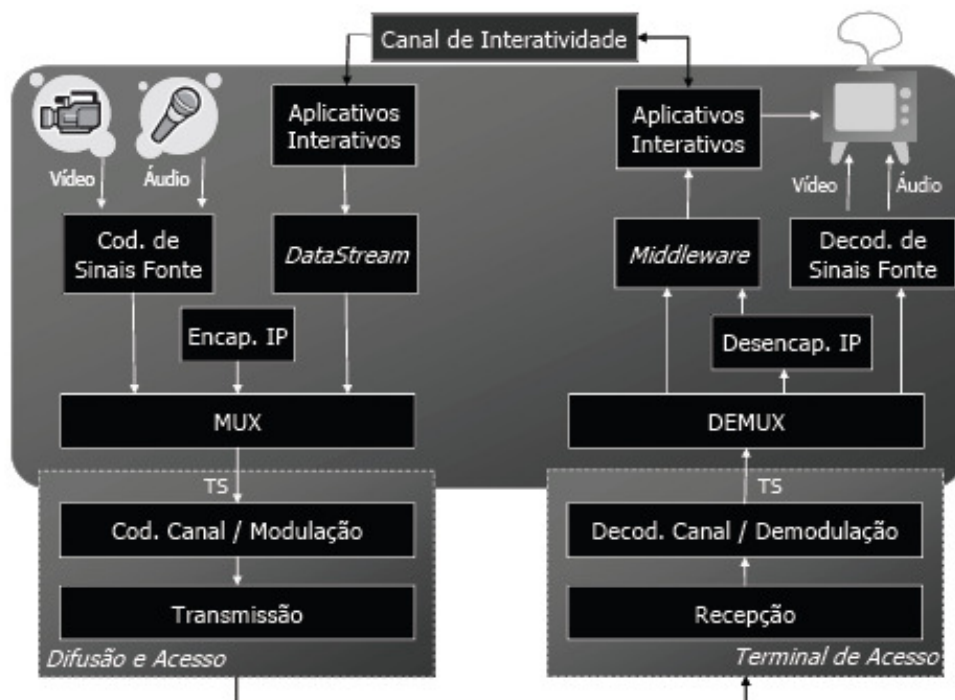


Figura 11 - Processo de transmissão e recepção de TVD (BARBOSA; SOARES, 2008)

A recepção pode ser observada no lado direito da Figura 11. Primeiramente o sinal é recebido e demodulado, ou seja, retirado do canal de frequência sintonizado e a seguir, é encaminhado ao demultiplexador. Este separa os fluxos de áudio e vídeo principais encaminhados para os decodificadores apropriados dos fluxos de dados entregues para processamento.

Diante de todo processo de transmissão do sinal digital, a relevância para este trabalho encontra-se na transmissão dos metadados. Visto que o TS possui vários programas e serviços, o que torna a decodificação mais complicada é importante a presença de metadados para que o decodificador saiba o que decodificar. Sendo assim, a utilização de metadados é importante, pois estes descrevem as informações sobre os serviços e conteúdos multimídia transmitidos por *broadcast*. Dentre essas informações estão o número e o nome do canal, além do nome, descrição, hora de início e duração de cada conteúdo. Para prover essas informações, o ISDTV-T define um conjunto de tabelas, denominadas SI (*Service Information*) (ABNT NBR 15603-1, 2008), que hierarquicamente associadas compõem as tabelas MPEG-2/PSI (*Program Specific Information*). Essa tabela de informação de programas está detalhada na ISO/IEC 13818-1 (2000) e os dados contidos nesta permitem que o STB selecione canais e eventos existentes e configure-os automaticamente. Por não possuir as mesmas necessidades, cada sistema de TVD tem particularidades em relação às tabelas e a ABNT NBR 15603-1 (2008) especifica detalhadamente a estrutura para a construção das informações básicas relacionadas à PSI que fazem parte do ISDTV-T.

Dentre as várias tabelas componentes do SI, as mais importantes para este trabalho são a SDT (*Service Description Table*) – tabela de descrição de serviço, a EIT (*Event Information Table*) - tabela de informação de eventos e a TDT (*Time and Date Table*) – tabela de data e horário. A tabela SDT descreve os serviços existentes em um TS, pois contém informações como nome e provedor do serviço. A tabela EIT oferece informações em ordem cronológica sobre os eventos existentes por serviço. Cada evento é formado por um identificador único, por um determinado instante de início, pela sua duração e por um conjunto de descritores para informações adicionais como, por exemplo, indicação de faixa etária e gêneros dos programas e a descrição de eventos curtos ou estendidos. A TDT é utilizada para informar ao receptor a hora e a data atual. (ABNT NBR 15603-2, 2008).

Os metadados permitem aplicações como o EPG, o qual apresenta a grade de programação disponibilizada pelas emissoras, o comércio televisivo (*T-commerce*), que oferece ao telespectador um serviço semelhante ao da internet, o governo televisivo (*T-government*), o qual, por exemplo, permite que o telespectador declare o imposto de renda pela TV, o acesso ao banco (*T-bank*), que permite o acesso de contas, dentre outros. Além desses serviços os metadados são essenciais para o desenvolvimento e funcionamento de sistemas de recomendação.

### 3 Personalização na Televisão Digital

A personalização pode ser resumida como a criação de algo apropriado para as necessidades de uma determinada pessoa e essa é uma das possibilidades de serviços que a tecnologia de TVD contempla. Com todas as vantagens inerentes à TVD, a personalização tende a ser uma área de exploração que visa a inclusão social e satisfação dos telespectadores, pois estes desejam que a TV seja inteligente o suficiente para identificar suas preferências e fornecer recursos personalizados e aplicações úteis (KIM; PAN; MCGRATH, 2004). Dessas aplicações, podem surgir dois assuntos emergentes para o uso da personalização, *T-commerce* e oferta de programação personalizada.

Em primeiro lugar, com o *T-commerce*, as mesmas técnicas de personalização utilizadas na Internet poderão ser mapeadas para serem utilizadas na TVD, permitindo a oferta de produtos de acordo com as preferências dos telespectadores. Em segundo lugar, as preferências dos telespectadores poderão ser consideradas e a programação de uma emissora poderá ser direcionada a cada um especificamente. Assim, com o ISDTV-T a expectativa é que diversas empresas surgirão e passarão a oferecer serviços de personalização às emissoras, para que essas ofereçam conteúdo de acordo com as preferências dos telespectadores.

Este tipo de oferta de conteúdo é relevante, pois com a adoção da radiodifusão digital e receptores digitais, novos desafios surgem em relação a pesquisas de conteúdo devido ao fato da tecnologia digital permitir a multiprogramação. Sendo assim, faz com que a quantidade do número de canais de TVD disponíveis gere uma sobrecarga de informação, tornando a pesquisa e a localização de conteúdo interessante, uma tarefa incômoda. Assim, a grande quantidade de informação faz da personalização de conteúdo uma das aplicações mais importantes para a emergente era da TVDI (CHORIANOPOULOS, 2008).

O problema da sobrecarga de informação ainda não afeta o Brasil e pode demorar um pouco para ocorrer. Porém, poderá acontecer por causa do avanço e da total implantação do ISDTV-T, pois a largura de banda de um canal digital é 6Mhz o que permite que sejam transmitidos vários programas ao mesmo tempo por uma única emissora. Este problema já é enfrentado em outros países que possuem TVD há algum tempo (MONTEIRO, 2002). A sobrecarga de informação também é evidente em propaganda televisiva, pois cria publicidade desorganizada e diminui a eficiência do canal de comunicação. A

personalização de anúncios pode oferecer o aumento da eficácia das propagandas ao localizar os telespectadores que provavelmente responderão positivamente à mensagem de propaganda.

O sistema iMEDIA (BOZIOS *et al.*,2001), descrito na seção 7.2, visa oferecer propagandas personalizadas conforme as preferências dos telespectadores, que são descobertas mediante o envio do comportamento de visualização para um servidor remoto. Porém, como relatado em Zhiwen e Xingshe (2004), os telespectadores esperam que as aplicações de TVD transmitam confiabilidade, privacidade e facilidade de uso (usabilidade), o que resulta na palavra “confiança”. Sendo assim, uma arquitetura centrada no STB, na qual os telespectadores não necessitam enviar seus dados a lugares remotos e mesmo assim, possam utilizar serviços de personalização, pode tornar uma abordagem menos intrusiva.

A personalização na TVD pode ser alcançada com o emprego de algoritmos e sistemas de coleta de dados que prevêm e recomendam conteúdos aos usuários conforme seus interesses. Assim, esta poderá ser uma solução para a sobrecarga de informação relacionada à seleção de programas, além de oferecer ao telespectador um serviço diferenciado.

### **3.1 Sistema de Recomendação**

O objetivo principal de um sistema de recomendação é conduzir o usuário por meio de sugestões, conselhos, advertências, efetuando um mapeamento do seu perfil com diferentes tipos de conteúdos, de tal forma que os conteúdos mais interessantes sejam filtrados e recomendados. Com um sistema de recomendação, torna-se possível implementar em programas de computador a grande rede social de sugestões e recomendações, que acontece de uma forma direta entre pessoas, auxiliando no aumento da capacidade e da eficácia deste processo de indicação.

O trabalho realizado por Chorianopoulos (2008) explorou o estado da arte sobre personalização na TVD em relação ao processo de recomendação de conteúdo. Assim, foi sugerido que os desafios desta área sejam em relação aos métodos empregados na recomendação de conteúdo e nas técnicas de coleta de dados.

O processo de recomendação de conteúdo tem sido bastante utilizado na personalização de aplicações baseadas na Web. Este conceito tem sido ajustado para o



domínio da TVD levando em consideração suas características inerentes. Para possibilitar a recomendação de itens, produtos ou conteúdo a um telespectador, são necessárias diversas técnicas e estratégias para coleta de informações, manipulação destas e apresentação das sugestões.

Para realizar a coleta de informações necessárias para a adaptação ou personalização, há duas maneiras, implicitamente ou explicitamente. A coleta implícita é transparente ao telespectador e pode ser realizada por monitoramento. Por exemplo, enquanto o telespectador muda de canal com o controle remoto, o seu comportamento é analisado, semelhante ao monitoramento do comportamento de aplicações baseados na web. Por outro lado, preferências de conteúdos podem ser realizadas pelos telespectadores por avaliações de itens em uma escala, como por exemplo, classificar um filme de um a cinco. Assim, por essa coleta explícita é possível capturar dados dos telespectadores e utilizá-los para inferir um perfil. Deste modo, é possível proporcionar conteúdos bem mais próximos aos interesses dos telespectadores.

As coletas implícita e explícita apresentam vantagens e desvantagens. A implícita é considerada discreta para os telespectadores de um sistema, porém, os dados recolhidos explicitamente são mais precisos para expressar interesses ou preferências. Apesar de a coleta implícita ser cômoda para o telespectador, uma forma ideal de criar o perfil do telespectador é permitir que ele altere seu perfil manualmente, com objetivo de efetuar alguns ajustes de preferência em dados coletados explicitamente. Em sistema de recomendação baseado na web, geralmente os usuários têm que avaliar os itens em uma escala.

A manipulação das informações pode ser realizada por diferentes técnicas e uma destas é a filtragem de informação, a qual pode ser colaborativa, híbrida ou baseada em conteúdo. Combinações de técnicas são comuns e o objetivo é melhorar as recomendações e também o tempo de geração destas. Este tempo deve ser considerado para definir a técnica de recomendação a ser utilizada, pois as recomendações instantâneas podem ser preferidas e deste modo necessita-se de pouco tempo de processamento. Por outro lado, há casos em que o tempo de geração das recomendações não é um problema e assim, pode haver um pré-processamento das informações utilizando mais tempo de processamento.

A apresentação das recomendações depende do tipo de aplicação e normalmente é definida em uma lista ordenada ou limitada aos itens mais relevantes para determinado

telespectador. A apresentação das recomendações de maneira adequada é uma importante decisão nos sistemas computacionais e pode ser em tecnologia *Push*, que recomenda conteúdos sem que o telespectador esteja interagindo com o sistema; tecnologia *Pull*, que apresenta as recomendações apenas quando o telespectador deseja e realiza a solicitação explicitamente; e apresentação passiva, na qual as recomendações estão inseridas no contexto da aplicação (SCHAFER, 2001).

Os níveis de personalização para sistemas de recomendação podem ser agrupados como não-personalizado, efêmero e persistente (TORRES, 2004). O nível não-personalizado permite a seleção manual através de categorias estabelecidas no projeto do sistema, o efêmero não usa dados persistentes para as recomendações, apenas dados da sessão de navegação atual do usuário e o persistente, oferece recomendações mais personalizadas e necessitam de grande quantidade de informações para isto.

Os sistemas de recomendação fornecem um tipo de personalização indireta, pois alteram o ambiente onde o telespectador está inserido, mas não o obriga a seguir um único caminho, sugerindo alterações que, não necessariamente, serão aceitas por ele. A implementação de sistemas de recomendação envolve aspectos das áreas de Interface Humano-Computador (IHC) devido à composição da interface aos usuários, e de Inteligência Artificial (IA) para a descoberta de informações e relacionamento entre elas, tornando-as conhecimento. Esta área tem sido explorada e utilizada como um complemento da estratégia de recomendação juntamente com a técnica de filtragem de informação abordada anteriormente e que será descrita nas próximas seções.

### **3.2 Técnicas de Filtragem aplicadas a Sistema de Recomendação**

Para efetuar uma recomendação de conteúdo conforme as preferências dos telespectadores, são aplicados algoritmos de filtragem de informação. Estes algoritmos, no contexto deste trabalho, servem para oferecer aos telespectadores conteúdos televisivos de acordo com o padrão de comportamento descoberto a priori. As principais abordagens da técnica de filtragem de informação, utilizadas pelo sistema de recomendação para oferecer personalização são filtragem de conteúdo, filtragem colaborativa e filtragem híbrida, as quais serão descritas a seguir.

### **3.2.1 Filtragem Colaborativa**

A filtragem colaborativa é baseada na similaridade de hábitos de comportamento entre os usuários para gerar recomendações e não considera o conteúdo dos itens; é umas das abordagens que mais ganha espaço atualmente. O princípio dessa técnica é oferecer uma forma automática utilizando computadores para realizar a recomendação “boca a boca”, ou seja, retratar de uma maneira computacional o que acontece na vida real quando algumas pessoas ajudam e oferecem conselhos a outras para realizar uma compra, tomar uma decisão, entre outros.

A filtragem relaciona-se com o fato de existir um processo seletivo no momento de gerar recomendações. Colaborativa é pelo fato das pessoas “colaborarem” entre si para a geração das recomendações. Assim, o princípio do algoritmo da filtragem colaborativa baseia-se na maior probabilidade do usuário ativo se interessar por itens que usuários semelhantes preferiram. Para isso, calcula-se um grau de similaridade entre o usuário ativo (alvo) e os outros usuários. Os itens com maior grau de similaridade são recomendados ao usuário alvo. A correlação pode ser explicitada pelo histórico ou frequência de utilização, ou ainda pelo emprego de técnicas que descubram tais relações.

A filtragem colaborativa reforça o conceito de conhecimento comunitário mesmo que as implicações de um usuário sobre outro não sejam explícitas. A idéia é aprender e prever os comportamentos de um usuário baseado em usuários com características de comportamento semelhantes. A filtragem colaborativa pode ser sintetizada pelo armazenamento das opiniões dos usuários sobre determinado item e baseada nessas opiniões, usuários com perfil semelhante são agrupados. Por fim, itens altamente avaliados pelos vizinhos são recomendados ao usuário ativo.

### **3.2.2 Filtragem baseada em conteúdo**

A filtragem baseada em conteúdo, também chamada correlação item-a-item, utiliza a técnica baseada em recuperação de informação que faz previsões ao supor que as preferências anteriores de um usuário são indicadores seguros para um comportamento futuro. Ou seja, categoriza as informações recuperadas e as relaciona com as preferências do usuário, gerando então recomendações para serem apresentadas ao usuário (CHORIANOPOULOS, 2008).

Assim, diferentemente da filtragem colaborativa, a recomendação que utiliza a filtragem baseada em conteúdo mede a similaridade entre os itens ou conteúdos televisivos

ao invés de utilizar a similaridade entre usuários. Sendo assim, o princípio é que se um usuário gostou de um determinado conteúdo, ele tende a gostar de um conteúdo similar no futuro. Deste modo, para efetuar a recomendação de um conteúdo, basta medir a similaridade dos conteúdos com o perfil desse usuário e indicar os mais similares.

### **3.2.3 Filtragem híbrida**

As duas técnicas abordadas anteriormente se complementam e vários estudos sugerem a combinação delas, filtragem híbrida, com o propósito de solucionar suas limitações intrínsecas. Uma recomendação oferecida por filtragem baseada em conteúdo irá somente contemplar dados de histórico de visualização dos usuários, não sendo possível recomendar conteúdos similares que não forem visualizados. Com isso, enfrenta-se o problema de exclusividade na recomendação. Já uma recomendação por filtragem colaborativa depende da sugestão de outros usuários, sem a qual o mecanismo não pode oferecer boas recomendações (HSU *et al.*, 2007).

As três abordagens supracitadas podem ser utilizadas juntamente com outras técnicas para manipular as informações coletadas em um sistema de recomendação e assim, aprimorar a qualidade das recomendações. Uma das possíveis técnicas que pode ser utilizada é a descoberta de conhecimento que será descrita na próxima seção.

## **3.3 Descoberta de Conhecimento**

O objetivo da descoberta de conhecimento não é simplesmente encontrar padrões e relações em meio a uma grande quantidade de informação, mas sim extrair conhecimento que seja inteligível e imediatamente utilizável para o apoio das decisões (FAYYAD; PIATETSKY-SHAPIRO; SMITH, 1996).

O processo de descoberta de conhecimento (informação de interesse, desconhecida a priori, não trivial e potencialmente útil), em base de dados é composto de várias etapas e é conhecido como KDD (*Knowledge Discovery in Database*), sendo que a mineração de dados é uma dessas etapas (FAYYAD; PIATETSKY-SHAPIRO; SMITH, 1996). O KDD utiliza algoritmos de mineração de dados para extrair padrões existentes entre dados coletados, representados e relacionados, culminado assim no “conhecimento”. Além disso, o KDD, ilustrado na Figura 12, tem como etapas a escolha do algoritmo adequado, o processamento e amostragem dos dados e interpretação de resultados. O KDD é um

processo não linear e deste modo, em cada etapa, pode ser necessário refazer as etapas anteriores (FAYYAD; PIATETSKY-SHAPIRO; SMITH, 1996).

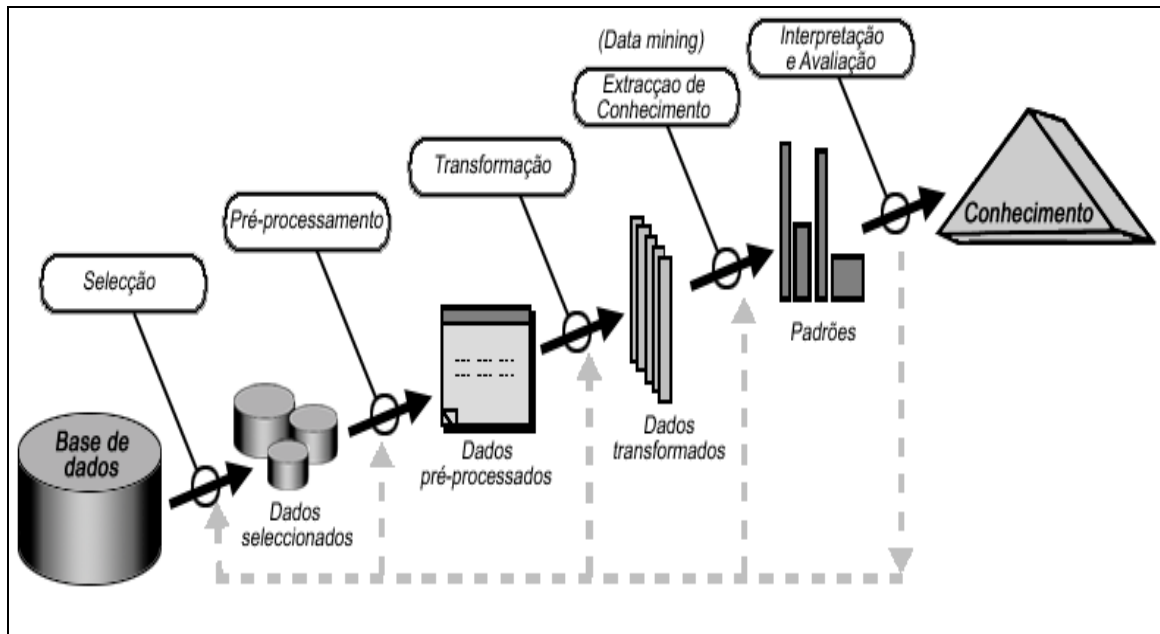


Figura 12 - Esquema do processo de KDD (FAYYAD; PIATETSKY-SHAPIRO; SMITH, 1996)

As etapas que fazem parte do processo KDD podem ser descritas, de maneira sucinta, da seguinte forma. Primeiramente as informações são coletadas e um conjunto de dados relevantes para a tarefa de análise é selecionado. A segunda etapa consiste no pré-processamento dos dados, que embora frequentemente ofuscado pela etapa mais atraente, a mineração de dados, a preparação dos dados é um componente essencial do processo de mineração. Sendo assim, esta etapa prepara os dados, pois nem sempre eles estão disponíveis para análise e nem em um formato adequado para a extração de conhecimento. Além disso, procura-se nesta fase eliminar inconsistências (dados nulos ou repetidos) e também aplicar transformações nos dados como extração, integração, transformação, limpeza, seleção e redução dos dados.

A terceira etapa é a transformação dos dados, que organiza os dados de uma forma harmonizada, de modo a localizar características úteis para representação destes dependendo do objetivo da tarefa. Além disso, visa à redução do número de variáveis no conjunto de dados e o acréscimo de dados externos. A quarta etapa é a mineração de dados, na qual são realizadas as escolhas da tarefa de mineração a ser empregada, do algoritmo e a extração dos padrões propriamente ditos. A quinta etapa consiste na interpretação dos padrões descobertos e se necessário, o retorno de algum passo anterior.

Além disso, a avaliação dos padrões é realizada removendo os que não têm importância. Após essas etapas, é possível obter o conhecimento e então usá-lo para resolução de problemas da vida real, por um Sistema Inteligente ou ainda por uma pessoa para realizar a tomada de decisão.

Conforme Han e Kamber (2006), a mineração de dados pode ser considerada um sinônimo de KDD ou um passo essencial no processo de descoberta de conhecimento. Sendo assim, essa técnica será abordada na próxima seção com mais detalhes. Além disso, serão descritos tanto a tarefa de regras de associação, a qual é relevante para este trabalho quanto o algoritmo padrão para esta tarefa, o Apriori.

### **3.3.1 Mineração de Dados**

A mineração de dados é a principal etapa do processo de KDD e ela utiliza mecanismos de aprendizagem de máquina (MA - *Machine Learning*) para extrair padrões dos dados. A mineração possui um potencial para descoberta de informação implícita em grandes bases de dados, o que faz esta técnica possuir característica interdisciplinar e ser bastante requisitada nas mais diversas áreas de conhecimento como banco de dados, redes neurais, inteligência artificial, estatística, recuperação de informação, reconhecimento de padrões, entre outras (REZENDE, 2003). O processo de mineração, que é uma etapa interativa, consiste de três passos, sendo eles a escolha da tarefa e do algoritmo e a extração de padrões.

Primeiramente, há dois tipos possíveis para a escolha da tarefa, a direta e a indireta. A primeira define uma classe a partir do conhecimento adquirido e busca identificar a classe de uma nova amostra de dados. Corresponde à modelagem preditiva, na qual desempenha inferências nos dados com intuito de fornecer previsões ou tendências para tomada de decisão. Já a segunda, tarefa descritiva, procura encontrar padrões ou similaridades nos grupos registrados em uma base de dados, porém não foca um alvo particular ou de alguma classe pré-definida e visa o suporte a decisão. Sendo assim, a tarefa de mineração pode ser classificada pelo tipo de padrão a ser descoberto e as principais tarefas são de classificação, associação e agrupamento (SCHAFER, 2001).

A classificação, uma tarefa preditiva, tem o objetivo de prever a categoria de novos dados mediante a construção de um modelo (classificador) baseado nos valores dos dados já existentes. É considerada preditiva, pois pode prever automaticamente a classe de um novo dado. Os classificadores podem ser implementados pelo uso de diferentes estratégias

de aprendizado de máquina como redes bayesiana, redes neurais, árvores de decisão e regras de classificação.

A associação, uma tarefa descritiva, tem como objetivo encontrar relacionamentos ou padrões frequentes entre conjuntos de dados. Regras de associação têm sido usadas com frequência para descrever o comportamento do consumidor no comércio varejista e poderá descrever o comportamento no uso da TVD. Quando aplicadas em um sistema de recomendação, podem identificar para qual item um usuário talvez esteja interessado baseado em sua demografia ou suas ações prévias.

O agrupamento, assim como a classificação, é uma tarefa preditiva e visa compor subgrupos ou segmentos homogêneos de populações heterogêneas. Assim, chama-se agrupamento o processo de formação de grupos de objetos dentro de classes de objetos similares (HAN; KAMBER, 2006).

O segundo lugar no processo de mineração é a escolha do algoritmo. Os algoritmos são definidos conforme a tarefa escolhida e podem ser algoritmos indutores de árvore de decisão, regra de produção, modelos lineares, modelos não lineares (Redes Neurais Artificiais), modelos baseados em exemplos (KNN) e modelos de dependência probabilística (Redes Bayesianas).

Em terceiro lugar é realizada a extração de padrões, que consiste na aplicação dos algoritmos escolhidos que efetuarão a extração dos padrões contidos nos dados. Deste modo, pode ser necessária a aplicação dos algoritmos de extração de padrões mais de uma vez, dependendo da função escolhida. Para melhorar e construir um preditor mais preciso, pode-se realizar a combinação de vários preditores.

Os sistemas de recomendação que utilizam a mineração de dados fazem as suas recomendações a partir de conhecimento aprendido das ações e dos atributos dos usuários. Sistemas assim são frequentemente baseados no desenvolvimento de perfis de usuário, os quais podem ser armazenados e são baseados geralmente em dados demográficos ou de histórico de consumo de itens. Outra opção é o não armazenamento relacionado apenas a ações durante a sessão. Esses tipos de sistemas são comuns no domínio de comércio eletrônico, pelo fato da aquisição de dados ser mais fácil do que em outros domínios. Os resultados alcançados com a mineração mostram-se promissores para qualquer domínio de aplicação. Isso acontece, pois a mineração de dados refere-se a uma ampla área de técnicas

de modelagem matemática e ferramentas de software que são usadas para procurar padrões em conjunto de dados, extraindo um novo conhecimento (SCHAFER, 2001).

A tarefa de associação, descrita a seguir, foi adotada, pois esta se adéqua à problemática deste trabalho, que é descobrir padrões em um histórico de visualização, com objetivo de evidenciar um comportamento. Além disso, a escolha também se deve a seu histórico de uso em diversos projetos.

### 3.3.2 Regras de associação

O estudo de regras de associação foi introduzido por (AGRAWAL; IMIELINSKI; SWAMI, 1993) com objetivo de encontrar um padrão de relacionamento entre itens de dados de um determinado domínio, ou seja, o quanto a presença de um conjunto de itens nos registros de uma base de dados implica na presença de outro conjunto distinto de itens nos mesmos registros. Sendo assim, neste tipo de tarefa, cada tupla de uma base de dados corresponde a um conjunto de atributos, denominados itens, e referem-se a uma transação. Deste modo, uma regra de associação corresponde a um relacionamento  $X \Rightarrow Y$ , onde  $X$  e  $Y$  são conjuntos de itens com intersecção vazia.

Cada regra de associação é unida a dois parâmetros, gerados por um especialista do domínio, chamados fator de suporte (FSup) e fator de confiança (FConf). O suporte representa o número de ocorrências de um determinado item ou conjunto de itens em relação ao total de dados analisados. A confiança reflete a frequência em que uma relação acontece sobre determinado item. De maneira a evitar a geração de alto número de regras, que se aproxime do número de transações, geralmente define-se o suporte com um valor mínimo (minSup). Já o valor mínimo de confiança (minConf) é definido com um valor alto para que exista uma elevada coesão entre os itens analisados, visto que, com uma confiança baixa não seria possível refletir qualquer padrão de comportamento. Deste modo, a tarefa de regras de associação consiste em encontrar todas as regras possíveis com valores FSup e FConf maiores ou iguais a minSup e minConf respectivamente.

Agrawal, Imielinski e Swami (1993) propuseram um modelo matemático definido formalmente como: sendo  $I = \{I_1, I_2, \dots, I_m\}$  um conjunto de atributos chamado itens e  $T = \{t_1, t_2, \dots, t_m\}$  um banco de dados de transações, onde cada transação  $t_i \in T$  é um conjunto de itens tal que  $t_i \subseteq I$ . Uma regra de associação  $R$  é uma implicação na forma  $LHS \rightarrow RHS$ , sendo que  $LHS$  e  $RHS$  são, respectivamente, o lado esquerdo ou



antecedente (**LHS**- *Left Hand Side*) e o lado direito ou consequente (**RHS** – *Right Hand Side*), observando que  $LHS \subset I$ ,  $RHS \subset I$  e  $LHS \cap RHS = \emptyset$ . A regra  $LHS \rightarrow RHS$  ocorre no conjunto de transação T com confiança, se minConf das transações de T em que ocorre **LHS** ocorre também **RHS**. A regra  $LHS \rightarrow RHS$  tem suporte na transação T se minSup das transações em T ocorre  $LHS \cup RHS$ .

As regras de associação são aplicadas a diversas áreas de negócios e pode ser utilizada como suporte à tomada de decisão. Há diversos algoritmos usados em regras de associação, dentre eles, Apriori, DHP, Tertius, Predictive Apriori. O algoritmo padrão mais utilizado para regras de associação é o Apriori e foi proposto por (AGRAWAL; SRIKANT, 1994). Este algoritmo originou diversos outros algoritmos, os quais visaram melhorar a eficiência computacional. O diferencial do Apriori está em sua simplicidade original, que permite uma fácil compreensão mesmo para não especialistas em mineração de dados, e na sua versatilidade em grandes conjuntos de dados. Além disso, a utilização do Apriori é relevante quando não se tem a classe de uma tarefa de mineração definida, como no caso da classificação. Ele tem como estratégia descobrir todos os conjuntos de itens frequentes, denominados *itemsets* maiores que o suporte adotado (minSup) e também construir todas as regras possíveis em uma base de dados a partir desses conjuntos, que sejam maiores que a confiança adotada (minConf). Um *itemset* que possui k itens é denominado *k-itemset* e, deste modo, o *itemset* denotado pelo conjunto {noticiário, esporte, tarde} é *3-itemset*.

O Apriori pode ser dividido em duas etapas. A primeira é em relação à descoberta de todos os conjuntos de itens frequentes e a segunda em relação à geração das regras de associação, as quais utilizam os conjuntos de itens frequentes descobertos. A primeira etapa demanda maior custo computacional do que a segunda. Na Figura 13 é ilustrado o algoritmo Apriori e a seguir é realizada uma descrição sobre ele.

```

L1 = {tamanho 1-itemset}; // Conjunto de Itens freqüentes de tamanho 1
for (k = 2; Lk-1 ≠ ∅; k++) do begin
    Ck = apriori-gen (Lk-1); // Novos candidatos
    forall as transações t do begin
        Ct = subset (Ck, t); // Candidatos contidos na transação t
        forall candidatos c ∈ Ct do
            c.count++;
    end
    Lk = {c ∈ Ck | c.count ≥ minsup}
end
Resposta = união de todos os Lk;

```

Figura 13 - Algoritmo Apriori.

O Apriori emprega um processo iterativo, onde primeiramente é gerado um conjunto de grupos com apenas um elemento e esse conjunto 1-itemset é denominado L1. A seguir, tem-se um laço onde são realizadas duas tarefas. A primeira é a geração do grupo de itens candidatos ( $C_k$ ) com uso da função Apriori-gen e a segunda analisa todo o banco de dados para a contagem do suporte dos itens ( $c$ ) do grupo candidato  $C_k$ . Para isto, o Apriori utiliza a função *subset*.

A função *Apriori-gen* pode ser dividida em dois passos, *Join* e *Prune*, sendo que o primeiro consiste em formar a união dos conjuntos frequentes  $L_{k-1}$ , e então gerar o conjunto candidato  $C_k$ . Nesse passo os itens do conjunto candidato formado estarão ordenados lexicograficamente, eliminando aqueles que possuem itens iguais. O segundo passo da função Apriori-gen, é eliminar todos os candidatos que não tem subconjuntos frequentes, ou seja, que estão abaixo do minSup e minConf. Deste modo, o objetivo é reduzir o número de candidatos  $C_k$  a serem comparados com cada transação na base de dados.

A função *subset* é responsável pela análise de uma transação para verificar se algum de seus subconjuntos é um *itemset* candidato. Essa verificação nos subconjunto pode ser realizada pelo uso de *hash-tree* para todos *itemsets* frequentes.

Após os passos *Join* e *Prune*, já é possível unir todos os itens frequentes ( $L_k$ ) e, a partir deles, são geradas as regras de associação que constituem a resposta do algoritmo. Após

obter as regras, uma dificuldade é selecionar quais destas realmente são importantes. Isto acontece, pois as regras de associação são subjetivas, visto que o interesse por determinadas regras depende do conhecimento do utilizador no domínio em análise.

A seguir será apresentada a ferramenta Weka, pois esta implementa diversos algoritmos de mineração inclusive o Apriori, permitindo o uso em diversos domínios.

### **3.3.3 WEKA**

Esta ferramenta, desenvolvida pela Universidade de Waikato na Nova Zelândia, possui código aberto distribuído sob licença GNU (*General Public License*) (WITTEN; FRANK, 2005). Ela tem sido utilizada para realizar o KDD e contempla uma série de algoritmos de pré-processamento dos dados e de algoritmos para diversas técnicas de mineração de dados, além de possuir uma interface gráfica amigável que disponibiliza grande parte dos recursos, sendo que os demais não disponibilizados podem ser utilizados com uso de APIs.

Por ser desenvolvida em Java, que é uma linguagem multiplataforma orientada a objetos, pode ser executada em plataformas distintas, enquanto sua orientação a objetos evidenciam vantagens como modularidade, polimorfismo, encapsulamento, reutilização de código, dentre outros. Além dessas características, há diferentes recursos de documentação e ao realizar a instalação da ferramenta, um pacote de documentação é disponibilizado contendo informações da API.

A ferramenta Weka pode ser utilizada de duas formas, a primeira através da interface gráfica para manipulação interativa de algoritmos de mineração de dados e a segunda pela chamada em um código Java. Para ambas as formas, é necessário que a entrada de dados seja em um arquivo com formato próprio, chamado ARFF (*Attribute-Relation File Format*).

Os arquivos ARFF foram desenvolvidos pelo projeto de aprendizagem de máquina do Departamento de Ciência da Computação da Universidade de Waikato para o uso com o software Weka. Duas sessões distintas são características de um arquivo ARFF, informações do cabeçalho e informações dos dados. O cabeçalho contém o nome da relação, uma lista de atributos e seus tipos ou valores que pode representar. Um exemplo de cabeçalho é ilustrado pela Figura 14.

```

% Título: Histórico de Visualização no uso da TV
%
% Dados reais do comportamento de visualização fornecidos pelo IBOPE
%
% Autor: Adriano dos Santos Lucas
% adriano.lucas@gmail.com / adriano_lucas@dc.ufscar.br

@RELATION TV-DIGITAL

@attribute emissora NUMERIC
@attribute nomeprograma string
@attribute descritor_categoria string
@attribute diadasemana string
@attribute periodo string
@attribute porcentagem_visu string

```

**Figura 14 - Cabeçalho de um arquivo ARFF**

As instâncias, ou seja, os registros a serem minerados são o que compõem a segunda parte, conforme ilustrado na Figura 15. Essas instâncias contêm um valor separado por vírgula para cada atributo declarado no cabeçalho. Quando há ausência de um valor para determinado atributo, o símbolo “?” é utilizado.

```

@data
006,"HOJE EM DIA","Variedade","segunda","manha","muito"
006,"BALANCO GERAL","Jornalismo","segunda","tarde","muito"
006,"PROGRAMA DA TARDE","Variedade","segunda","tarde","muito"
006,"SP RECORD","Jornalismo","segunda","noite","muitopouco"
006,"FALA BRASIL","Jornalismo","terca","manha","regular"

```

**Figura 15 - Informações dos dados de um arquivo ARFF**

A ferramenta Weka foi descrita, pois no trabalho desenvolvido foi utilizado o algoritmo Apriori implementado por ela. Deste modo, com o uso do Weka é possível realizar mineração de dados e, por conseguinte, aprimorar as recomendações de um sistema de recomendação. Ao combinar o uso da mineração de dados com a filtragem de informação, é possível oferecer a personalização.

## 4 Sistema de Recomendação para ambientes multiusuário

O sistema proposto nesta dissertação visa oferecer personalização na TVD mediante recomendações para grupos de telespectadores. A personalização pode ser mapeada para utilizar diferentes técnicas ou algoritmos com o objetivo de recomendar conteúdo. Este trabalho estabelece a seqüência de execução dos módulos, conforme a Figura 16, dentro do domínio de TVD, para obter personalização a partir de componentes de sistema de recomendação. A seqüência de passos e as características são descritas admitindo um possível cenário de uso (LUCAS; ZORZO, 2009a).

Assim, são descritas as estratégias de como devem ser coletadas e armazenadas as informações (passo 1, 2 e 3), como estas devem ser processadas para descobrir informações úteis do grupo de telespectadores (passo 4 e 5), como transformar as informações em recomendações (passo 6 e 7) e posteriormente, como apresentar as sugestões aos telespectadores (passo 8).

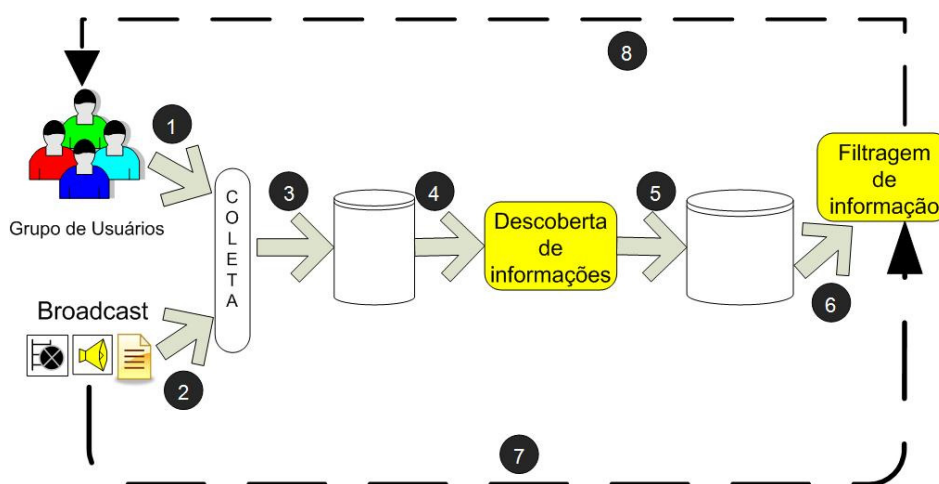


Figura 16 – Sequência de execução dos módulos

- (1) O grupo de telespectadores interage com a programação da TV e durante este período, algumas informações referentes à visualização são coletadas implicitamente. Desse modo, é possível obter um histórico de visualização do grupo.
- (2) As emissoras enviam vídeo, áudio e metadados referentes aos programas que estão sendo visualizados e algumas informações são coletadas para recomendações futuras.
- (3) Os dados referentes ao comportamento de visualização dos telespectadores e metadados dos programas visualizados são armazenados em um arquivo, localizado no STB.

- (4) Com a utilização de técnicas e algoritmos, informações que refletem as preferências dos telespectadores são obtidas do arquivo armazenado no STB, possibilitando as recomendações que se adequam melhor ao grupo. A escolha dos algoritmos para realizar tais tarefas pode depender do domínio da aplicação bem como da personalização desejada.
- (5) Após o processamento de tais informações, estas são manipuladas e armazenadas em um novo arquivo
- (6) e (7) É realizada uma intersecção entre as preferências descobertas contidas no arquivo e os metadados referentes à programação para efetuar a filtragem de informação com o objetivo de encontrar os conteúdos adequados a serem recomendados.
- (8) Por fim, as recomendações são apresentadas aos telespectadores quando solicitadas.

Essa sequência de execução é compatível com qualquer sistema de TVD existente e o principal objetivo é descobrir diferentes padrões de comportamento e regras para efetuar recomendações direcionadas a um grupo de telespectadores. Essa sequência foi implementada como prova de conceito e originou o sistema de recomendação RePTVD. Este sistema utiliza técnicas de mineração de dados e filtragem de informação para efetuar as recomendações e pretende-se não somente demonstrar a utilização destas técnicas, mas utilizá-las como partes de um processo de recomendação, o qual apresenta todos os detalhes necessários para efetuar recomendações.

Para o desenvolvimento do RePTVD, foram consideradas características inerentes à TVD como o baixo envolvimento com o ambiente, dispositivos de entrada, grupo de visualização, entre outros. Sendo assim, o RePTVD não é simplesmente uma adaptação de um sistema de recomendação da WEB que pode ser utilizado para a TVD. É um sistema totalmente baseado nas características da TVD que não está atrelado a nenhum vídeo e sua existência é independente dos programas audiovisuais em transmissão. O RePTVD contempla os passos que estão demonstrados na Figura 16 e a seguir, sua arquitetura e o processo de recomendação são detalhados.

Nas seções seguintes, proceder-se-á uma descrição mais pormenorizada do sistema RePTVD, sua arquitetura, o processo de recomendação e a implementação.

## **4.1 Sistema RePTVD**

Para que o sistema RePTVD possa recomendar itens, produtos ou conteúdos são necessárias técnicas e estratégias para coleta e manipulação de informações, além da apresentação das sugestões aos telespectadores.

Primeiramente, a coleta de informações para a adaptação ou personalização de conteúdo pode ser realizada de maneira explícita ou implícita. O método explícito exige tempo e esforço por parte dos telespectadores e não se adapta à evolução de suas preferências (CHORIANOPOULOS, 2008) (VILDJIOUNAITE et. al, 2008). Já a coleta implícita pode ser realizada por monitoramento e proporciona diminuição do esforço dos telespectadores, além de deduzir seus interesses mediante o histórico de visualização (GOREN-BAR; GLINANSKY, 2004). Pesquisa realizada por O'Sullivan et. al (2004a), mostrou que os perfis implícitos são tão precisos, se não mais, quanto suas contrapartes explícitas. O RePTVD coleta as informações de forma implícita mediante o monitoramento do comportamento de visualização dos telespectadores.

Em segundo lugar, o componente central dos sistemas de recomendação é a técnica de recomendação a ser empregada para manipular as informações. Para realizar a filtragem de informação, os sistemas de recomendação tradicionais usam as técnicas de filtragem colaborativa, filtragem baseada em conteúdo e a junção das duas anteriores, o método híbrido. Porém, para aprimorar a qualidade das recomendações, diversos autores adotam combinações de técnicas juntamente com filtragem de informação para gerar as recomendações. A rapidez para gerar a recomendação também é um fator relevante em alguns domínios. O RePTVD descobre as informações pelo uso de mineração de dados e depois utiliza filtragem de conteúdo para ofertar a recomendação.

Por fim, há diversas possibilidades para representar as recomendações e uma delas, adotada pelo RePTVD, é uma lista de recomendação com os conteúdos mais similares às preferências dos telespectadores. Preferencialmente, os conteúdos que são assistidos frequentemente não devem ser recomendados. Porém, há relevância em recomendar um programa já assistido caso não tenha sido visualizado por algum tempo, além de outros programas com conteúdos semelhantes que podem ser desconhecidos pelo telespectador. Desse modo, foi adotada a recomendação de conteúdos frequentes como também de conteúdos que são novidades aos telespectadores.

O desafio de um sistema de recomendação para TVD é representar e oferecer recomendações de acordo com as preferências individuais dos integrantes de um grupo, identificando-os entre todos em um ambiente multiusuário de forma implícita. O RePTVD enfrenta esse desafio, porém não identifica especificamente qual membro do grupo está assistindo TV em determinado momento. O RePTVD descobre os padrões de comportamento e a tendência dos membros de um grupo e por essas descobertas é possível oferecer conteúdo adequado independente de quem esteja assistindo a TV.

#### 4.1.1 Arquitetura do RePTVD

A arquitetura do RePTVD foi desenvolvida com a opção de alocação das decisões no cliente, ou seja, a aplicação permanecerá residente no STB. Um requisito fundamental para o RePTVD é o STB possuir memória suficiente para a persistência de informações referentes ao histórico de visualização dos telespectadores e também ter poder de processamento capaz de suprir a demanda da aplicação por este recurso. O histórico varia de tamanho, dependendo do período de visualização de determinado grupo, mas considerando que o desenvolvimento dos STBs tende a evoluir, tanto a capacidade de armazenamento como também o poder de processamento não podem ser considerados um problema. Atualmente poder haver uma limitação de recursos em relação ao STB, que será superado com sua evolução. O sistema de recomendação RePTVD é composto de três módulos como ilustrados na Figura 17.

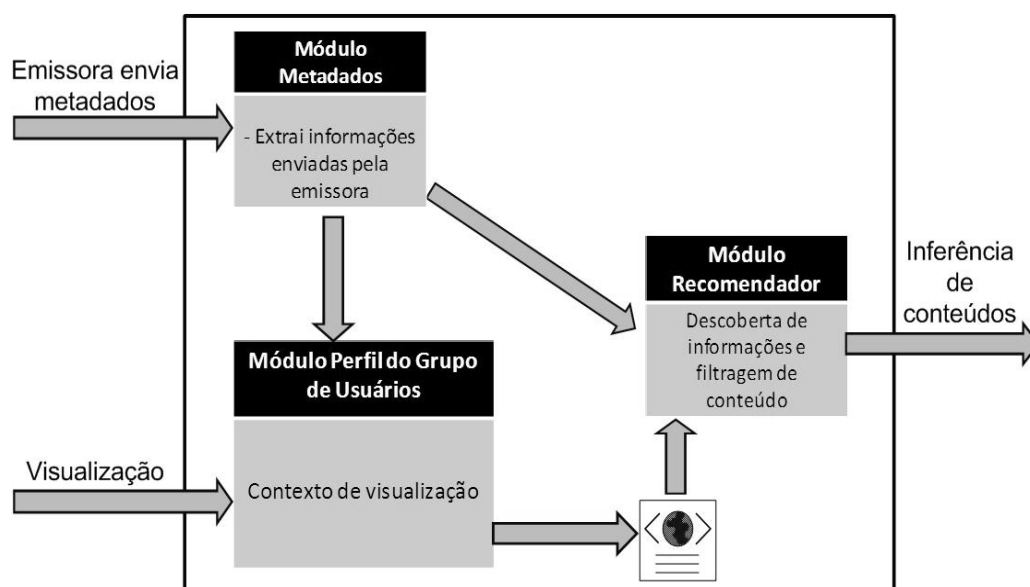


Figura 17 - Módulos do sistema RePTVD

O RePTVD possui interação local, pois considera a transmissão unidirecional, na qual o STB funciona como servidor de aplicações. Assim, diferentemente de outros tipos de



serviços como *T-commerce*, *T-bank* e acesso a e-mail, o RePTVD não considera a infraestrutura de canal de retorno. Novas possibilidades para a personalização poderão ser oferecidas pelo canal de retorno, como por exemplo, coletar as informações localmente e fazer o processamento remoto ou também utilizar as preferência de vários grupos e efetuar filtragem colaborativa. Porém há questões ainda não equacionadas sobre o canal de retorno em relação a sua eficiência em desempenho e aplicabilidade.

Nas seções seguintes será descrito a funcionalidade de cada módulo que compõe o RePTVD, além do processo de recomendação proposto, o qual é responsável pela interligação destes módulos e outros detalhes para resultar em recomendações aos telespectadores.

#### 4.1.2 Módulo Metadados

O módulo de metadados analisa os dados transmitidos pela tabela SI e extrai as informações referentes aos conteúdos televisivos importantes para o RePTVD durante o uso da TV pelos telespectadores.

A Figura 18 ilustra as informações relevantes para o sistema RePTVD, sendo que o número do canal, o nome do programa e a categoria do programa estão destacados por serem coletados por esse módulo. O RePTVD armazena os dados coletados em um arquivo ARFF, que é um formato próprio do pacote Weka que contém o algoritmo de mineração de dados utilizado neste trabalho (WITTEN; FRANK, 2005).

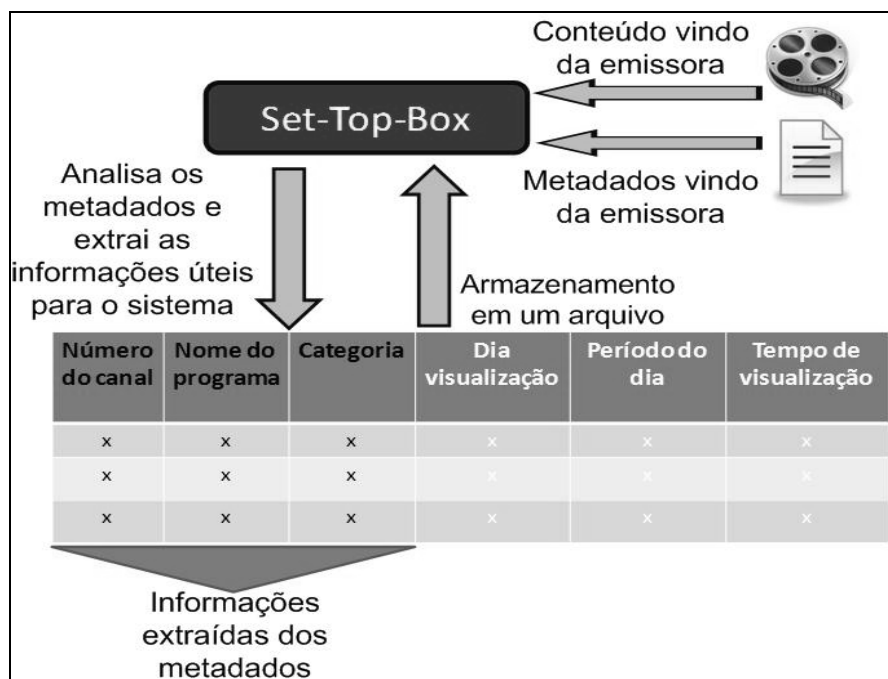


Figura 18 - Extração dos metadados

A tabela SDT disponibiliza as informações referentes ao provedor do serviço (emissora) e serviço (nome do programa) e a tabela EIT contém informações sobre o início e a duração do serviço. Essa também contém descritores que podem ser utilizados pelo provedor de serviço para associar informações adicionais como descritor de conteúdo que informa o gênero e subgênero, descritor de classificação indicativa que define faixa etária do programa e um descritor de eventos curtos com uma sinopse. A tabela EIT contém os dados da grade de programação referente a um período de até 14 dias. A tabela TDT é utilizada pelo RePTVD para obter a data e horário atuais. Os dados referentes a essas três tabelas supracitadas ficam disponíveis no STB e podem ser acessadas através de APIs.

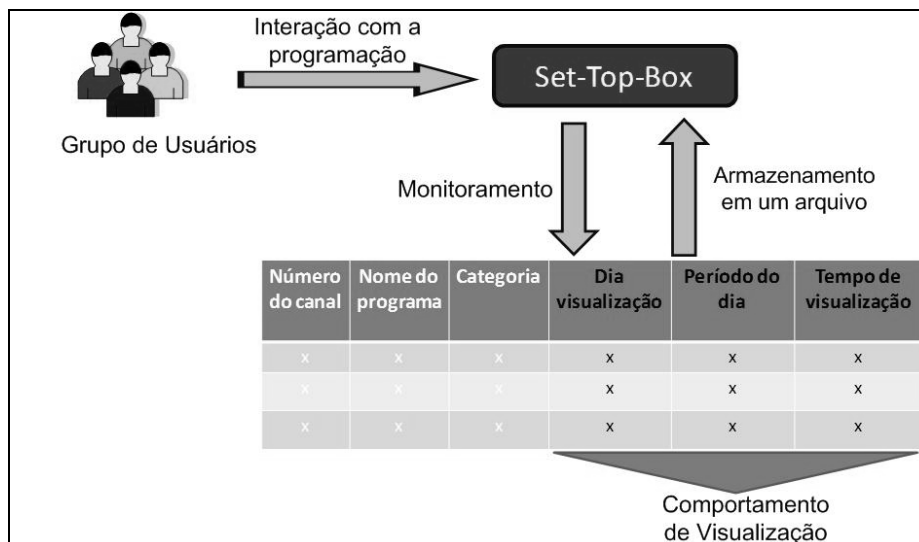
O módulo metadados atua em conjunto com o módulo perfil do grupo de telespectadores e ambos armazenam as informações no mesmo arquivo ARFF. Este módulo de metadados foca nos dados referentes aos programas, enquanto o módulo perfil do grupo de telespectadores, foca nos dados referentes ao comportamento de visualização dos telespectadores. Assim que a TV é ligada, os dois módulos tornam-se ativos e em cada troca de canal o arquivo ARFF é atualizado.

#### **4.1.3 Módulo Perfil do Grupo de Telespectadores**

O módulo perfil do grupo de telespectadores coleta informações de visualização do grupo de forma implícita. Esta coleta é realizada pelo monitoramento da troca de canais e tempo que o telespectador assiste cada um deles. Para realizar a coleta implícita, é necessário que o sistema residente ao STB seja habilitado pelo grupo de telespectadores. Dessa forma, contempla-se a privacidade e opção do grupo para autorizar o sistema a coletar dados e efetuar as recomendações.

Esse módulo utiliza o dia, o período do dia e o tempo de visualização como previsores para efetuar recomendação. Tais informações são extraídas da tabela TDT, com exceção do tempo de visualização que é calculado pelo RePTVD, e armazenadas no arquivo ARFF simultaneamente com as informações do módulo de metadados. Esse arquivo é armazenado no STB e atualizado de forma contínua e autônoma conforme a interação dos telespectadores com a programação da TV. Além deste, outro arquivo ARFF que contém categoria, período do dia e tempo de visualização é armazenado. Este arquivo de frequência de categorias será utilizado para efetuar recomendações de tempo real. Desse modo, este arquivo permite adaptar as recomendações de conteúdo por período do dia, e assim inferir a preferência dos telespectadores por programas diferentes em períodos

diferentes. Com as informações adotadas presentes nos arquivos ARFFs, é possível descobrir características inerentes ao grupo de telespectadores de um STB. A Figura 19 ilustra o módulo descrito.

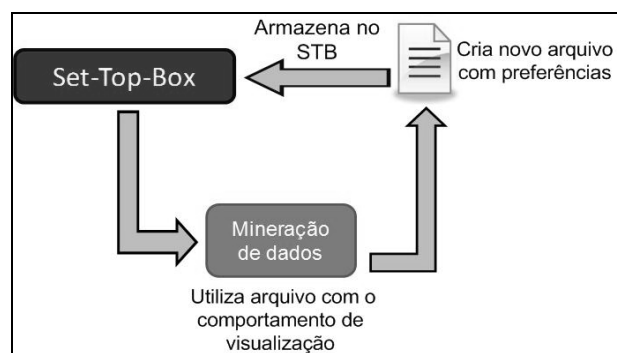


**Figura 19 - Informações dos telespectadores**

#### 4.1.4 Módulo Recomendador

Após a coleta e armazenamento das informações no arquivo ARFF, este se torna o histórico de visualização do grupo. Após determinado tempo de uso da TV, esse conjunto de informações certamente conterà muitos dados. Parte dessas informações pode não ser relevante e, conseqüentemente, não ser aproveitada pelo sistema de recomendação. Dessa forma, o módulo recomendador possui duas funções que consistem em descobrir informações e filtrá-las para efetuar a recomendação.

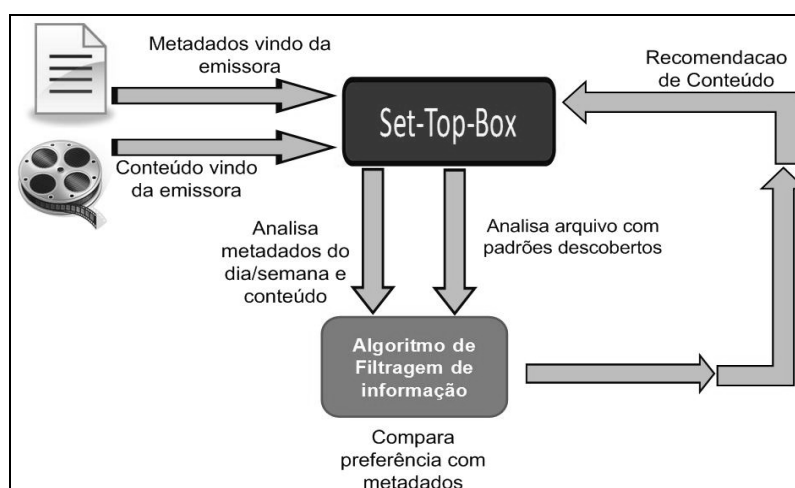
A primeira função é responsável por utilizar o arquivo armazenado no STB para realizar a captura de informações específicas e descobrir padrões ou regras que permitam uma melhor compreensão dos dados. Sendo assim, o algoritmo Apriori é utilizado para executar essa função. Com isso, as informações obtidas tornam-se relevantes para o contexto em que o telespectador está inserido e as recomendações de conteúdos refletem as preferências do grupo de telespectadores. A mineração permite que o sistema de recomendação de conteúdo efetue recomendações baseadas principalmente no conhecimento acumulado e armazenado no STB. A Figura 20 ilustra a primeira função do módulo recomendador.



**Figura 20 - Descoberta de informações úteis**

A técnica de mineração de dados foi escolhida por evidenciar tendências e comportamentos implícitos previamente desconhecidos e potencialmente úteis, além de demonstrar a viabilidade da estratégia do sistema de recomendação desenvolvido. Os conhecimentos obtidos pela mineração de dados são geralmente expressos na forma de regras e padrões (HAN; KAMBER, 2006). Assim, este módulo realiza a mineração pela utilização do arquivo de comportamento de visualização do grupo de telespectadores e após descobertas as regras e conhecimento, um novo arquivo é armazenado no STB.

A segunda função do módulo recomendador é utilizar a filtragem de conteúdo para comparar as preferências descobertas com o conteúdo enviado pelas emissoras e efetuar a criação de uma lista de recomendação dinâmica. A Figura 21 ilustra como é realizada a filtragem de informação.



**Figura 21 - Filtragem de informação**

O processo de filtragem de informação ocorre a cada 24 horas e uma lista com as sugestões é gerada. Ao solicitar a recomendação, o RePTVD apresenta esta lista contendo quatro recomendações, sendo duas referentes a conteúdos novos seguindo o padrão de comportamento e duas que podem ser mais comuns aos telespectadores.

Além disso, são fornecidas no máximo quatro recomendações de tempo real, ou seja, a partir do momento que a TV é ligada, o RePTVD verifica o relógio interno do STB. Ao obter a data e horário, realiza uma pesquisa no arquivo que contém a frequência de categorias por período e aplica a filtragem que gera uma recomendação por período. Os períodos adotados são madrugada, manhã, tarde e noite. Deste modo, se em determinada casa a TV é ligada somente à noite, o relógio do STB é verificado e o RePTVD fornece uma recomendação de tempo real específica para esse período.

## 4.2 Processo de Recomendação

O RePTVD envolve os passos de preparação dos dados, a procura por padrões, a avaliação do conhecimento e a realização de sugestões para efetuar recomendações de conteúdo. Desse modo, o processo de recomendação é composto pela junção de todos os passos enumerados acima, produzindo recomendações de conteúdo. Esse processo envolve a execução dos três módulos que foram descritos em seções anteriores. Na Figura 22 é possível observar todo o processo de recomendação e em seguida é realizada uma descrição pormenorizada de cada passo que o compõe.

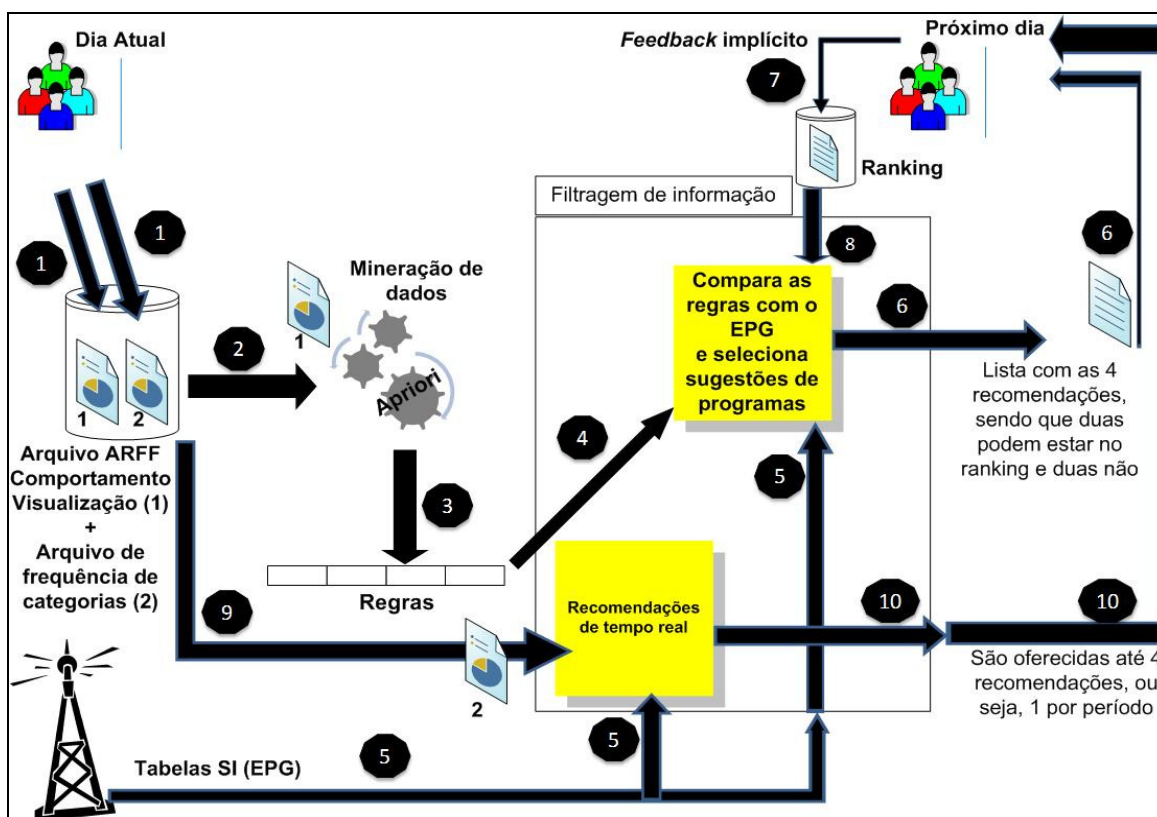


Figura 22 - Mecanismo do RePTVD

O primeiro passo ocorre durante o tempo em que a TV está ligada e consiste em coletar implicitamente o comportamento de visualização do grupo e armazenar tais

informações em um arquivo ARFF. A Figura 23 ilustra como o sistema RePTVD armazena o comportamento de visualização.

```
% Título: Histórico de Visualização no uso da TV
%
% Dados reais do comportamento de visualização fornecidos pelo IBOPE
%
% Autor: Adriano dos Santos Lucas
% adriano.lucas@gmail.com / adriano_lucas@dc.ufscar.br
% Data: Janeiro de 2008

% Domicílio: 01
% Data: 05-03-2008 e 06-03-2008

@RELATION TV-DIGITAL

@attribute emissora NUMERIC
@attribute nomeprograma string
@attribute descritor_categoria string
@attribute diadasemana string
@attribute periodo string
@attribute porcentagem_visu string

@data
6,"HOJE EM DIA","Variedade","segunda","manha","muito"
6,"BALANCO GERAL","Jornalismo","segunda","tarde","muito"
6,"TODO MUNDO ODEIA O CHRIS VES","Serie/seriado","segunda","tarde","muito"
6,"PROGRAMA DA TARDE","Variedade","segunda","tarde","muito"
6,"SP RECORD","Jornalismo","segunda","noite","muitopouco"
%
% DIA 06
6,"FALA BRASIL","Jornalismo","terca","manha","regular"
6,"HOJE EM DIA","Variedade","terca","manha","muitopouco"
4,"VIDEO SHOW","Variedade","terca","tarde","muitopouco"
4,"VALE A PENA VER DE NOVO","Novela","terca","tarde","muito"
4,"FLASH SP TV VIVO VES","Jornalismo","terca","tarde","muito"
4,"VALE A PENA VER DE NOVO","Novela","terca","tarde","muito"
4,"SESSAO DA TARDE","Filme","terca","tarde","muito"
4,"GLOBO NOTICIA VES","Jornalismo","terca","tarde","muito"
4,"MALHACAO","Novela","terca","tarde","muito"
4,"NOVELA I","Novela","terca","noite","muitopouco"
6,"PROGRAMA DA TARDE","Variedade","terca","noite","muitopouco"
6,"SP RECORD","Jornalismo","terca","noite","moderado"
```

**Figura 23 – Informações sobre o comportamento de visualização armazenado**

Esse arquivo é atualizado a cada mudança de canal, porém um registro é armazenado somente após 60 segundos em um mesmo canal, com o objetivo de minimizar as informações insignificantes devido à constante mudança de canal com uso do controle remoto (*zapping*). Quando o RePTVD é executado pela primeira vez, o arquivo ARFF é criado ou atualizado no STB. Os registros do comportamento de visualização são armazenados durante trinta dias e após isso, as informações são sobrescritas. Essa política foi adotada devido ao espaço restrito, além de renovar o arquivo e consequentemente, as regras geradas se adaptarem mais rapidamente às mudanças de comportamento. O tamanho

médio de cada registro é aproximadamente 62 bytes e com isso, exige-se um espaço de armazenamento de 216 Kbytes por dia, considerando que o telespectador faça uma troca de canal por minuto, o que é perfeitamente aceitável. Com isso, em trinta dias tem-se uma demanda de armazenamento de aproximadamente 6,4 Mbytes, que é compatível com as arquiteturas de STB disponíveis. A quantidade de informações armazenadas para nosso estudo de caso foi de trinta dias, devido à possibilidade de existência de STB com capacidade de armazenamento limitada, porém é possível armazenar dados por períodos maiores.

Além do comportamento do grupo, outro arquivo distinto é armazenado contendo a frequência das categorias assistidas por período, conforme ilustrado na Figura 24.

```
segunda,manha,desenho,pouco
segunda,manha,culinaria,muito
segunda,tarde,novela,moderado
segunda,tarde,filme,muito
segunda,noite,noticiario,pouco
segunda,noite,variedade,muito
```

**Figura 24 - Arquivo com frequência das categorias**

O segundo passo consiste na execução do algoritmo Apriori, que por motivo de desempenho, é programada para ser realizada a cada 24 horas. Sendo assim, as regras geradas contemplam todo o histórico disponível até o momento. Essas regras são armazenadas em tempo de execução do processo (passo 3) para utilização dos próximos passos e não em arquivos. Para demonstrar a utilização da extração de regras de associação no domínio de TVD, foi adotado um cenário de uso representado de acordo com a entrada de dados disponibilizada na Tabela 2.

**Tabela 2 - Exemplo da coleta do comportamento do uso da TV**

Número do canal	Nome programa	Categoria	Dia visualização	Hora visualização	Período de visualização
5	Programa 1	Noticiário	20/04	20:15	2 min.
2	Programa 2	Noticiário	21/04	19:20	10 min.
7	Programa 3	Seriado	21/04	23:30	30 min.
2	Programa 2	Noticiário	22/04	22:00	20 min.
10	Programa 4	Infantil	23/04	21:00	10 min.
2	Programa 5	Novela	23/04	15:00	30 min.

Como descrito anteriormente, as regra de associação consistem no relacionamento  $X \Rightarrow Y$  ( $X$  e  $Y$  são conjuntos de itens com intersecção vazia) associada a um valor de suporte mínimo desejado ( $\text{minSup}$ ) e a um fator de confiança mínimo desejado ( $\text{minConf}$ ). O valor de suporte representa o número de ocorrência de um determinado item ou conjunto de itens sobre o total de tuplas. Deste modo, tem-se a seguinte fórmula:

$$FSup = \frac{X}{N}, \text{ onde } N \text{ é o número total de tuplas.}$$

O valor de confiança é a medida da freqüência em que a relação acontece sobre o item em questão. Assim:

$$FConf = \frac{X \Rightarrow Y}{X}.$$

Para realizar a extração de regras significativas é necessário estipular valores para  $\text{minSup}$  e  $\text{minConf}$ . Neste exemplo foi adotado o valor de  $\text{minSup} = 0,4$  e  $\text{minConf} = 0,6$ . Deste modo, ao aplicar regras de associação nos dados referentes à Tabela 2 para cada métrica, tem-se os valores para  $FSup$ , resultando nos dados da Tabela 3. Para calcular a métrica hora de visualização, foram adotados os períodos manhã, tarde, noite e madrugada. Para cada período de visualização foi considerado tempo de 10 em 10 minutos.

**Tabela 3 - Cálculo de  $FSup$  para os dados da Tabela 2**

<b>Canal</b>	$FSup_{canal2} = \frac{3}{6} = 0,5$	$FSup_{canal5,7,10} = \frac{1}{6} = 0,167$
<b>Programa</b>	$FSup_{prog2} = \frac{2}{6} = 0,3$	$FSup_{prog1,3,4,5} = \frac{1}{6} = 0,167$
<b>Categoria</b>	$FSup_{Noticiario} = \frac{3}{6} = 0,5$	$FSup_{Seriado, \text{ inf antil, novela}} = \frac{1}{6} = 0,167$
<b>Dia Visualização</b>	$FSup_{20e22} = \frac{1}{6} = 0,167$	$FSup_{21e23} = \frac{2}{6} = 0,34$
<b>Horário</b>	$FSup_{Tarde} = \frac{1}{6} = 0,167$	$FSup_{Noite} = \frac{5}{6} = 0,84$
<b>Período</b>	$FSup_{0-9} = \frac{1}{6} = 0,167$	$FSup_{10-19} = \frac{2}{6} = 0,34$



	$FSup_{20-29} = \frac{1}{6} = 0,167$	$FSup_{30-39} = \frac{2}{6} = 0,34$
--	--------------------------------------	-------------------------------------

Depois de realizados os cálculos de FSup, as variáveis que possuem um suporte desejado, ou seja,  $FSup \geq \text{minSup} = 0,4$  foram canal 2, categoria noticiário e horário noturno. Assim, ao aplicar o FConf relacionado ao horário, por exemplo, pode-se obter:

$$FConf = \frac{\text{Noturno} \Rightarrow \text{Noticiário}}{\text{Noturno}}$$

$$FConf = \frac{3}{5} = 0,6$$

Com o resultado obtido no exemplo acima, pode-se dizer que essa regra é relevante, pois indica que 60% da programação noturna é noticiário. Outro exemplo seria relacionar duas métricas, categoria e horário, com suporte favorável. Assim:

$$FSup_{\text{noticiario,noturno}} = \frac{3}{6} = 0,5$$

Esse fator é desejável, pois é maior que 0,4. Aplicando o FConf tem-se:

$$FConf = \frac{\text{Noturno, Noticiario} \Rightarrow \text{Canal}}{\text{TotalNoturno} / \text{Noticiario}}$$

$$FConf = \frac{2}{3} = 0,67$$

O resultado obtido de FConf é maior que o minConf adotado e com isso pode-se concluir que no período noturno geralmente são visualizados programas de noticiário, com preferência aos do canal 2. Com isso pode-se analisar o EPG e efetuar a recomendação de conteúdo baseado nessas regras descobertas.

O quarto passo do processo consiste no uso das regras descobertas pelo Apriori para efetuar a filtragem de informação. A Figura 25 ilustra como o Apriori retorna as regras com base em dados descritos em (LUCAS, ZORZO, 2008).

Melhores Regras encontradas:

1. categoriaprograma=Noticiario 4 ==> hora=Noite 4 conf:(1)
2. nomeprograma=P5 3 ==> numerocanal=canal5 3 conf:(1)
3. numerocanal=canal2 3 ==> nomeprograma=P2 3 conf:(1)
4. nomeprograma=P2 3 ==> numerocanal=canal2 3 conf:(1)
5. periodovisu=pouco 2 ==> numerocanal=canal2  
nomeprograma=P2 categoriaprograma=Noticiario hora=Noite 2 conf:(1)
6. numerocanal=canal2 categoriaprograma=Noticiario 2 ==> nomeprograma=P2  
hora=Noite periodovisu=pouco 2 conf:(1)
7. categoriaprograma=Filme 2 ==> hora=Noite periodovisu=moderado 2
8. numerocanal=canal2 periodovisu=pouco 2 ==> nomeprograma=P2  
categoriaprograma=Noticiario hora=Noite 2 conf:(1)
9. nomeprograma=P2 categoriaprograma=Noticiario 2 ==> numerocanal=canal2  
hora=Noite periodovisu=pouco 2 conf:(1)
10. nomeprograma=P2 hora=Noite 2 ==> numerocanal=canal2  
categoriaprograma=Noticiario periodovisu=pouco 2 conf:(1)

**Figura 25 - Regras descobertas pelo algoritmo Apriori**

Normalmente, este algoritmo produz um número significativo de regras e nem todas podem ser consideradas úteis. Dessa maneira, para decidir as que realmente serão consideradas úteis, são aplicadas as métricas de suporte e confiança com seus respectivos valores conforme descrito anteriormente. Na Figura 25 são apresentadas 10 regras geradas de acordo com os parâmetros configurados. O valor de suporte mínimo inicia com 100% e diminui 5% até que 10 regras sejam formadas ou o valor chegue a 10%. O valor de confiança é 90 % e as regras geradas são ordenadas de acordo com esse valor.

Ao analisar a melhor regra gerada, a número 1, tem-se: se a categoria de programa é noticiário, então a tendência é que os usuários assistam no período noturno. O número que aparece antes do símbolo “=>” indica o suporte da regra, por exemplo, a regra 1 ocorre quatro vezes, o que corresponde aproximadamente a 40,0%, visto que existe um total de dez registros que formam os dados. O número que aparece no final da regra indica quantas vezes o item posterior aparece para cada ocorrência do item anterior. Assim, na regra 1, das quatro ocorrências da categoria de programa noticiário, foram obtidas quatro ocorrências de noite, sendo assim, confiança de 100.

A partir das regras geradas e para que estas sejam utilizadas no passo 4, é necessário realizar algumas adequações para automatizar o processo de análise dos resultados providos pela mineração, visto que na maioria dos domínios esta análise é realizada por um especialista do domínio. Assim, como pode ser observado na regra 1 da Figura 25, no passo 4 são separados os valores do atributo do antecedente (Noticiário) e do consequente (Noite) por serem relevantes para efetuar a filtragem. Estas adequações permitem a comparação com os dados providos da tabela EIT que formam o EPG (passo 5). Sendo

assim, programas que correspondam às regras geradas são selecionados e uma lista de recomendação é desenvolvida (passo 6). Esses programas são referentes à grade de programação do dia posterior. Logo, a seqüência do processo para geração das recomendações é coletar dados de um determinado dia, realizar a mineração e geração das regras e fazer a filtragem para sugerir conteúdo para o dia seguinte. Nesse dia seguinte, os dados também são coletados, a mineração se refere aos dois dias e a recomendação é feita para o terceiro dia, e assim por diante. A lista de recomendação gerada possui quatro recomendações e fica disponível todo tempo para os telespectadores acessarem.

Para auxiliar na construção dessa lista, foi criado um *ranking* das melhores recomendações (mais frequentes), como pode ser observado no passo 7. Este *ranking* é desenvolvido mediante a utilização de um *feedback* implícito, ou seja, as recomendações que são visualizadas (acertos) são computadas pelo sistema de maneira implícita e inseridas no *ranking*. As recomendações que não são visualizadas (erros) são descartadas e podem ser utilizadas novamente. Esse *ranking* é utilizado no momento de efetuar a filtragem de informação (passo 4 e 5), com o objetivo de identificar as recomendações mais aceitas. Com isso, são disponibilizadas quatro recomendações, sendo duas destas presentes no *ranking* e duas ausentes. Desta maneira, é possível evitar o problema de superespecialização, que faz com que o sistema recomende somente conteúdos habituais ao telespectador e torne o sistema pouco atraente ao telespectador. A abordagem adotada também evita que o sistema recomende somente conteúdos que o telespectador nunca visualizou, o que pode tornar o sistema ineficiente.

Os outros passos correspondem às recomendações de tempo real. Sendo assim, no momento que a TV é ligada a filtragem de informação é realizada comparando os dados da frequência de categorias (passo 9) com a grade de programação (passo 5). Desse modo, são sugeridos conteúdos reportados aos telespectadores sem eles precisarem acessar uma lista recomendação (passo 10).

## 5 Implementação do Sistema RePTVD

Para consolidar e validar as proposições dessa dissertação, foi construído um protótipo do sistema RePTVD. Para isso, a IDE NetBeans 6.5 e a linguagem de programação Java, mais especificamente a API Java TV foram utilizados para o desenvolvimento. A maioria dos sistemas de TVD utiliza a especificação da API Java TV por esta fornecer facilidade para o desenvolvimento de aplicações para TVD.

Para realizar os testes da aplicação, utilizou-se uma emulação em um computador devido à indisponibilidade do sistema ISDTV-T, pois o *middleware* Ginga possui apenas o interpretador Ginga-NCL, sendo ausente o módulo Ginga-J para suportar a execução de Xlets. Sendo assim, para efetuar a emulação de um ambiente de TVD em um desktop e executar o RePTVD, foi utilizado o Xletview (XLETVIEW, 2008), um emulador baseado no *middleware* MHP que foi escolhido por ser *Open Source*. Neste emulador, ilustrado na Figura 26, é possível adicionar uma aplicação para ser emulada a partir do menu *Applications / Manage Applications*.



Figura 26 - Tela inicial do emulador XletView

A API Weka foi utilizada para viabilizar o uso do algoritmo Apriori. Esta API foi adicionada ao projeto e deste modo, mediante as chamadas no código Xlet, foi possível utilizar todos os recursos do Weka. Por não oferecer suporte para essa API, foi necessário realizar uma modificação no emulador XletView. Sendo assim, uma extensão do XletView foi realizada com a adição do pacote weka.jar no arquivo META-INF.

O RePTVD é composto por 14 classes organizadas em 7 pacotes. A arquitetura da aplicação contempla o módulo cliente, sendo que o servidor é o provedor de serviço (emissora). Para melhor esclarecimento da implementação, as classes e os pacotes foram divididos em três diagramas. O primeiro é referente a extração dos metadados e ao armazenamento das informações. O segundo, ao pré-processamento dos dados, a aplicação do algoritmo Apriori e a análise computacional das regras para gerar as recomendações. O terceiro está relacionado com as interfaces do sistema. As especificações das classes e seus relacionamentos presentes no primeiro diagrama de classe estão ilustrados na Figura 27.

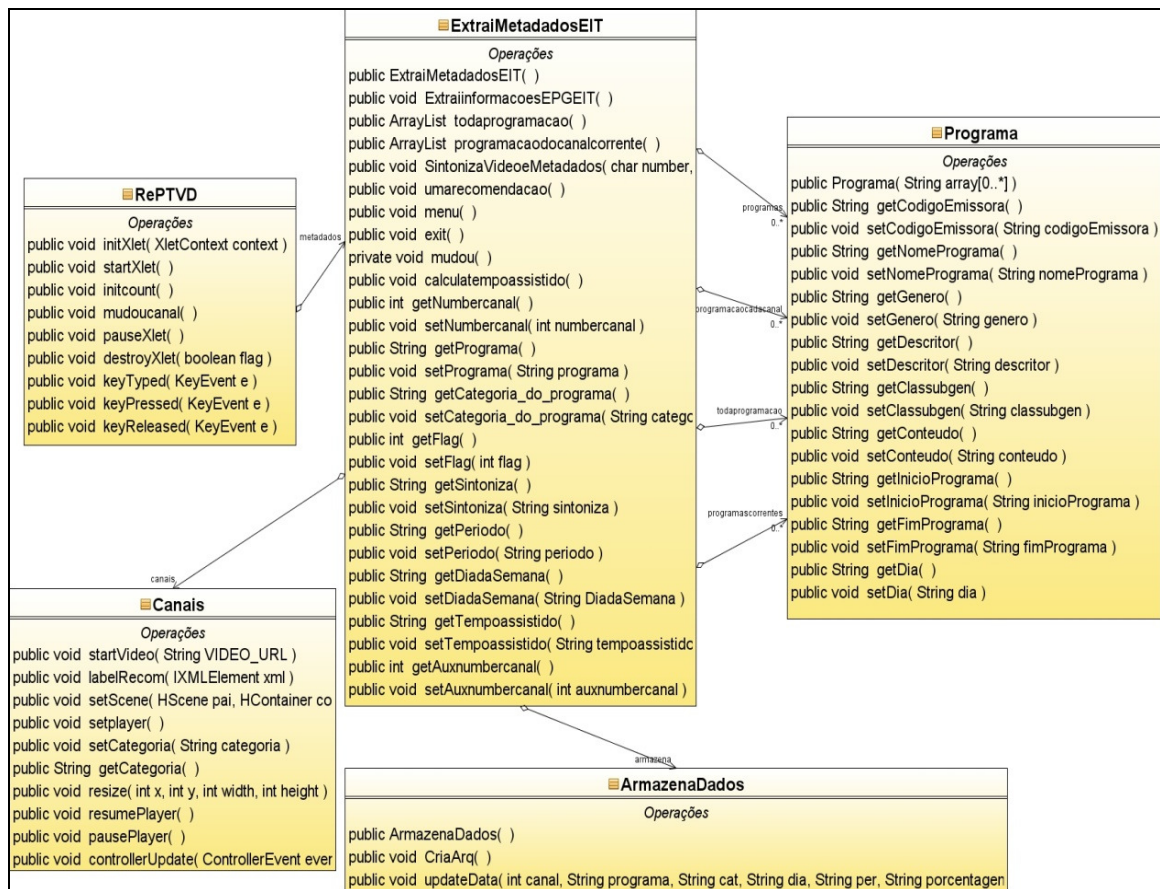


Figura 27 - Diagrama de classes do módulo de metadados e armazenamento das informações

A classe principal (RePTVD) é a responsável pela execução do aplicativo e pela instância da classe de extração de metadados (ExtraiMetadadosEIT), a qual tem como uma das funções instanciar a classe responsável por tocar os vídeos no emulador (Canais). Esta apresenta os vídeos de acordo com os botões do controle remoto do emulador, visto que estes foram mapeados de 1-9 com conteúdos distintos. Os vídeos são capturados de um endereço local já que o emulador não permite obter um *stream* de vídeo a partir de *broadcast*. De maneira semelhante, a classe ExtraiMetadadosEIT obtém os metadados a

partir de um arquivo local que contém os mesmo campos que as tabelas originais conforme a norma da ABNT. A data e horário atual foram obtidos mediante chamada ao sistema operacional e não a partir da tabela TDT. Essa abordagem foi adotada, pois o emulador não oferece suporte para uso das tabelas SI. O arquivo com os metadados pode ser observado na Figura 28.

CÓDIGO DA EMISSORA	NOME DO PROGRAMA	Classificação de Gênero	Descritor de Conteúdo	Classificação de gênero	Classificação de subgênero	Descritor de conteúdo
122	1 MINUTO	0xE	Debate/entrevista	0xE	0x01	Entrevista
013	15 MINUTOS DM 1900	0x9	Humorístico	0x9	0x00	Humorístico
013	15 MINUTOS DM 1930	0x9	Humorístico	0x9	0x00	Humorístico
013	15 MINUTOS SB 1530	0x9	Humorístico	0x9	0x00	Humorístico
013	15 MINUTOS SB 1600	0x9	Humorístico	0x9	0x00	Humorístico
013	15 MINUTOS SSX 0100	0x9	Humorístico	0x9	0x00	Humorístico
013	15 MINUTOS SSX 1700	0x9	Humorístico	0x9	0x00	Humorístico
013	15 MINUTOS SSX 2130	0x9	Humorístico	0x9	0x00	Humorístico
006	50 POR 1 ALVARO GARNERO	0x8	Informação	0x8	0x04	Turismo
125	50 POR 1 ALVARO GARNERO MAD	0x8	Informação	0x8	0x04	Turismo
125	50 POR 1 ALVARO GARNERO NOT	0x8	Informação	0x8	0x04	Turismo
125	50 POR 1 ALVARO GARNERO R	0x8	Informação	0x8	0x04	Turismo
007	8 E MEIA NO CINEMA	0xC	Filme	0xC	0x00	Filme
013	A FILA ANDA DM 1930	0x6	Variedade	0x6	0x00	Auditório
013	A FILA ANDA SB 2000	0x6	Variedade	0x6	0x00	Auditório
013	A FILA ANDA SG 0200	0x6	Variedade	0x6	0x00	Auditório
013	A FILA ANDA SG 1500	0x6	Variedade	0x6	0x00	Auditório
001	A GRANDE CHANCE NOT	0x6	Variedade	0x6	0x05	Game show
004	A GRANDE FAMILIA	0x9	Humorístico	0x9	0x00	Humorístico

**Figura 28 - Arquivo com metadados**

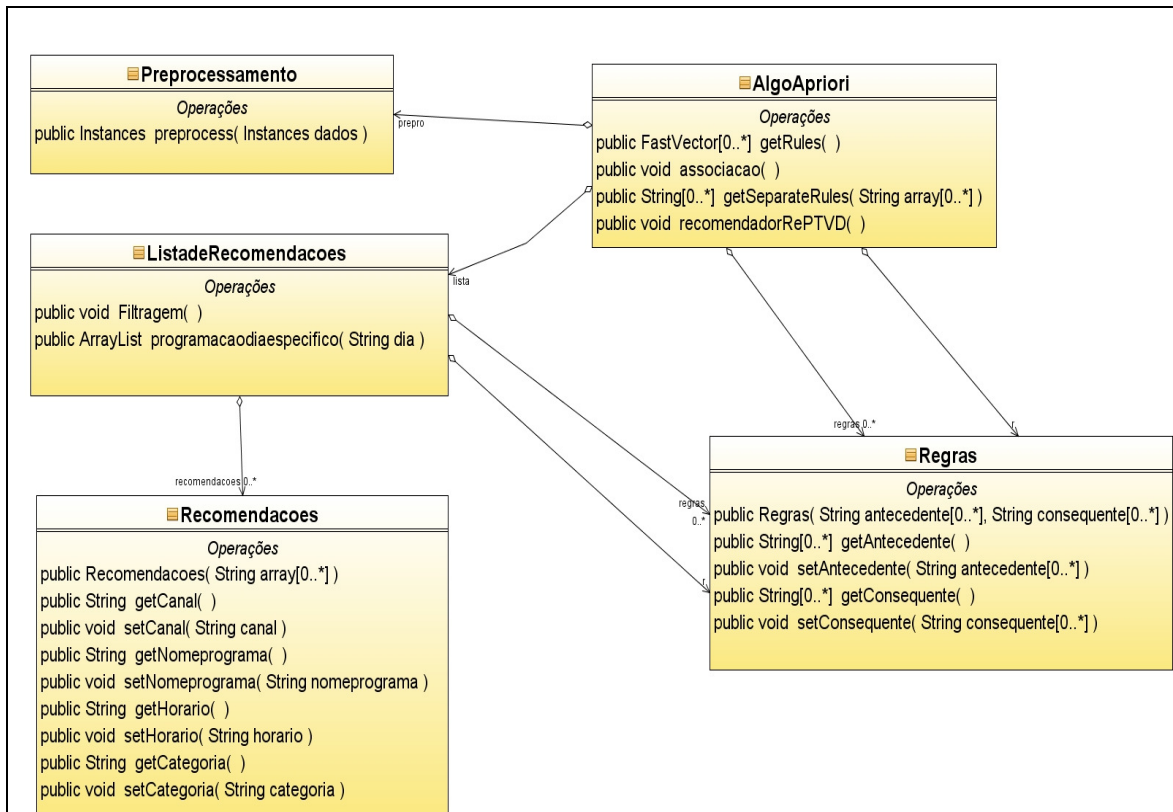
Outra função da classe `ExtraiMetadadosEIT` é efetuar o armazenamento de todas as informações adotadas e relatadas anteriormente em um arquivo ARFF. Para isso, a classe `ArmazenaDados` é instanciada para checar a existência do arquivo ARFF. Se o arquivo existir, é realizada sua atualização, se não, um novo arquivo é criado. Antes de efetuar o armazenamento utilizando a classe `ArmazenaDados`, a classe `ExtraiMetadadosEIT` realiza algumas operações em relação aos dados coletados. Uma operação é referente ao dia de visualização que é transformado de números para *string*. Esta transformação ocorre, pois o algoritmo Apriori trabalha com frequências de itens e sendo assim, se as datas fossem armazenadas em números, dificilmente se repetiriam e o algoritmo seria ineficiente. Outra operação é em relação ao período de visualização, para o qual foram adotados quatro períodos com as faixas de horários madrugada (00:00 às 05:59), manhã (06:00 às 11:59), tarde (12:00 às 17:59) e noite (18:00 às 23:59). A última operação realizada relaciona-se com a porcentagem de visualização, na qual foi criada a fórmula:

$$\delta = \frac{(hvf - hvi) * 100}{hfp - hip}$$

As métricas adotadas correspondem à hora de visualização final (hvf) de um determinado programa, à hora de visualização inicial (hvi), à hora final do programa (hfp)

e à hora inicial do programa (hip). Deste modo, para cada conteúdo visualizado é calculado o  $\delta$  e classificado como: se  $\geq 0$  e  $\leq 20\%$  (muito pouco), se  $>20$  e  $\leq 40\%$  (pouco), se  $>40$  e  $\leq 60\%$  (regular), se  $>60$  e  $\leq 80\%$  (moderado) e se  $>80$  e  $\leq 100\%$  (muito). Novamente, pelo modo como o algoritmo Apriori funciona, é necessário converter para atributos *string*.

O segundo diagrama de classe está ilustrado na Figura 29 com suas especificações das classes e seus relacionamentos.

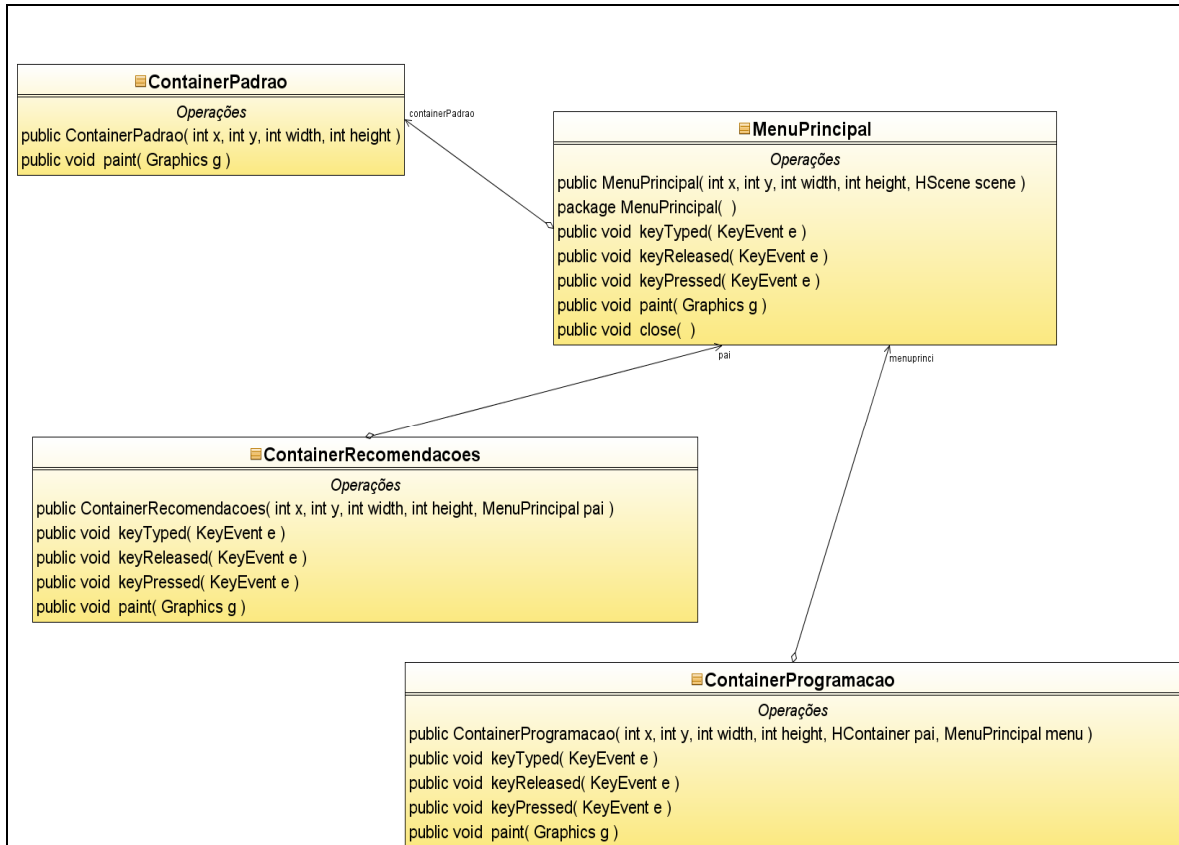


**Figura 29 - Diagrama de classes mineração e filtragem de informação**

As classes contidas nesse diagrama são responsáveis por utilizar os dados gerados e armazenados e efetuar a mineração de dados e filtragem de informação. O primeiro passo é o pré-processamento dos dados (Preprocessamento), que consiste em aplicar dois filtros para transformar os atributos numéricos e *strings* em atributos nominais. É necessário aplicar esses filtros, pois o algoritmo Apriori aceita somente atributos nominais. Após a adequação dos dados, o Apriori (AlgoApriori) é aplicado e as regras geradas pela saída desse são tratadas (Regras) para serem utilizadas na filtragem de informação (ListadeRecomendacoes). Em seguida, as regras são armazenadas (Recomendacoes) para serem apresentadas na interface do sistema.

O terceiro diagrama de classes consiste nas interfaces do sistema e pode ser observado na Figura 30. A classe ExtraiMetadadosEIT instancia a classe principal e compõe a

interface (MenuPrincipal). Esta, por sua vez, instancia a classe responsável por apresentar a parte de baixo do menu do sistema (ContainerPadrao), além das opções de visualizar o programa do canal atual (ContainerProgramacao) e a lista de recomendações oferecidas (ContainerRecomendacoes).



**Figura 30 - Diagrama de classes da interface do sistema**

O telespectador interage com o RePTVD pela interface principal, ilustrada na Figura 31.





**Figura 31 - Interface inicial do sistema RePTVD**

A primeira opção que aparece na interface principal é a visualização da programação, como pode ser observado na Figura 32. Para isso foi desenvolvido um EPG que analisa o horário atual do STB e a partir dele, apresenta toda a programação do canal sintonizado.



**Figura 32 - Guia de programação de cada canal**

A outra opção da interface é para visualizar as recomendações oferecidas pelo RePTVD, como pode ser observado na Figura 33.

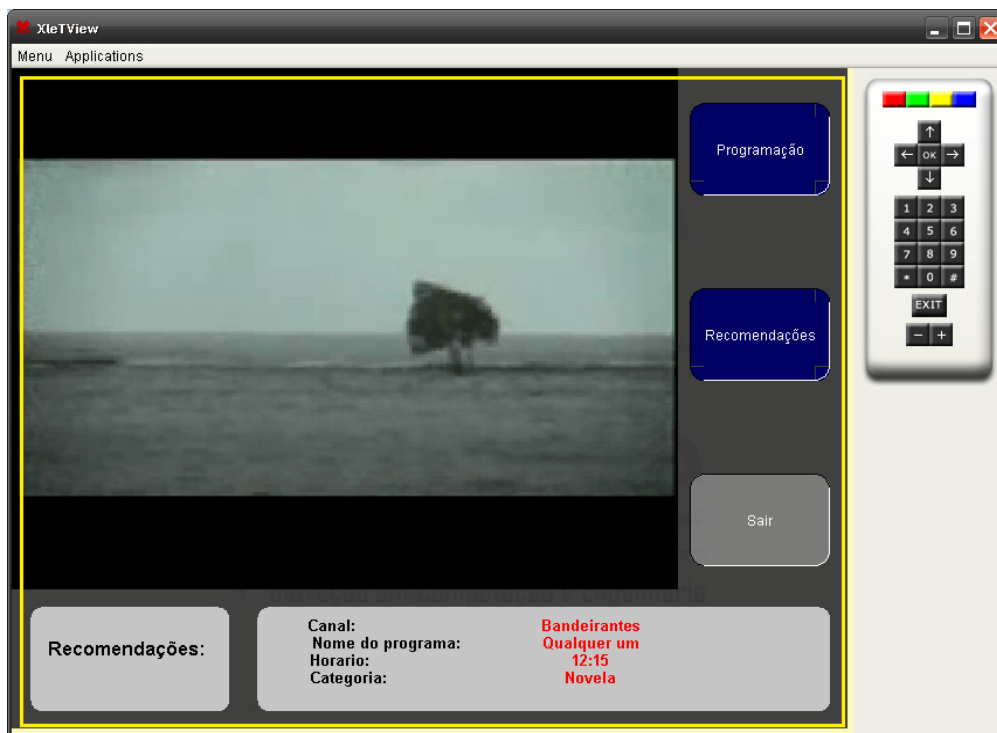


Figura 33 - Lista de recomendações sugeridas

A última opção, ilustrada na Figura 34, permite que o telespectador saia do menu do RePTVD e retorne a visualizar o conteúdo da TV. Todas as opções possibilitam que o telespectador continue a assistir o canal sintonizado, pois este é redimensionado.

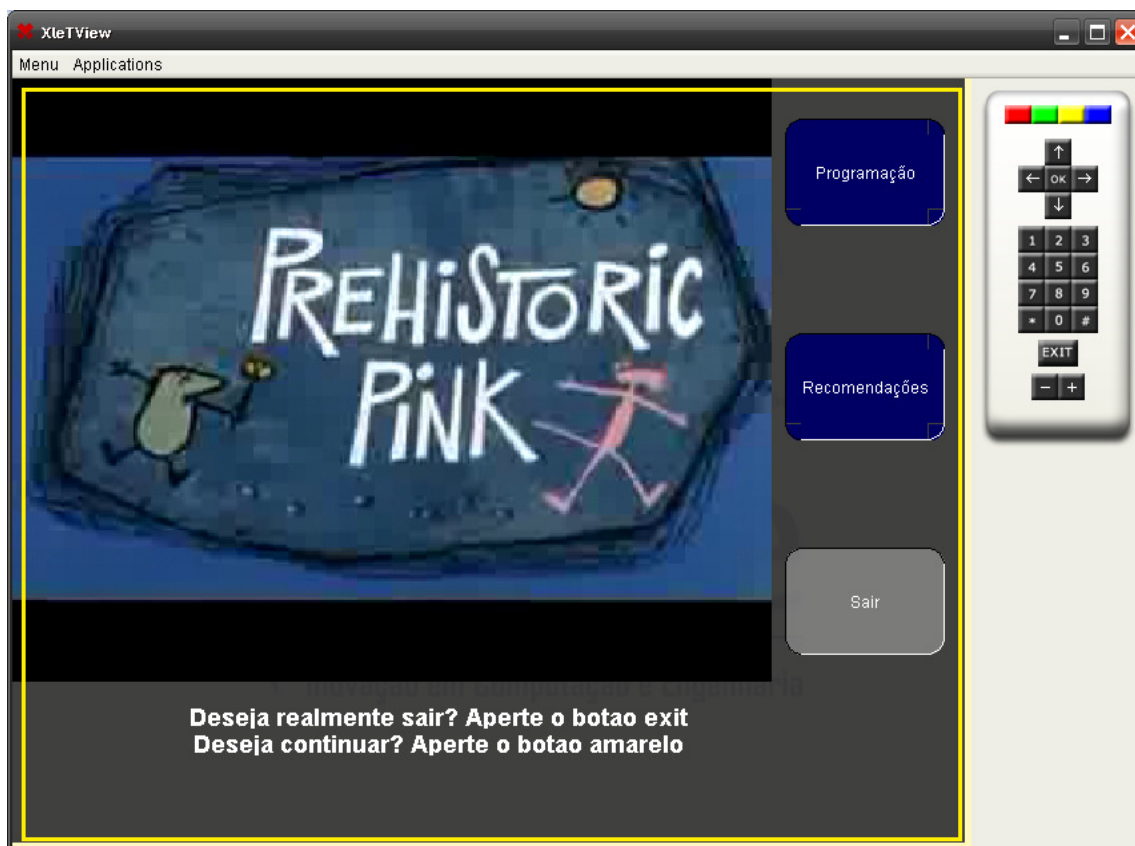


Figura 34 - Interface de saída do sistema

## 6 Experimento e Resultados


De modo a verificar a aplicabilidade do sistema RePTVD, foi realizado um experimento que permite a avaliação da precisão das recomendações. A seguir é descrito, primeiramente, o experimento em si e, em seguida, os resultados obtidos com a avaliação.

### 6.1 Descrição do experimento realizado

O experimento realizado analisou a precisão do sistema RePTVD em identificar os conteúdos de interesse dos telespectadores, oferecidos conforme o processo proposto neste trabalho. As recomendações ofertadas pelo sistema foram avaliadas por uma amostra de quinze pessoas subdivididas em seis grupos (domicílios). O primeiro com duas pessoas, o segundo e o terceiro com três pessoas cada, o quarto e o quinto com duas pessoas cada e o último com três pessoas. A contabilização da eficiência do sistema foi mediante o uso de *feedback* implícito, ou seja, quando o telespectador optava em assistir as recomendações.


Os dados referentes aos telespectadores e ao comportamento de visualização de cada domicílio e da programação de cada canal foram fornecidos pelo IBOPE. Os dados do comportamento de visualização foram obtidos pelo monitoramento de cada minuto durante o período de duas semanas em cada casa. Em relação à grade de programação foram fornecidos dados reais referentes a dez emissoras de canais abertos. Tanto os dados do comportamento das famílias quanto as recomendações oferecidas pelo RePTVD são baseados conforme horário e programas da TV real contidos nessa programação. Para caracterizar a amostra, os dados analisados foram faixa etária, sexo, classe social e grau de instrução do chefe da casa.

Na distribuição percentual da faixa etária pode-se observar que 33% dos telespectadores encontram-se no intervalo 35-45, sendo correspondente ao maior agrupamento. Já o intervalo 65-75 não possui telespectador e três faixas etárias se igualam com o menor percentual (7%) (Gráfico 1).



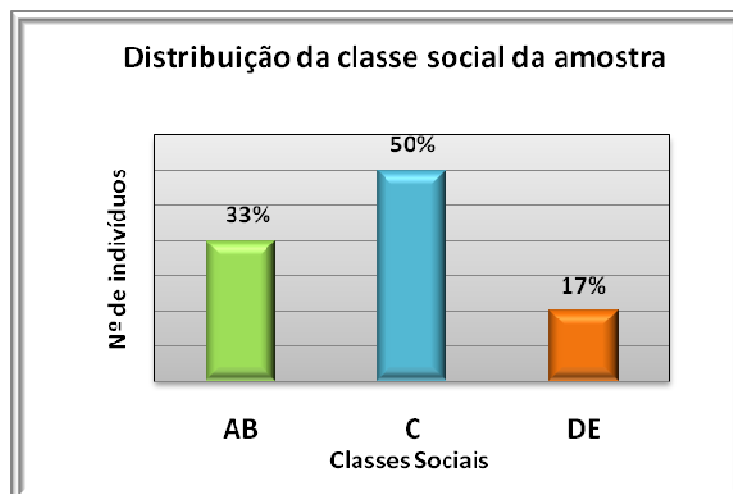
**Gráfico 1- Faixa etária dos membros dos grupos de telespectadores**

O Gráfico 2 demonstra o percentual de homens e mulheres presentes na amostra fornecida pelo IBOPE, sendo que 60% são correspondentes ao sexo feminino e 40% ao sexo masculino.



**Gráfico 2 - Divisão do sexo em relação ao grupo**

O estudo da classe social foi segundo o critério Brasil 2008. Assim, foram encontrados 33%, 50% e 17% dos telespectadores nas classes AB, C e DE, respectivamente (Gráfico 3).



**Gráfico 3 - Classe social**

Em relação ao grau de instrução do chefe da casa (Gráfico 4), é possível observar que há uma igualdade entre os graus “Colegial Completo” (CC) e “Colegial Incompleto” (CI) com 33% e entre “Primário Incompleto” (PI) e “Ginasial Incompleto” (GI) com 17% dos telespectadores que são chefes de casa.




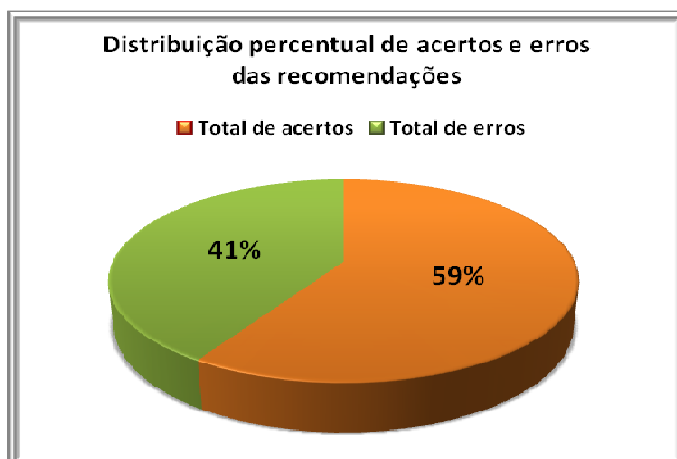
Gráfico 4 - Grau de instrução do chefe da casa

## 6.2 Resultados

A análise dos resultados foi realizada pela medida da precisão do sistema em apresentar conteúdos relevantes às expectativas dos telespectadores pela seguinte fórmula:


$$\delta = \frac{\beta}{\alpha}$$

Onde  $\delta$  corresponde à eficiência do sistema e varia de 0 a 100%,  $\beta$  é o número de recomendações visualizadas pelos telespectadores e  $\alpha$  é o número de recomendações efetuadas. Quanto maior o resultado de  $\delta$ , mais alta a precisão que o sistema de recomendação possui em ofertar conteúdo de acordo com as preferências do grupo de telespectadores. Sendo assim, em relação ao total de acertos e erros das recomendações efetuadas, é possível verificar que 59% das recomendações foram aceitas e 41% das recomendações foram recusadas pelos telespectadores (Gráfico 5).




**Gráfico 5 - Precisão do RePTVD**

Para melhor análise dos resultados encontrados, foram realizados dois gráficos (Gráfico 6 e Gráfico 7) com os dados dos seis domicílios, demonstrando os índices de acertos e erros do sistema de recomendação, tanto da primeira quanto da segunda semana. Ao realizar essa separação, é possível verificar que houve um aumento da aceitação dos conteúdos recomendados de todos os domicílios na segunda semana quando comparada com a primeira.




**Gráfico 6 - Precisão do RePTVD na primeira semana**




**Gráfico 7 - Precisão do RePTVD na segunda semana**

No Gráfico 8, pode-se observar que o maior índice de aceitação dos conteúdos recomendados durante a primeira semana foi de 17 no domicílio 1, e o menor, foi de 11 no domicílio 2.




**Gráfico 8 - Índice de aceitação na primeira semana**

Já no Gráfico 9, o maior índice de recomendações aceitas é de 23, também no domicílio 1, e o menor de 17 no domicílio 6. Porém, esses dados são referentes à segunda semana, sendo assim, já era esperado esse aumento na aprovação e aceitação dos conteúdos recomendados, devido ao maior acúmulo do histórico de visualização.



**Gráfico 9 - Índice de aceitação na segunda semana**

O Gráfico 10 ilustra o total de recomendações efetuadas por domicílio durante as duas semanas. Sendo assim, o maior índice de aceitação foi no domicílio 1 com 40 recomendações aceitas e o menor, 29, no domicílio 2.



**Gráfico 10 - Índice de aceitação durante as duas semanas**

Os resultados demonstrados elucidaram a precisão do sistema em oferecer conteúdo personalizado de acordo com cada grupo de telespectadores. Neste experimento, a realimentação do sistema em relação aos acertos foi mediante a utilização do *ranking*, o qual armazena as recomendações aceitas. Em relação aos erros, não houve realimentação do sistema, sendo descartados tais conteúdos, os quais podem ser utilizados posteriormente em outras recomendações.

A precisão do sistema também foi quantificada, porém deve-se relevar o fato de que os dados utilizados foram do IBOPE e não da utilização em tempo real pelo telespectador. Sendo assim, foi evidenciada a precisão do sistema proposto e o índice de acertos foi de 59%. Porém esta não pode ser generalizada, pois a abordagem utilizada pode ter influenciado os resultados, visto que o fator de resposta de um ser humano frente às recomendações não habituais poderia alterá-los.

Estudo de Zhiwen *et al.* utilizou uma abordagem baseada na união dos perfis de todos os telespectadores para gerar um perfil comum, e assim, recomendar conteúdo baseado neste único perfil. Os resultados deste trabalho mostraram que esta abordagem refletiu as preferências da maioria dos membros constituintes do grupo, sendo que em um dos experimentos realizados foi alcançado 57% de precisão, corroborando os resultados do RePTVD que obteve eficácia na maior parte das recomendações oferecidas, porém, nesta dissertação aborda-se a coleta implícita de dados, diferente do estudo inicialmente citado.

No sistema SRPTV, desenvolvido por Silva, foi realizada coleta explícita e implícita e utilizado os algoritmos *Rocchio* e *kNN*. O primeiro teve melhor desempenho no domínio



específico de filmes, foco do trabalho. Houve satisfação dos usuários participantes do estudo em relação aos guias personalizados propostos pelo SRPTV. Este sistema foi implementado em HTML, PHP, JavaScript e o núcleo funcional encontra-se centralizado no servidor. Ambas as características diferem do RePTVD que utilizou uma linguagem específica para TVD e tem arquitetura local no STB. Apesar do RePTVD não ter sido executado em ambiente real, pode-se dizer que o resultado assemelhou-se com o sistema SRPTV por ter apresentado eficácia de 59%.

Vildjiounaite *et al.* realizou um estudo para ambientes multiusuário em casas inteligentes e com interações implícitas, sendo consideradas tanto as escolhas dos usuários de uma família juntos ou individualmente. Esta abordagem obteve eficácia semelhante, de 60%, comparada com os sistemas que requerem interação explícita do telespectador, assim como o RePTVD.

Hsu *et al.* realizaram um estudo, no qual o mecanismo de recomendação foi baseado em algumas características dos telespectadores coletadas explicitamente. Os autores propuseram um sistema, o AIMED, que obteve precisão em torno de 70%, alcançando a maioria dos usuários do sistema, assim como o RePTVD com 59% de precisão, o qual se diferencia por obter dados implicitamente.

Desse modo, é possível observar que os resultados obtidos no sistema RePTVD corroboraram os resultados dos estudos supracitados, sendo então capaz de obter precisão semelhante ou próxima ao que é encontrado na literatura atualmente.

## 7 Trabalhos Relacionados

Vários sistemas de recomendação para TVD foram construídos para oferecer um serviço diferenciado de personalização e auxiliar os telespectadores a lidar com a abundância de programas de TV. A seguir, são apresentados sistemas que possuem alguma intersecção com este trabalho.

### 7.1 AIMED – Um Sistema de Recomendação Personalizado

O trabalho de Hsu et. al (2007) propõe um mecanismo de recomendação que considera características como atividades, interesses, humores, histórico do uso da TV e informações demográficas (*AIMED – Activities, Interests, Mood, Experiences, Demographic information*), as quais alimentam um modelo de rede neural que infere as preferências de programas dos telespectadores. É utilizada uma abordagem híbrida baseada nos métodos de filtragem de conteúdo e filtragem colaborativa. O sistema utiliza a técnica de redes neurais artificiais (*ANN – Artificial Neural Networks*) para construir o modelo de predição de recomendação e prever efetivamente as preferências dos telespectadores quando as recomendações são requeridas. Especificamente, o estudo utilizou o método de rede neural *back-propagation* (*BPN – Back Propagation Network*), o qual é um dos mais comuns utilizados dentre a técnica. O método BPN é estabelecido pela importação de dados dos módulos perfil e estereótipo do telespectador; comunidade de espectadores; metadados de programas e módulo de contexto de visualização.

O primeiro módulo visa coletar informações básicas sobre o telespectador, o qual responde questionários para configurar todo o sistema conforme suas preferências. Essa abordagem diferencia-se do trabalho proposto nessa dissertação, o qual realiza toda coleta implicitamente sem nenhuma intervenção dos telespectadores.

No segundo módulo, é realizada a recomendação por filtragem colaborativa, ou seja, um telespectador individual e uma comunidade de telespectadores são comparados de acordo com semelhanças de características fundamentais. Além disso, o AIMED atualiza constantemente o modelo de grupos de telespectadores, encontrando informações de recomendação de programas relevantes para a comunidade. A abordagem de filtragem colaborativa não foi utilizada no RePTVD, pois seria necessário considerar o canal de retorno e esta opção foi descartada visto que ainda não há indícios do funcionamento eficaz desse canal de retorno.

O terceiro módulo executa uma rede neural artificial para inferir um conjunto de recomendações baseado no mapeamento entre dados de grupos de telespectadores (atividades, interesses, informações demográficas e preferências de programas) e metadados de programas. O módulo de metadados de programas armazena atributos de programas, os quais seguem as categorias definidas pela Comissão de Comunicação Nacional de Taiwan. O RePTVD utiliza a mineração de dados para inferir as recomendações e baseia-se no mapeamento entre os dados coletados implicitamente e os metadados dos programas.

O último módulo é responsável por registrar o comportamento de visualização do telespectador, por exemplo, número do canal, hora da visualização e duração da visualização em cada canal, e efetuar um mapeamento com diferentes tipos de humor. Sendo assim, os telespectadores têm que prover informações de humor pressionando o “botão humor” presente no controle remoto. Uma rede neural artificial é modelada para relacionar diferentes tipos de humor e diferentes categorias de programas.

Os resultados da avaliação indicaram que o sistema AIMED aumentou a precisão da recomendação e diminuiu os erros de predição. Além disso, as redes neurais artificiais sugerem que os humores dos telespectadores e estilos de vida representam papéis importantes na produção de recomendação precisa de programas de TVD. Portanto, os estados emocionais dos usuários deveriam ser considerados no desenvolvimento de serviços de TVD. Entretanto, torna-se incômodo fazer com que os telespectadores informem através do controle remoto os seus humores.

## **7.2 The iMEDIA System**

Bozios et. al (2001) apresentam uma abordagem que permite a identificação de grandes grupos de telespectadores pelas empresas de publicidade e possibilita o desenvolvimento de técnicas de publicidade e oferta de marketing personalizado. Os dados demográficos, as preferências e a análise da interação do consumidor com a TVD são coletados automaticamente e assim, o sistema define os perfis dos consumidores e seus agrupamentos. Os dados são armazenados a priori no STB e posteriormente enviados para um servidor que aplicará a técnica de mineração de dados.

Diferentemente da abordagem adotada por esses autores, o RePTVD coleta dados de comportamento de visualização de forma implícita e os dados permanecem no STB para descoberta de padrões de comportamento pela aplicação de mineração de dados.

### **7.3 TV3P: Um assistente adaptativo para personalização na TV**

Zhiwen e Xingshe (2004) desenvolveram um assistente adaptável, TV3P (*TV Program Personalization for PDR*), para oferecer personalização de programas de TV para PDR (*Personal Digital Recorders*). Deste modo, diferencia-se do sistema proposto nesta dissertação que é para TVD, porém nada impede que o RePTVD seja mapeado e implementado para ser utilizado de outras maneiras. O PDR pode ser considerado o sucessor do videocassete, já que sua principal funcionalidade é a gravação de programas de TV. Porém possui outras características como disco rígido, transformar um vídeo analógico em digital e permitir o armazenamento de um programa ao vivo, podendo efetuar pausa ou retrocesso. O TV3P observa os comportamentos de visualização dos telespectadores e, implicitamente, atualiza os perfis destes de forma contínua e autônoma, para então filtrar e recomendar programas de acordo com as suas respectivas informações de preferências.

Os autores destacam o TV3P, pois nos outros sistemas de recomendação personalizados o tempo e o esforço que o sistema necessita para aprender novas preferências não são avaliados. Também foi provado que as preferências podem mudar ao longo do tempo. Outro aspecto do TV3P é sua utilização em um esquema de traçar perfil implícito e explícito. Para prever as preferências dos usuários, cada perfil de telespectador contém um conjunto de termos que são classificados em ordem decrescente de peso, sendo indicadores de importância dos mesmos e cada termo é definido como uma tupla (termo, peso). Com isso, o perfil do telespectador pode ser representado como um vetor.

Para atualizar o perfil do telespectador podem ser usadas três fontes de conhecimento, são elas a entrada/modificação explícita, o *feedback* explícito e o *feedback* implícito. No RePTVD a única maneira de atualizar o perfil do grupo de telespectadores é mediante o comportamento de visualização que é realizado de maneira implícita.

A fim de demonstrar o protótipo desenvolvido, os autores usaram um computador trabalhando como o PDR, um cartão TriMedia para decodificação de vídeo e uma TV para exibição do conteúdo da simulação. Conteúdos foram continuamente disponibilizados por

*broadcast* ao dispositivo de PDR. O sistema filtra o conteúdo da difusão e aprende as preferências dos telespectadores. Se o conteúdo de transmissão ao vivo possuir um valor de preferência alto, o mesmo será gravado e esse programa será exibido na TV.

O sistema foi avaliado por 20 usuários que foram convidados a assistir conteúdos de sua preferência durante um período pré-determinado. A experiência envolveu 1682 segmentos de filmes distintos que duravam de 20 segundos a 5 minutos. Dois critérios para avaliação da eficácia da filtragem foram utilizados, precisão e *recall*. Em geral, a precisão pode ser usada como uma medida da capacidade do sistema apresentar apenas programas relevantes; *recall* pode ser usado como uma medida da capacidade do sistema apresentar todos os programas.

Mediante os resultados experimentais, concluiu-se que o sistema TV3P, especialmente o emprego de um esquema de definição de perfil implícito e explícito, pode evidenciar as preferências dos telespectadores que mudam com o passar do tempo e apresentar boas e efetivas filtragens de conteúdos. Os telespectadores poderão exigir certas características de aplicações de TVD, incluindo confiabilidade, privacidade e facilidade de uso (usabilidade) que podem ser encapsuladas na palavra "confiança".

#### **7.4 TV program recommendation for multiple viewers based on user profile merging**

Em Zhiwen et. al (2006), é proposto uma estratégia de recomendação de programa para múltiplos telespectadores baseada na junção do perfil do telespectador. Foi originado um sistema chamado TV4M que consiste em uma melhora do sistema TV3P descrito anteriormente. O estudo analisou três estratégias alternativas para efetuar as recomendações de conteúdo e a análise proporcionou a escolha da estratégia baseada na junção do perfil. Primeiramente, a estratégia escolhida aglomera todos os perfis dos telespectadores para construir um perfil comum e depois utiliza uma abordagem de recomendação para gerar uma lista comum de sugestões de programas para este grupo. Porém, esta estratégia não é adaptável e flexível, ou seja, requer que todo o grupo assista TV junto por um longo período de tempo para que o sistema descubra as preferências comuns dos telespectadores constituintes do grupo.

O sistema TV4M foi desenvolvido em Java e para identificar quais dentre todos os telespectadores estão assistindo TV, uma interface foi fornecida para que esses efetuem o *login* no sistema. Diferentemente deste sistema, no desenvolvimento do RePTVD

considerou-se o máximo das características inerentes a TVD e por este fato, foi desenvolvido com uso da linguagem Java TV.

O TV4M foi testado por 25 usuários e 200 programas de TV, filmes e propagandas. Os resultados comprovaram que a união do perfil dos telespectadores pode refletir de forma adequada nas preferências da maioria dos membros de um grupo. Porém, observou-se que o sistema é aceitável para grupos homogêneos, mas membros de grupos heterogêneos não ficaram satisfeitos com as recomendações.

### **7.5 Personalization: Improving Ease-of-Use, Trust and Accuracy of a TV Show Recommender**

Em Buczak *et al.* (2002), aborda-se a possibilidade de que a tecnologia de TVD tem de proporcionar a utilização de PDR, o que tem mudado a forma como as pessoas assistem TV, pois os PDRs permitem que os programas sejam gravados. Desse modo, os telespectadores utilizam o EPG para escolher a programação que será gravada em formato digital no disco rígido. Nesse contexto, cria-se a necessidade de ajudar os telespectadores a encontrar os programas que são mais interessantes para eles assistirem. Sendo assim, os autores propuseram e desenvolveram um sistema de personalização que recomenda programas de TV baseados no conhecimento das preferências dos telespectadores.

Durante as demonstrações e testes de uso da interface de recomendação do sistema, muitos telespectadores indicaram que queriam o mínimo ou mesmo nenhuma interação com o sistema. Por outro lado, alguns telespectadores queriam tomar o controle da recomendação, configurando o sistema para que ele produzisse recomendações precisas. Com base nisso, foram criados três modelos de telespectadores: “faça isso para mim”, para os telespectadores que querem que o sistema seja totalmente automatizado, “vamos fazer juntos”, para os que querem ter algum controle, mas sem gastar muito tempo ajustando parâmetros e “permita-me conduzir”, para os que querem controle completo da recomendação.

Para melhorar o requisito de confiança das recomendações entregues, os autores propuseram um método denominado de Histórico de Visualização Refletivo como uma característica única de seu sistema. Com o andamento dos testes, os autores notaram que quando o sistema recomendava programas regularmente assistidos, os telespectadores pensavam que o trabalho da recomendação tinha sido importante. No entanto, quando o sistema recomendava programas que os telespectadores não conheciam, eles sentiam que a

recomendação tinha sido fraca. Sendo assim, o Histórico de Visualização Refletivo explica as recomendações de uma maneira relativa à conversa, permitindo aos telespectadores melhorarem a confiança nas recomendações oferecidas pelo sistema.

Para melhorar a precisão das recomendações, os autores combinaram recomendações de vários algoritmos usando uma rede neural capaz de detectar correlações a fim de obter a recomendação final. Os algoritmos usados são inferência bayesiana implícita baseada no histórico individual, inferência bayesiana implícita baseada no histórico familiar, árvore de decisão implícita baseado no histórico individual, árvore de decisão implícita baseado no histórico familiar e no método explícito.

Para uma rápida adoção de um sistema de personalização, é necessário que este seja de fácil utilização, que se tenha a confiança do usuário, além das recomendações serem de alta precisão. Assim, os autores focaram o desenvolvimento de um EPG personalizado para melhorar esses três requisitos. Alguns desses métodos foram observados para o desenvolvimento do RePTVD. Dentre eles, estão o modo automatizado de efetuar a recomendação “faça isso para mim” e o desenvolvimento de um processo combinando várias características, de forma a oferecer melhor precisão nas recomendações.

## ***7.6 Interactive Television Personalization: From Guides to Programs***

Em O’Sullivan et. al (2004b), o aumento do volume de conteúdo nos dispositivos de PDR é abordado como um novo desafio para os telespectadores, ou seja, como se deve procurar e navegar por coleções de conteúdos de vídeos interessantes e obtê-los de uma maneira intuitiva e eficiente. Assim, o Guia de Programação Eletrônico Personalizado (pEPG – *personalized Electronic Program Guide*) é visto como uma possível solução para o problema de sobrecarga de informação. Os autores concentram-se na tecnologia de recomendação dos pEPGs e na maneira como a abordagem de mineração de dados pode ser usada para suavizar muitos destes problemas. A tarefa de mineração de dados utilizada para extrair novos metadados de programas a partir dos perfis dos telespectadores foi a de regras de associação. Esses metadados podem aumentar significativamente o conhecimento sobre a similaridade e relevância do programa. As avaliações dessa abordagem mostram que essa técnica fornece uma precisão superior de recomendação comparada com abordagens tradicionais. Os autores acreditam que essa oferece uma fundação sólida para o modelo de utilizador individual que foi usado no estudo. Também foi comparado o uso de

perfil explícito e implícito e provou-se que os indicadores de interesse implícito são semelhantes aos indicadores de interesse explícitos. Mediante esses resultados, optou-se somente na utilização dos indicadores implícitos no RePTVD visto que os telespectadores dificilmente ficarão preenchendo questionários ou configurando o sistema através do controle remoto. O RePTVD se diferencia deste trabalho, pois é voltado para recomendação de conteúdo para STB e não PDR além de considerar grupos de telespectadores ao invés de um único utilizador do sistema.

### **7.7 Unobtrusive Dynamic Modelling of TV Program Preferences**

Em Vildjiounaite et. al (2008) um método para ambiente multiusuário em casas inteligentes é apresentado a partir de interações implícitas de escolhas feitas por diferentes subgrupos de um grupo. Esse método é capaz de reconhecer pessoas e suas ações, pois utiliza as informações armazenadas no *log* de casas inteligentes. Desse modo, os *logs* podem ser usados por um sistema de recomendação para reduzir o esforço e adaptar o conteúdo tanto para um único telespectador quanto para situação multiusuário. Foi focado o desenvolvimento de um sistema baseado somente em dados de cada casa. Como vantagem, o sistema adapta as práticas familiares ao invés de forçar uma prática a priori. Uma desvantagem do sistema é o tempo que requer para o aprendizado, além dos telespectadores serem identificados ao informar pelo controle remoto quem são. Na avaliação com históricos de telespectadores de 20 famílias, a precisão do método proposto foi semelhante ao de um sistema que requer avaliação explícita dos telespectadores.

Este sistema de recomendação desenvolvido requer alguma interação explícita por parte dos telespectadores, que é a identificação pelo controle remoto e o *feedback* explícito, porém isso é opcional. Diferentemente desse sistema, o trabalho apresentado nessa dissertação visou o desenvolvimento de um sistema de recomendação para um ambiente multiusuário que seja totalmente implícito. Outra diferença é em relação à linguagem de programação, visto que o sistema de Vildjiounaite *et al.* (2008) foi desenvolvido parcialmente em C# e em C++ e é executado em um computador não considerando nenhuma característica da TVD. Já o RePTVD foi desenvolvido em Java TV, é executado em um emulador para TVD e com o mapeamento de algumas partes do sistema será possível implementá-lo para ser utilizado em um ambiente real. Há semelhança em relação aos dados que são baseados nas casas separadamente e também ao modo de avaliação do sistema, o qual coleta os dados reais dos telespectadores, mas não oferece recomendações



diretamente para eles. Assim, realiza um estudo de como o sistema pode prever os interesses de determinado grupo se ele estivesse sendo executado de maneira invisível para os telespectadores.

### ***7.8 FIT-recommending TV programs to family member***

O sistema de recomendação desenvolvido por Goren-Bar e Glinansky (2004), denominado FIT, efetua recomendações de programas para membros de uma família por modelos baseados em estereótipos e histórico de visualização. Para criar inicialmente perfis de preferências de membros de uma família, utiliza-se um estereótipo pré-definido e adicionado posteriormente às preferências dos telespectadores conforme a visualização. Desse modo, esse sistema baseia-se no tempo de visualização e na informação das categorias dos programas para inferir qual subconjunto de membros da família está assistindo TV e recomendar programas preferenciais. A estratégia utilizada para isso foi a implementação de um algoritmo de aprendizagem que permite a adaptação de mudanças nas preferências dos telespectadores, ou seja, é suposto a identificação do telespectador atual e sugerido programas de gêneros que reflitam a combinação das preferências do telespectador para o tempo atual designado.

O sistema foi avaliado mediante uma simulação, que coletou dados de nove grupos de família, os quais foram divididos em três grupos com características similares e em cada um foi aplicado um método diferente para efetuar recomendações. Desse modo, para o primeiro grupo, foram criadas predições aleatoriamente, para o segundo, geradas predições pelo FIT e para o terceiro foi usado o conhecimento de quem estava assistindo a TV. A precisão do FIT foi mais baixa que no terceiro grupo e mais alta que no primeiro grupo.

O RePTVD possui recomendações chamadas de tempo real, que assim como o FIT, relaciona o tempo e as categorias dos programas. Além desse tipo de recomendação, o RePTVD também utiliza mineração para gerar uma lista de recomendação, o qual relaciona várias outras informações. Outra diferença do RePTVD em relação ao FIT é que o segundo pode irritar o telespectador de forma mínima, pois necessita que esse forneça algumas informações para a primeira representação das suas preferências. As informações requeridas são idade, ocupação e gênero de preferência e além dessas, os telespectadores têm que informar, mediante uma classificação, qual a probabilidade de estarem na frente da TV em intervalos de 2 horas. Essas informações são coletadas no STB (lado cliente) e

enviadas para um servidor (canal de retorno), diferenciando-se do RePTVD que é um sistema local.

## **7.9 Observações Finais**

Conforme observado nos trabalhos supracitados, há diversas soluções que visam oferecer personalização com o uso de sistema de recomendação, seja para solucionar o problema de sobrecarga de informação ou para oferecer um serviço diferenciado. Assim, foram abordadas as semelhanças e diferenças dos sistemas existentes em relação ao RePTVD. É fato que a maioria dos sistemas consideram a interação do telespectador em relação ao fornecimento de informações de suas preferências, sendo o RePTVD diferenciado nesse aspecto. Além disso, é possível observar diversos sistemas implementados com estratégias diferentes, mas não consideram características inerentes à TV, como os metadados e linguagem de programação específica para este domínio, as quais foram contempladas nessa dissertação. Também consideram uma característica não totalmente difundida que permite a transmissão de dados entre cliente e servidor, o canal do retorno. Além disso, não abordam o gargalo que pode ocorrer no processamento de um sistema disponível para milhares de telespectadores, sendo esse baseado em uma arquitetura cliente/servidor.

Para a concepção do sistema de recomendação RePTVD, considerou-se e observou-se as características que a TVD possui atualmente, além do protótipo ter sido desenvolvido em uma linguagem que é específica para este domínio.

## 8 Conclusões e Trabalhos Futuros

O domínio de TVD é uma área promissora para pesquisa sobre aplicações e serviços a serem oferecidos aos telespectadores. Essa tecnologia contribui para o surgimento de novas aplicações na área de personalização e esse trabalho apresentou uma dessas possibilidades. Para alcançar esse objetivo, foi proposto um sistema de recomendação que visa identificar os padrões de comportamento de grupos de telespectadores de um mesmo domicílio de maneira implícita para oferecer conteúdos de interesse. O sistema apresentado contempla alguns dos objetivos de personalização da interface de um sistema computacional como oferecer ao usuário informações relevantes a seus interesses, e também disponibilizar o que ele quer, da maneira e no tempo que deseja.

Para desenvolver um sistema de recomendação, é relevante observar que alguns domínios específicos apresentam peculiaridades, como a forma de coleta, o tratamento dos dados, a interação do usuário com o sistema, dentre outros. Um caso típico é a recomendação de programas televisivos, o qual foi o foco principal dessa dissertação, que buscou oferecer um serviço diferenciado de personalização e uma possível solução para o problema de sobrecarga de informação.

Nessa dissertação, apresentou-se um estudo para modelar um sistema de recomendação para ambientes multiusuário. Visando viabilizar a aplicação do RePTVD, foram utilizadas técnicas como mineração de dados, filtragem de informação, coleta implícita e armazenamento de informações. Mediante um estudo de caso, foi oferecida uma arquitetura que permite utilizar recursos concentrados no STB, recomendando o conteúdo mais indicado ao perfil de cada casa separadamente. Para isso o processo de recomendação apresentado elucida a maneira como os problemas foram tratados e quais as estratégias traçadas para se alcançar a recomendação.

Esse sistema mostra-se flexível para ser utilizado em qualquer sistema de TVD, visto que foi desenvolvido com a API Java TV. Porém, foi desenvolvido para utilização na realidade brasileira, pois usa informações provenientes das normas ABNT, além de obter informações fornecidas pelo IBOPE referentes ao comportamento de visualização dos telespectadores e à grade de programação.

Com os resultados do experimento de análise da precisão do sistema realizado, verificou-se a aplicabilidade da abordagem proposta em recomendar conteúdos adequando-

se às práticas familiares, visto que o sistema atingiu 59% de acerto nas recomendações sugeridas. Ao efetuar recomendações, foram utilizados tanto conteúdos frequentes e conhecidos pelos telespectadores como também recomendações inovadoras. Dessa forma, evidencia-se nesse trabalho uma possibilidade de evitar ou reduzir a superespecialização.

A estratégia implícita para identificar padrões em um grupo de telespectadores diferencia-se de outros sistemas de recomendação que freqüentemente utilizam algum mecanismo explícito. Além disso, esses sistemas são desenvolvidos em linguagens que não são padrão para TVD e também não consideram as características inerentes a essa tecnologia.

De maneira geral, as contribuições que esse trabalho evidencia são: o desenvolvimento de um sistema de recomendação para ambiente multiusuário considerando-se as peculiaridades da TVD e a definição de um processo de recomendação, que se baseia em um conjunto de etapas para o oferecimento de sugestões aos telespectadores. Para cada etapa foram adotadas algumas técnicas específicas, porém, o processo pode vir a ser utilizado como parâmetro para o desenvolvimento de outros sistemas de recomendação para TVD, e desse modo, ser mapeado para uso de diferentes técnicas.

O aplicativo foi desenvolvido como prova de conceito e demonstra ser o primeiro passo para oferecer um serviço de personalização na TVD, que em determinado momento deverá ser amplamente difundido. Para realização de trabalhos futuros, espera-se o lançamento da implementação completa de referência do *middleware* Ginga (OPENGINA, 2008) para acoplar os módulos do RePTVD diretamente nesse *middleware*. Pretende-se também desenvolver o RePTVD utilizando *hardware* real, que permitirá o uso das tabelas enviadas por *broadcasting*. Também será possível, com o canal de retorno, enviar os dados sobre o comportamento de visualização para um servidor gerenciador da aplicação, que ficará responsável pelo processamento e possibilitará a aplicação da filtragem colaborativa.

Além disso, com o advento chamado TV social, no qual cada receptor poderá ser um potencial emissor de conteúdo, os telespectadores poderão compartilhar os dados referentes à visualização e preferências para outro grupo e assim, aplicar a filtragem colaborativa.

## Referências Bibliográficas

ABNT NBR 15602-2 - **Associação Brasileira de Normas Técnicas. Televisão digital terrestre – Codificação de vídeo, áudio e multiplexação – Parte 2: Codificação de áudio.** 2008. Disponível em <  
[http://www.abnt.org.br/tvdigital/norma\\_bra/ABNTNBR15602-2\\_2007Vc\\_2008.pdf](http://www.abnt.org.br/tvdigital/norma_bra/ABNTNBR15602-2_2007Vc_2008.pdf)>.  
Acesso em: 20 de fevereiro de 2009.

ABNT NBR 15603-1 - **Associação Brasileira de Normas Técnicas. Televisão digital terrestre - Multiplexação e serviços de informação (SI) - Parte 1: Serviços de informação do sistema de radiodifusão.** 2008. Disponível em <  
[http://www.abnt.org.br/tvdigital/norma\\_bra/ABNTNBR15603-1\\_2007Vc2\\_2008.pdf](http://www.abnt.org.br/tvdigital/norma_bra/ABNTNBR15603-1_2007Vc2_2008.pdf)>.  
Acesso em: 21 de fevereiro de 2009.

ABNT NBR 15603-2 - **Associação Brasileira de Normas Técnicas. Televisão digital terrestre - Multiplexação e serviços de informação (SI) - Parte 2: Estrutura de dados e definições da informação básica da SI.** 2008. Disponível em <  
[http://www.abnt.org.br/tvdigital/norma\\_bra/ABNTNBR15603-2\\_2007Vc2\\_2008.pdf](http://www.abnt.org.br/tvdigital/norma_bra/ABNTNBR15603-2_2007Vc2_2008.pdf)>.  
Acesso em: 21 de fevereiro de 2009.

ABNT NBR 15606-4 - **Associação Brasileira de Normas Técnicas. Televisão digital terrestre - Codificação de dados e especificações de transmissão para radiodifusão digital – Parte 4: Ginga-J – Ambiente para a execução de aplicações procedurais (VERSÃO DRAFT 05/2008).** 2008. Disponível em <[www.openginga.org/00.001.85-006-4.pdf](http://www.openginga.org/00.001.85-006-4.pdf)>. Acesso em: 20 de fevereiro de 2009.

ABNT NBR 15606-5 - **Associação Brasileira de Normas Técnicas. Televisão digital terrestre – Codificação de vídeo, áudio e multiplexação – Parte 2: Codificação de áudio.** 2008. Disponível em  
<[http://www.abnt.org.br/tvdigital/norma\\_bra/ABNTNBR15606-5\\_2008Vc\\_2008.pdf](http://www.abnt.org.br/tvdigital/norma_bra/ABNTNBR15606-5_2008Vc_2008.pdf)>.  
Acesso em: 20 de fevereiro de 2009.

AGRAWAL, R.; IMIELINSKI, T. e SWAMI, A.: **Mining association rules between sets of items in large databases.** In: ACM SIGMOD INTERNATIONAL CONFERENCE ON MANAGEMENT OF DATA, 1993, Washington,D.C, Estados Unidos. **Proceedings...**pp. 207-216.

AGRAWAL, R.; SRIKANT, R.: **Fast Algorithms for Mining Association Rules.** In: 20th INTERNATIONAL CONFERENCE ON VERY LARGE DATA BASES (VLDB), 1994, Santiago de Chile, Chile. **Proceedings...**pp. 487-499.

ATSC. **Advanced Television Systems Committee.** 2006. Disponível em: <<http://www.atsc.org>>. Acesso em: 20 de janeiro de 2009.

BARBOSA, S. D. J. ; SOARES, L. F. G.: **TV Digital interativa no Brasil se faz com Ginga: Fundamentos, Padrões, Autoria Declarativa e Usabilidade.** In: ATUALIZAÇÕES EM INFORMÁTICA, 2008, Rio de Janeiro, Brasil. Editora PUC-RIO, PP 105 - 174.

BECKER, V.; PICCIONI, C. A.; MONTEZ, C.; HERWEG FILHO, G. H. **Datacasting e Desenvolvimento de Serviços e Aplicações para TV Digital Interativa.** In: WEB E MULTIMÍDIA: DESAFIOS E SOLUÇÕES, 2005, Poços de Caldas, vol. 01, pp. 01-30.

BOZIOS, T.; LEKAKOS, G.; SKOULARIDOU, V.; CHORIANOPOULOS, K.: **Advanced techniques for personalized advertising in a digital TV environment: The imedia system.** In: eBUSINESS AND eWORK CONFERENCE, 2001, Veneza, Itália. **Proceedings...**pp. 1025-1031.

BUCZAK, A.; ZIMMERMAN, J.; KURAPATI, K.: **Personalization: Improving Ease-of-Use, Trust and Accuracy of a TV Show Recommender.** In: SECOND WORKSHOP ON PERSONALIZATION IN FUTURE TV AT 2<sup>nd</sup> INTERNATIONAL CONFERENCE

ON ADAPTIVE HYPERMEDIA AND ADAPTIVE WEB BASED SYSTEMS, 2002, Malaga, Espanha. **Proceedings...**pp. 3-12.

CAVALCANTI, João F. B.: **Medidas de Rádio Propagação em UHF em Ambientes Suburbanos para TV Digital: Estudo de Cobertura para Recepção Fixa.** Dissertação de Mestrado. Programa de Pós-Graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica da PUC-Rio. 2005.

CHORIANOPOULOS, K.: **Personalized and mobile digital TV applications.** Multimedia Tools and Applications. Publisher: Kluwer Academic Publishers. Vol. 36 Issue 1-2. pp. 1 – 10. 2008.

COMUNIDADE GINGA. **Portal do Software Público Brasileiro.** Disponível em: <[http://www.softwarepublico.gov.br/dotlrn/clubs/ginga/one-community?page\\_num=0](http://www.softwarepublico.gov.br/dotlrn/clubs/ginga/one-community?page_num=0)>. Acesso em: 5 de fevereiro de 2009.

DOU. **Diário Oficial da União. Decreto 4.901, de 16 de novembro de 2003, que institui o Sistema Brasileiro de TV Digital e dá outras providências.** Brasília. 2003. Disponível em: <[http://sbtvd.cpqd.com.br/downloads/decreto\\_4901\\_2003.pdf](http://sbtvd.cpqd.com.br/downloads/decreto_4901_2003.pdf)>. Acesso em: 20 fevereiro de 2008.

DOU. **Diário Oficial da União. Decreto 5.820, de 29 de junho de 2006. Dispõe sobre a implantação do SBTVD-T, estabelece diretrizes para a transição do sistema de transmissão analógica para o sistema de transmissão digital do serviço de radiodifusão de sons e imagens e do serviço de retransmissão de televisão, e da outras providencias.** Brasília. 2006. 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)>. Acesso em: 20 de dezembro de 2008.

DVB. **Digital Video Broadcasting Project**. 2003. Disponível em: <<http://www.dvb.org>>. Acesso em 10 de janeiro de 2009.

FAYYAD, U. M.; PIATETSKY-SHAPIRO G.; SMITH, P.: **Knowledge Discovery In Databases: An Overview**. In: KNOWLEDGE DISCOVERY IN DATABASES, eds. G. Piatetsky- Shapiro, and W. J. Frawley, 1996, Cambridge, MA. **Proceedings...**pp 1-36.

FERNANDES, J.; LEMOS, G.; SILVEIRA, G.: **Introdução à Televisão Digital Interativa: Arquitetura, Protocolos, Padrões e Práticas**. Mini-curso apresentado na XXIII Jornada de Atualização em Informática do XXIV Congresso da Sociedade Brasileira de Computação (JAI-SBC), em Salvador – BA. 2004.

FORUM SBTVD: **Fórum do Sistema Brasileiro de TV Digital Terrestre**. 2008. Disponível em: <<http://www.forumsbtvd.org.br/>>. Acesso em: 05 de maio de 2009.

GINGA. **Portal do GINGA**. Disponível em: <<http://www.ginga.org.br/>>. Acesso em: 8 fevereiro 2009.

GOREN-BAR, D.; GLINANSKY, O.: **FIT-recommending TV programs to family member**. In: COMPUTERS & GRAPHICS, 2004, vol.28, pp 149-156.

HAN, J.; KAMBER, M.: **Data Mining: Concepts and Techniques**. Morgan Kaufmann. 2006.

HSU, S. H.; WEN, M. H.; LIN, H. C.; LEE, C. C.; LEE, C. H: **AIMED – A personalized TV Recommendation System**. In: 5<sup>th</sup> EUROPEAN CONFERENCE ON INTERACTIVE TELEVISION (EuroITV): INTERACTIVE TV: A SHARED EXPERIENCE, 2007, Amsterdam, Netherlands. **Proceedings...**pp 166-174.



ISDB. **ISDB-T - Terrestrial integrated services digital broadcasting (ISDB-T): specification of channel coding, framing structure and modulation**. 1998. Disponível em: <[http://www.dibeg.org/techp/Documents/Isdb-t\\_spec.PDF](http://www.dibeg.org/techp/Documents/Isdb-t_spec.PDF)>. Acesso em: 10 de dezembro de 2009.

ISO/IEC 14496-10. International Organization for Standardization / Internacional Eletrotécnica Committee. **Information Technology – Coding of Audio-Visual Objects – Part 10: Advanced Video**. 2005.

ISO/IEC 13818-1. International Organization for Standardization / Internacional Eletrotécnica Committee. **Information technology – Generic coding of moving pictures and associated audio information: Systems**. 2000.

ISO/IEC TR 13818-6. International Organization for Standardization / Internacional Eletrotécnica Committee. **Information technology - Generic coding of moving pictures and associated audio information - Part 6: Extensions for DSM-CC**. 1998.

KIM, J.; PAN, Y.; MCGRATH, B.: **Personalization in Digital Television: Adaptation of Pre-Customized UI Design**. In: 2<sup>nd</sup> EUROPEAN CONFERENCE ON INTERACTIVE TELEVISION (EuroITV): ENHANCING THE EXPERIENCE, 2004, Brighton, UK. **Proceedings...**pp 169-171.

LEITE, L. E. C.; BATISTA, C. E. C. F.; FILHO, G. L. S.; KULESZA, R.; ALVES, L. G. P.; BRESSAN, G.; RODRIGUES, R. F.; SOARES, L. F. G.: **FlexTV . Uma Proposta de Arquitetura de Middleware para o Sistema Brasileiro de TV Digital (FlexTV – a Middleware Architecture Proposal for the Brazilian Digital TV System)**. In: REVISTA DE ENGENHARIA DE COMPUTAÇÃO E SISTEMAS DIGITAIS, 2005, vol. 2, pp 29-50.

LUCAS, A. S.; ZORZO, S. D.: **Modelo de Sistema de Recomendação Personalizado para Televisão Digital**. In: 7<sup>th</sup> INTERNATIONAL INFORMATION AND TELECOMMUNICATION TECHNOLOGIES SYMPOSIUM (I2TS), 2008, Foz do Iguaçu, Brasil.

LUCAS, A. S.; ZORZO, S. D.: **Personalização para Televisão Digital utilizando a estratégia de Sistema de Recomendação para ambientes multiusuário**. In: XXVII SIMPÓSIO BRASILEIRO DE REDES DE COMPUTADORES E SISTEMAS DISTRIBUÍDO (SBRC), 2009a, Recife, Brasil.

LUCAS, A. S.; ZORZO, S. D.: **Personalization of Digital Television using Recommendation System strategy**. In: 16<sup>th</sup> INTERNATIONAL WORKSHOP ON SYSTEM, SIGNALS AND IMAGE PROCESSING (IWSSIP), 2009b, Chalkida, Grécia.

MENDES, L. L.: **SBTVD – Uma visão sobre a TV Digital no Brasil**. In: REVISTA T&C AMAZÔNIA, 2007, Ano V, N. 12, ISSN - 1678-3824, pp. 48-59.

MONTEIRO, M. S.: **TV Interativa e seus Caminhos**. Tese de mestrado da Universidade Estadual de Campinas. 2002. Disponível em <<http://libdigi.unicamp.br/document/?code=vtls000294986>>. Acesso em: 23 de janeiro de 2009.

MONTEZ, C., BECKER, V.: **TV Digital Interativa: conceitos, desafios e perspectivas para o Brasil**. Florianópolis: Ed. da UFSC, 2<sup>a</sup> edição. 2005.

NCL - **Nested Context Language**. Disponível em: <<http://www.telemidia.puc-rio.br/~rmc/ncl/>>. Acesso em: 10 de fevereiro de 2009.

OpenGinga - **Implementação de Referência do Middleware Brasileiro de TV Digital**. 2008. Disponível em: <<http://www.openginga.org/index.html>>. Acesso em: 13 de fevereiro de 2009.

O'SULLIVAN, D.; SMYTH, B.; WILSON, D. C.; MCDONALD, K.; SMEATON, A.: **Improving the Quality of the Personalized Electronic Program Guide**. In: UMUAI SPECIAL ISSUE ON USER MODELING AND PERSONALIZATION FOR TELEVISION, 2004a, vol.14, n.1, pp 5-36.

O'SULLIVAN, D.; SMYTH, B.; WILSON, D. C.; MCDONALD, K.; SMEATON, A.: **Interactive Television Personalization: From Guides to Programs**. In: PERSONALIZED DIGITAL TELEVISION: TARGETING PROGRAMS TO INDIVIDUAL VIEWERS, 2004b, New York, Estados Unidos, Kluwer Academic Publishers, pp 73-91.

REZENDE, S.O.: **Sistemas Inteligentes: Fundamentos e Aplicações** (1 Ed.). Barueri, SP: Manole. 2003.

RODRIGUES, R. F.; MORENO, M. F.; SOARES, L. F. G.: **Controle de Apresentação de Aplicações Declarativas em Receptores de Sistemas de TV Digital Interativa**. In: 12st BRAZILIAN SYMPOSIUM ON MULTIMEDIA AND WEB (WebMedia), 2006, Natal, Brazil. **Proceedings...**pp. 184-192.

SBTV.D. **Sistema Brasileiro de Televisão Digital**. Ministério das Comunicações. Disponível em: <<http://sbtvd.cpqd.com.br>>. Acesso em: 20 de janeiro de 2009.

SCHAFER, J. B.: **MetaLens: A Framework for Multi-source Recommendations**. Tese em Ciências da Computação, University of Minnesota. 2001.

SILVA, F. S.: **Personalização de Conteúdo na TVDI Através de um Sistema de Recomendação Personalizada de Programas de TV**. III Fórum de Oportunidades em Televisão Digital Interativa, 2005, Poços de Caldas, Brasil.

SOARES, L. F. G.: **MAESTRO: The Declarative Middleware Proposal for the SBTVD**. In: 4<sup>th</sup> EUROPEAN CONFERENCE ON INTERACTIVE TELEVISION (EuroITV), 2006, Atenas, Grécia.

SOARES, L. F. G.; SOUZA, G. L.: **Interactive Television in Brazil: System Software and the Digital Divide**. In: 5<sup>th</sup> EUROPEAN CONFERENCE ON INTERACTIVE TELEVISION (EuroITV): INTERACTIVE TV: A SHARED EXPERIENCE, 2007, Amsterdam, Netherlands.

SOARES, L. F. G.; RODRIGUES, R. F.; MORENO, M. F.: **Ginga-NCL: the Declarative Environment of the Brazilian Digital TV System**. In: JOURNAL OF THE BRAZILIAN COMPUTER SOCIETY, 2007, Vol. 12, pp 37-46.

SOUZA, G. L. F.; LEITE, L. E. C.; BATISTA, C. E. C. F.: **Ginga-J: The Procedural Middleware for the Brazilian Digital TV System**. In: JOURNAL OF THE BRAZILIAN COMPUTER SOCIETY, 2007, Vol. 12, pp 47-56.

SUN Microsystems. **Java TV API 1.1 (JSR-927)**. 2006. Disponível em: <<http://java.sun.com/javame/reference/apis/jsr927>>. Acesso em: 20 de novembro de 2008.

TORRES, R.. **Personalização na Internet**. Editora Novatec. 2004.

VILDJIOUNAITE, E.; KYLLONEN, V.; HANNULA, T.; ALAHUHTA, P.: **Unobtrusive Dynamic Modelling of TV Program Preferences**. In: 6<sup>th</sup> EUROPEAN

CONFERENCE ON INTERACTIVE TELEVISION (EuroITV): CHANGING TELEVISION ENVIRONMENTS, 2008, Salzburg, Austria. **Proceedings...**pp 82-91.

WITTEN, I. H; Frank, E.: **Data mining: Practical machine learning tools and techniques**, Morgan Kaufmann, 2th edition. 2005.

XletView. Disponível em: < <http://xletview.sourceforge.net/index.php> >. Acesso em: 20 dezembro de 2008.

ZHIWEN Yu; XINGSHE Zhou: **TV3P: an adaptive assistant for personalized TV**. IEEE TRANSACTIONS ON CONSUMER ELECTRONICS, 2004, vol.50, Issue 1, pp. 393 – 399.

ZHIWEN, Y.; XINGSHE, Z.; YANBIN, H.; JIANHUA, G.: **TV program recommendation for multiple viewers based on user profile merging**. In: JOURNAL OF THE USER MODELING AND USER-ADAPTED INTERACTION, 2006, vol. 16, No. 1, pp. 63-82.