

UNIVERSIDADE FEDERAL DE SÃO CARLOS

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Recommender TV: Suporte ao Desenvolvimento de
Aplicações de Recomendação para o Sistema Brasileiro de TV
Digital

ALUNO: Paulo Muniz de Ávila

ORIENTADOR: Prof. Dr. Sérgio Donizetti Zorzo

São Carlos-SP

Janeiro/2010

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

Paulo Muniz de Ávila

Recommender TV: Suporte ao Desenvolvimento de
Aplicações de Recomendação para o Sistema Brasileiro de TV
Digital

*DISSERTAÇÃO DE MESTRADO
APRESENTADO AO PROGRAMA DE PÓS-
GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO
DO DEPARTAMENTO DE COMPUTAÇÃO DA
UNIVERSIDADE FEDERAL DE SÃO CARLOS
COMO PARTE DOS REQUISITOS PARA
OBTENÇÃO DO TÍTULO DE MESTRE EM
CIÊNCIA DA COMPUTAÇÃO*

São Carlos-SP
Janeiro/2010

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

A958rt

Ávila, Paulo Muniz de.

Recommender TV : suporte ao desenvolvimento de aplicações de recomendação para o Sistema Brasileiro de TV Digital / Paulo Muniz de Ávila. -- São Carlos : UFSCar, 2010.
90 f.

Dissertação (Mestrado) -- Universidade Federal de São Carlos, 2010.

1. Métodos especiais de computação. 2. Televisão digital.
3. Personalização. 4. Middleware. I. Título.

CDD: 006 (20^a)

Universidade Federal de São Carlos

Centro de Ciências Exatas e de Tecnologia

Programa de Pós-Graduação em Ciência da Computação

“Recommender TV: Suporte ao Desenvolvimento de Aplicações de Recomendação para o Sistema Brasileiro de TV Digital”

PAULO MUNIZ DE ÁVILA

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

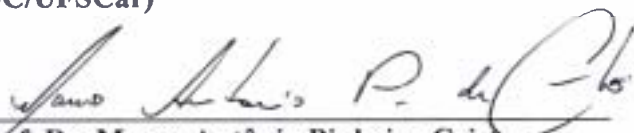
Membros da Banca:



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



Prof. Dr. César Augusto Camillo Teixeira
(DC/UFSCar)



Prof. Dr. Marco Antônio Pinheiro Cristo
(FUCAP/AM)

São Carlos
Janeiro/2010

AGRADECIMENTOS

Agradeço à minha família, em especial aos meus pais Paulo e Rosely. Eles não mediram esforços e mesmo não podendo, sempre davam um jeito de me ajudar financeiramente ou com conselhos. Ao meu irmão Guilherme por sempre apoiar os meus estudos e à minha irmã Juliana, que sempre me ajudou muito.

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

Ao Prof. João Benedito dos Santos Jr. que por diversas vezes colaborou com ideias e dicas.

Enfim, a todos que de forma direta ou indireta participaram para a conclusão desse trabalho.

RESUMO

A televisão digital possibilitará a transmissão de novos serviços (no sistema analógico, canais), com um crescimento significativo na quantidade de informação disponibilizada aos usuários em comparação ao sistema analógico tradicional. Em face desse crescimento de aplicações possíveis, sistemas de recomendação destacam-se como ferramentas úteis para auxiliar os telespectadores a lidar com essa sobrecarga de informação, permitindo identificar suas necessidades e preferências. Para isso, esse trabalho apresenta uma solução para suporte ao desenvolvimento de sistemas de recomendação, através da inclusão de um novo módulo na implementação de referência do *middleware* Ginga, intitulado *Recommender TV*. Com isso, implementou-se uma camada de abstração que permite aos desenvolvedores de aplicativos para televisão digital interativa, especificamente para os desenvolvedores de sistemas de recomendação, preocuparem-se com a interface e navegabilidade de seus sistemas, deixando questões de baixo nível para o módulo *Recommender TV* gerenciar. O novo módulo apresentado nessa dissertação permite a implementação de diferentes sistemas de recomendação, de forma rápida e eficiente. Assim, a partir da análise de resultados de um sistema de recomendação é possível obter medidas relevantes sobre a aplicação da personalização em ambientes de televisão digital interativa.

Palavras-Chave: Ginga, Personalização, TV Digital.

ABSTRACT

Digital television will allow the transmission of new services, with a significant increase in the amount of information available to users compared to traditional analog system. Given that growth of possible applications, recommendation systems have emerged as useful tools to help viewers cope with this overload of information, allowing identify their needs and preferences. For this reason, this work presents a solution to support the development of recommender systems, by adding a new module in the middleware Ginga entitled Recommender TV. Thus, it was implemented an abstraction layer that allows developers of applications for interactive digital television, specifically for developers of recommender systems, be concerned with the interface and navigability of their systems, leaving questions of low-level module Recommender TV manage. Issues regarding the low level processing the new module presented in this work allows the implementation of different recommender systems, quickly and efficiently. The use of the results provided by such systems will assist us to better understand the implementation of interactive digital television.

LISTA DE FIGURAS

Figura 1 – Arquitetura do Middleware Ginga adaptado de (SOARES, 2007)	23
Figura 2– TV Digital Interativa adaptado de (ALVES et al. , 2008).....	25
Figura 3 - Etapas de difusão sinal adaptada de (PICCIONI, 2005)	26
Figura 4– Campos da Tabela EIT adaptado de (MORRIS; SMITH-CHAIGNEAU, 2005)	28
Figura 5– Estrutura de dados do descritor de serviços (NBR 15603-1, 2007)	30
Figura 6 – Carrossel de dados / Objetos (Alves, 2008).....	31
Figura 7 – Processo de transmissão e recepção de TVDI (BARBOSA; SOARES, 2008)	32
Figura 8 – Aplicação interativa que permite a inserção de dados do usuário no STB	39
Figura 9 – Arquitetura do <i>Middleware</i> Ginga destacando a inserção do módulo Recommender TV	43
Figura 10 – Interconexão das aplicações interativas com o módulo Recommender TV.....	44
Figura 11 – <i>Middleware</i> Ginga destacando <i>Bridge</i> adaptado de (Soares, 2007)	48
Figura 12–Interconexão das camadas do módulo Recommender TV e o <i>middleware</i> Ginga	49
Figura 13–Camada Recommender Engine	52
Figura 14 – Dados do IBOPE sobre a programação dos provedores de serviço	56
Figura 15 – Dados do IBOPE minuto a minuto do domicilio.....	57
Figura 16 – Ambiente de teste do Recommender TV (ÁVILA; ZORZO, 2009a).....	58
Figura 17– Etapas do processo de recomendação no ambiente de TVDI	64
Figura 18– Aplicação protótipo executando no <i>middleware</i> Ginga.....	66
Figura 19 – Interface do gerador de tabelas EIT	89
Figura 20 – Interface do gerador de tabelas SDT	90

LISTA DE TABELAS

Tabela 1 – Classificação dos gêneros/subgêneros - Amostra.....	30
Tabela 2 - API disponibilizada as aplicações interativas	50
Tabela 3 – Tabela histórico de comportamento do usuário.....	53

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ACATS	Advisory Committee on Advanced Television
API	Application Programming Interface
ATSC	Advanced Television Systems Committee
CPqD	Centro de Pesquisa e Desenvolvimento em Telecomunicações
DSM-CC	Digital Storage Media – Command and Control
DTMB	Digital Terrestrial Multimedia Broadcast
DTV	Digital Television
DVB	Digital Video Broadcasting
EIT	Event Information Table
EPG	Electronic Programme Guide
FBC	Filtragem Baseada em Conteúdo
FC	Filtragem Colaborativa
FINEP	Financiadora de Estudos e Projetos
HD	High Definition
HDTV	High Definition TV
IBOPE	Instituto Brasileiro de Opinião Pública e Estatística
ISDB	Integrated System for Digital Broadcasting
ISDB-TB	International Service Digital Broadcasting - Terrestrial Brazil
JNI	Java Native Interface
KDD	Knowledge Discovery in Databases
MAC	Multiplexed Analog Components
MHP	Multimedia Home Platform

MPEG	Moving Picture Experts Group
MUSE	Multiple Sub-Nyquist Sampling Encoding
NBR	Normas Brasileiras
NCL	Nexted Context Language
PC	Personal Computer
PES	Packetized Elementary Stream
PSI	Program Specific Information
SBTVD	Sistema Brasileiro de Televisão Digital
SBTVD-T	Sistema Brasileiro de Televisão Digital Terrestre
SDT	Service Description Table
SI	Service Information
STB	Set-Top Box
TVDI	Televisão Digital Interativa
XML	eXtensible Markup Language

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO.....	15
1.1 Motivações e Justificativas	16
1.2 Objetivos	17
1.3 Organização do Trabalho	18
CAPÍTULO 2 - TV DIGITAL INTERATIVA.....	19
2.1 Sistemas de TV Digital	20
2.2 O Sistema Brasileiro de Televisão Digital.....	21
2.3 Componentes de um sistema de televisão digital interativa	24
2.3.1 Provedores de Serviços	26
2.3.2 Metadados em TV Digital Interativa	27
2.3.3 Carrossel de Dados.....	31
2.3.4 Recepção	32
CAPÍTULO 3 - SISTEMAS DE RECOMENDAÇÃO	34
3.1 Coleta de Conteúdo	34
3.2 Métodos empregados na recomendação	35
3.3 Descoberta de Conhecimento	36
3.4 Recomendação para multiusuários	38
3.5 Apresentação das recomendações	40
3.6 Observações Finais.....	41
CAPÍTULO 4 - MÓDULO RECOMMENDER TV.....	42
4.1 Visão Geral.....	42
4.2 Interconexões do módulo Recommender TV e as aplicações interativas	43
4.3 Arquitetura do Módulo Recommender TV	46
4.3.1 Camada Recommender API.....	49
4.3.2 Camada Recommender Engine	52

CAPÍTULO 5 - EXPERIMENTOS E RESULTADOS	55
5.1 Ambiente de teste e dados do IBOPE	55
5.2 Resultados	58
5.3 Aplicação Protótipo	63
CAPÍTULO 6 - TRABALHOS RELACIONADOS	67
6.1 AIMED – A personalized TV Recommendation System	67
6.2 A Personalized TV Guide System Compliant with MHP	69
6.3 TV program recommendation for multiple viewers based on user profile merging	71
6.4 Personalization: Improving Ease-of-Use, Trust and Accuracy of a TV Show Recommender.....	72
6.5 Unobtrusive Dynamic Modelling of TV Program Preferences.....	74
6.6 FIT-recommending TV programs to family member	75
6.7 Personalização para Televisão Digital utilizando a estratégia de Sistema de Recomendação para ambientes multiusuário	76
6.8 Observações Finais.....	77
CAPÍTULO 7 - CONCLUSÕES E TRABALHOS FUTUROS.....	79
REFERÊNCIAS BIBLIOGRÁFICAS	81
APÊNDICE A – GERADOR DE TABELAS EIT & SDT	89

Uma das principais inovações que se espera com o advento da Televisão Digital Interativa (TVDI), especialmente no contexto do Brasil, é a possibilidade da oferta de uma vasta gama de novos serviços¹ e aplicações (comércio eletrônico, educação a distância e governo eletrônico são alguns típicos exemplos) que permitam a intervenção do telespectador, oferecendo formas de interatividade até então desconhecidas no universo do sistema de televisão analógico. A vasta gama de novos aplicativos, dentre os quais: *Electronic Program Guide* (EPG), propagandas personalizadas, jogos, *T-learning*, *T-commerce*, *T-government*, etc, permitirão uma oferta de serviços nunca observada no sistema analógico (SANTOS JUNIOR *et al.*, 2008).

A evolução da televisão analógica para um sistema digital observado em diversos países do mundo inclusive no Brasil, com a implementação do Sistema Brasileiro de Televisão Digital denominado *International Service Digital Broadcasting - Terrestrial Brazil* (ISDB-TB) constitui uma evolução importante dessa mídia.

Aliado a essa evolução, de acordo com (MONTEZ; BECKER, 2005), espera-se uma mudança no comportamento do telespectador que deixa de ser um agente passivo, assumindo uma postura pró-ativa. Essa mudança acontece principalmente pela possibilidade da interação do telespectador com aplicações interativas, como por exemplo, os sistemas de recomendação.

A esta interatividade, que torna o telespectador um agente pró-ativo, aliada a novas formas de codificação do sinal de áudio e vídeo, dá-se o nome de TVDI.

¹ Serviços são os canais conhecidos no sistema analógico de TV.

1.1 Motivações e Justificativas

Com o advento da TVDI e principalmente com a possibilidade de transmissão de aplicações interativas, ocorreu tanto na indústria quanto no mundo acadêmico, interesse no desenvolvimento de pesquisas visando a oferta de novos produtos/serviços aos usuários. No mundo acadêmico o tema de pesquisa voltado ao Sistema Brasileiro de Televisão Digital (SBTVD) teve início em 2003, com a iniciativa do governo brasileiro, através do CPqD (agência gestora da pesquisa) e da FINEP (agência financiadora da pesquisa), de solicitar a suas universidades e centros de pesquisa a apresentação de soluções de *hardware* e *software* para a construção de um sistema de televisão digital com tecnologia totalmente desenvolvida no Brasil. Na indústria, com o advento das transmissões digitais, que tiveram início no fim de 2007, e a necessidade da oferta de conversores digitais ou *set-top box* (STB), esforços foram direcionados para apresentar soluções compatíveis com a realidade brasileira.

Com a migração do sistema analógico para o sistema de TVDI duas implicações ocorrem: o aumento da capacidade de transmissão de novos canais com a mesma largura de banda e a possibilidade de enviar aplicativos multiplexado com o conteúdo audiovisual. Ao mesmo tempo em que novos canais surgem em virtude do aumento da capacidade de transmissão, torna-se necessário a criação de meios que possibilitem aos telespectadores navegar entre estes serviços (ÁVILA; ZORZO, 2009d).

O guia de programação eletrônico (EPG) auxilia os telespectadores nesta tarefa. Porém a medida que novos canais são disponibilizados é inevitável que ocorra sobrecarga de informação, tornando os sistemas de EPG inadequados. Por exemplo, em Shanghai, uma grande cidade na China, os provedores de serviços oferecem 110 diferentes serviços e este número tem crescido numa taxa de 20% ao ano (ZHANG *et al.*, 2005). Desta forma, os sistemas de EPG tradicionais tornam-se pouco atraentes porque os telespectadores necessitam de muito tempo para navegar nas dezenas de páginas disponibilizadas à procura de seu programa

predileto. É nesta situação que surge a necessidade dos sistemas de recomendação personalizados.

Diferente das funções do EPG que possibilitam navegação básica, um sistema de personalizado pode criar um perfil para cada telespectador ou um perfil para o grupo de telespectadores, dependendo da abordagem adotada e recomendar programas que melhor enquadrem nesse perfil, evitando que o telespectador tenha que navegar por várias páginas do EPG à procura de seu programa predileto. A obtenção do perfil do telespectador pode ser realizada de forma explícita, onde são informadas ao sistema quais suas preferências; ou de forma implícita, ao analisar o histórico de comportamento do telespectador, o sistema é capaz de inferir suas preferências. No contexto de TVDI, a opção implícita é certamente a mais adequada em virtude das limitações impostas pelo controle remoto à entrada de dados (Cesar P. *et al.* , 2008).

Neste sentido, a principal motivação desse trabalho é investigar e desenvolver soluções e infraestruturas de suporte que possam auxiliar os telespectadores nas suas escolhas, explorando as características computacionais providas pela TVDI.

1.2 Objetivos

O objetivo desse trabalho é contribuir para área de personalização no domínio da TVDI. Nesse sentido, é apresentada nessa dissertação um novo módulo na implementação de referência do *middleware* Ginga que possibilita suporte ao desenvolvimento de sistemas de recomendação, intitulado *Recommender TV*.

O objetivo principal do módulo *Recommender TV* é permitir a aquisição de dados visando conhecer o comportamento do usuário, oferecer recursos de mineração de dados e disponibilizar acesso a essas informações, permitindo aos desenvolvedores de sistemas de recomendação concentrar seus esforços em detalhes de interface e navegabilidade com o telespectador.

1.3 Organização do Trabalho

Este trabalho possui 7 capítulos que desenvolvem o assunto proposto. No capítulo 2, são apresentados os conceitos de TVDI. O capítulo 3 apresenta os conceitos sobre personalização na TVDI com ênfase em sistemas de recomendação. No capítulo 4, é apresentado o módulo *Recommender TV*. O capítulo 5 apresenta resultados obtidos a partir de uma aplicação protótipo. O capítulo 6 apresenta alguns trabalhos que possuem intersecção com a proposta. Por fim, as conclusões e trabalhos futuros são apresentados no capítulo 7.

A TVDI é um tema bastante discutido no Brasil e será uma das áreas mais promissoras nos próximos anos. Assim como qualquer tecnologia, a TVDI passa por uma constante evolução que teve início na década de 70 com o objetivo de aprimorar a qualidade e expandir as funcionalidades da televisão analógica. Nesse período, grupos de pesquisa se formaram através do mundo em busca do que viria a ser a TVDI.

Os japoneses foram os primeiros a iniciar as pesquisas e, no início da década de 80, apresentaram como resultado o MUSE (*Multiple Sub-Nyquist Sampling Encoding*) onde um sinal de alta definição com mais de 1 Gbit de informação é codificado em um canal com 27Mhz de faixa compatível com os canais disponíveis em satélite.

Em 1986, os europeus também iniciaram suas pesquisas com um projeto denominado MAC (*Multiplexed Analog Components*) que era baseado em digitalização e compressão dos dados e ainda usavam algumas técnicas analógicas para geração do sinal. Posteriormente, lançou-se uma nova versão do sistema com o nome HD-MAC que apresentava uma maior definição de imagem. Estes sistemas europeus não obtiveram um êxito comercial e a comunidade científica voltou suas pesquisas para um padrão totalmente digital.

Foi em 1987, nos Estados Unidos com o ACATS (*Advisory Committee on Advanced Television*), que se iniciou o desenvolvimento de um sistema totalmente digital, o DTV (*Digital Television*), porém nenhuma das propostas testadas nos laboratórios de pesquisa conseguiu satisfazer todos os requisitos do sistema digital. A partir desses resultados sete grandes empresas e instituições (incluindo a Phillips e MIT) se uniram para desenvolver um novo padrão de televisão digital, esse grupo de pesquisa foi denominado de “Grande Aliança”.

Após as pesquisas dos grupos europeus e da Grande Aliança, finalmente, em 1998, os padrões europeu *Digital Video Broadcasting* (DVB) e americano

Advanced Television System Committee (ATSC) entraram em funcionamento. Os japoneses iniciaram sua busca por um padrão totalmente digital somente em 1997 e este só foi implantado em 2000 (FERNANDES; LEMOS; SILVEIRA, 2004).

No caso do Brasil, a TV Analógica está presente em 99% do território nacional e em mais de 95% dos domicílios (BITTENCOURT, 2007). Como consequência, é possível acesso a quase toda população brasileira, tornando a TV um dos principais meios de integração nacional.

A televisão analógica oferece somente fluxos de áudio e vídeo, sendo o telespectador um agente passivo ao conteúdo transmitido. A TVDI é um avanço em relação à analógica no sentido de uma melhora significativa no áudio e vídeo, porém o telespectador ainda continua sendo um agente passivo. (MONTEZ; BECKER, 2004).

A maior expectativa com relação à televisão digital reside na interatividade. Segundo Montez e Becker (2005), o surgimento de aplicações interativas, levam a uma mudança de comportamento dos telespectadores que passam a assumir uma postura pró-ativa.

Com a TVDI, surgem novas possibilidades de exploração comercial e de negócios, além disso, com a interatividade é possível aumentar a quantidade e a qualidade dos serviços oferecidos na TV, muitos ainda nem inventados.

2.1 Sistemas de TV Digital

Existem atualmente cinco sistemas de TV Digital no cenário mundial. O sistema europeu, DVB, o sistema norte-americano, ATSC, o sistema japonês, *Integrated Services Digital Broadcasting* (ISDB), o sistema chinês, *Digital Terrestrial Multimedia Broadcast* (DTMB) e o sistema brasileiro, ISDB-TB. A seguir são apresentadas as principais características dos três sistemas de destaque no cenário mundial atualmente: DVB, ATSC e ISDB. O sistema DTMB é pouco discutido na literatura e o ISDB-TB é abordado com mais detalhes na seção 2.2.

O sistema europeu DVB² teve o projeto iniciado nos anos 80. Em 1998 entrou em operação e detém hoje um mercado de 500 milhões de receptores. O sistema adota o padrão MPEG-2 para vídeo e o MPEG-2 *Layer 2* para áudio. O *middleware* do sistema DVB é o *Multimedia Home Platform* (MHP). Assim com o ISDB-TB, o sistema DVB privilegia a interatividade do telespectador.

O sistema norte-americano ATSC³ foi desenvolvido a partir de 1987 por um grupo de empresas do ramo de eletrônicos. Possui um mercado de 267 milhões de televisores. O *middleware* do sistema ATSC é o DASE. O padrão foi projetado para prover a melhor imagem possível sem previsão de interatividade com os telespectadores. O padrão adotado para vídeo é o MPEG-2 HDTV e o áudio *Dolby AAC*. Recentemente, o sistema ATSC aprovou a norma A/153 que define especificações técnicas para recepção de sinal digital nos dispositivos móveis, tais como celulares e *handheld*.

O sistema japonês ISDB⁴ é considerado versátil, pois possibilita bons resultados em mobilidade e portabilidade. O *middleware* é o ARIB e utiliza o padrão MPEG-2 Video. O áudio segue o padrão MPEG-2 AAC (*Advanced Audio Coding*). Em 2003, o sistema começou a operar e, recentemente, foi adotado pela Venezuela.

Como mencionado anteriormente, o governo brasileiro tomou a iniciativa de criar o SBTVD que utiliza o padrão MPEG-4 para vídeo e MPEG-2 AAC para áudio e será detalhado a seguir.

2.2 O Sistema Brasileiro de Televisão Digital

O padrão do SBTVD é uma combinação entre a tecnologia japonesa e as inovações desenvolvidas por pesquisas brasileiras, tais como os métodos de compressão, sistemas operacionais e *softwares* (MONTEZ; BECKER, 2005).

Em 26 de novembro de 2003, foi instituído a partir do Decreto N° 4.901, o

² <http://www.dvb.org/>

³ <http://www.atsc.org/>

⁴ <http://www.dibeg.org/>

Sistema Brasileiro de Televisão Digital (MONTEZ; BECKER, 2005; SBTVD, 2008; DOU, 2003). Com este decreto, as discussões em relação ao padrão de TVDI 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 japonês foi adotado para modulação, codificação e decodificação dos sinais de áudio e vídeo que consiste na camada de baixo nível. Nas camadas superiores, decidiu-se por inovações brasileira, dando origem ao padrão brasileiro chamado *International Standard for Digital Television Terrestrial ISDTV-T* (DOU, 2006). A partir do início de 2007, o padrão brasileiro passou a ser denominado de ISDB-TB.

A principal inovação no SBTVD está nas camadas superiores, com a proposição do *middleware* denominado Ginga (GINGA,2008).

Middleware é a camada de *software* localizada entre as aplicações (programas de uso final) e o sistema operacional. Seu objetivo é oferecer às aplicações suporte necessário para seu rápido e fácil desenvolvimento, além de esconder os detalhes das camadas inferiores, bem como a heterogeneidade entre os diferentes sistemas operacionais e *hardwares*, definindo, para os que produzem conteúdo, uma visão única de aparelho. Ginga-NCL é o subsistema “lógico” do *middleware* Ginga que processa documentos *Nested Context Language* (NCL) e objetos mídias. Ginga-J (OPENGINGA, 2009) é o subsistema “lógico” que controla a execução de aplicações baseadas na JavaTV⁵. A união desses dois subsistemas “lógicos” constitui o *middleware* Ginga (SOARES, 2006; ALVES, 2008). 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, 2009). O subsistema 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 (NCL, 2009). Já o subsistema Ginga-J, utiliza a linguagem Java e,

⁵“JavaTV é uma biblioteca que contempla a maior parte dos recursos necessários para a operação de sistemas receptores de TV digital”.

deste modo, possibilita o desenvolvimento de aplicativos procedurais baseados em Xlets (SOARES; SOUZA, 2007).

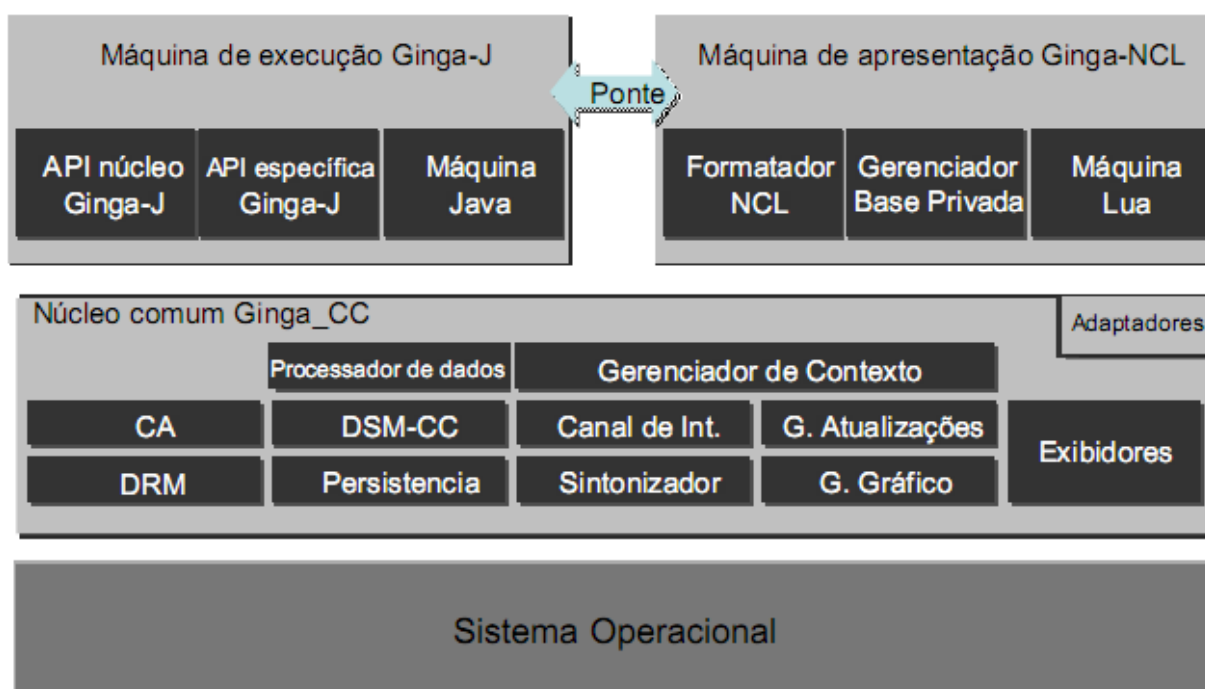


Figura 1 – Arquitetura do Middleware Ginga adaptado de (SOARES, 2007)

Conforme ilustrado na Figura 1, o *middleware* Ginga está dividido em três camadas, sendo: camada de apresentação, composta pela máquina de execução Ginga-J e a máquina de apresentação Ginga-NCL, responsável pela execução das aplicações interativas; camada *Common Core* ou *núcleo comum Ginga_CC*, responsável em prover recursos de troca de serviço, gerenciamento de perfil, recepção e processamento das *transport stream*, entre outras funções; camada do sistema operacional que provê gerenciamento de memória, serviços de rede, entre outros.

Uma inovação do *middleware* Ginga em relação aos outros sistemas é a possibilidade de desenvolver aplicações híbridas. Uma aplicação Ginga não precisa ser totalmente declarativa ou procedural, pois os ambientes de apresentação e execução são interconectados por uma ponte que permite que uma aplicação declarativa NCL referencie uma aplicação procedural Xlet e vice-versa (SOUZA; LEITE; BATISTA, 2007). Nesse sentido, as aplicações Ginga podem explorar o melhor das duas abordagens.

Outra inovação presente no *middleware* Ginga é a máquina LUA. “Lua é uma linguagem de programação, rápida e leve, projetada para estender aplicações. Lua combina sintaxe simples para programação procedural” (LUA, 2009). A máquina Lua permite que aplicações NCL executem *scripts* Lua. *Scripts* Lua possibilitam as aplicações declarativas NCL solicitarem serviços da camada *Common Core* do Ginga. Essa possibilidade estende o universo das aplicações NCL, permitindo o desenvolvimento de sistemas complexos que manipulem base de dados, solicitem serviços de canal de retorno e acessem arquivos no disco, por exemplo.

2.3 Componentes de um sistema de televisão digital interativa

Apesar da arquitetura de sistemas de televisão analógica atual já ser capaz de apresentar um conjunto de componentes digitais (forma de armazenamento, ilha de edição, câmeras e satélites), a implantação do sistema de televisão digital implica um conjunto de impactos em toda a arquitetura da televisão desde a gravação em estúdio à recepção realizada na casa do telespectador.

No estúdio, os impactos são: a câmera digital possui maior resolução de linhas e colunas, utilização de codificador MPEG para aplicar técnicas de compressão de dados e ilha de edição passa a ser não linear, pois as cenas gravadas passam a ser armazenadas em discos rígidos e DVD. A central de produções passa a ser chamada de **provedora de serviços** graças à introdução de três elementos: o *streamer*, o multiplexador e o Carrossel de dados. (FERNANDES; LEMOS; SILVEIRA, 2004). A radiodifusão apresenta novos algoritmos e técnicas de compressão de dados. Na recepção doméstica, percebe-se a inclusão do STB para recebimento, decodificação e demultiplexação dos sinais digitais.

Os STB além de responsáveis pela decodificação e demultiplexação dos sinais digitais, podem permitir a comunicação entre o telespectador e a emissora através de um canal de retorno. Assim, da mesma maneira que o telespectador recebe os dados enviados pela emissora, ele também pode enviar dados para a mesma. A emissora, portanto, pode interagir em tempo real com o telespectador

através de um provedor de serviços que recebe e processa as informações enviadas pelo telespectador.

Conforme visto, o usuário não está mais diante de um simples aparelho de TV, mas sim de um dispositivo dotado de poder de processamento computacional capaz de executar aplicativos (ALVES, 2008). A Figura 2 ilustra a arquitetura da TVDI, que tem seu ciclo de vida iniciado nos provedores de serviços (etapa 1), onde os programas e aplicações são preparadas, codificadas, multiplexadas e, posteriormente, transmitidas em *broadcast* (etapa 2), e completando o ciclo de vida no telespectador (etapa 3) que, interagindo com os programas interativos, tem a possibilidade de enviar informações através de um canal de retorno (etapa 4) ao provedor de serviço de interação (etapa 5).

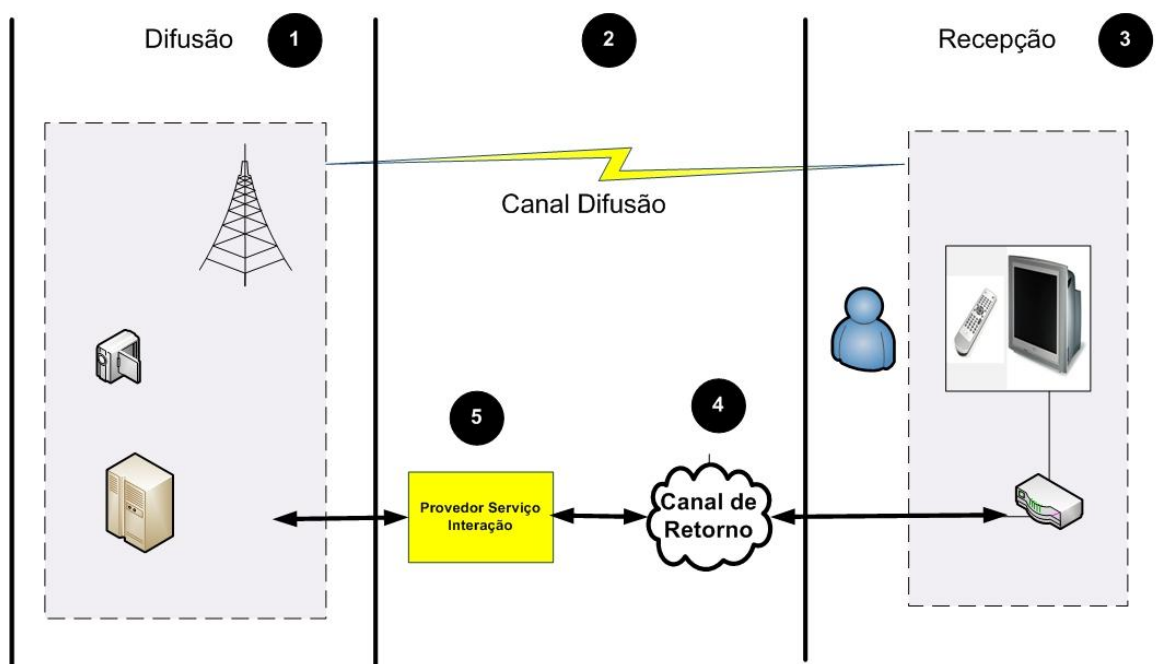


Figura 2– TV Digital Interativa adaptado de (ALVES et al. , 2008)

A seguir, são abordados os principais componentes que compõe a difusão e recepção no contexto da TVDI, detalhando os metadados envolvidos nessa operação e que são fundamentais para o trabalho proposto.

2.3.1 Provedores de Serviços

No sistema de TVDI é previsto além da transmissão de áudio e vídeo, o envio de dados ao telespectador. Os provedores de serviços podem enviar por *broadcast* aplicativos escritos em Java, conhecidos como Xlets, ou aplicações NCL, ambos definidos no padrão do SBTVD. Além das aplicações, os provedores de serviços enviam tabelas que transportam informações ao STB. Para o contexto desse trabalho, duas tabelas são importantes: a EIT (*Event Information Table*) e a SDT (*Service Description Table*).

Os sistemas abertos de televisão digital adotam o padrão MPEG-2 System – *Transport Stream* para a multiplexação dos fluxos elementares. Para se compreender o que são fluxos elementares, é preciso entender como é feita a construção do sinal digital. Inicialmente, o áudio capturado pelo microfone e o vídeo capturado pela câmera são enviados separadamente ao codificador de áudio e ao codificador de vídeo. Os aplicativos e as estruturas de dados, comentadas a seguir, são enviados ao codificador de dados. O fluxo de bits gerado pelos codificadores separadamente são denominados fluxos elementares. Uma vez multiplexados em um único fluxo de bits, os fluxos elementares passam a ser denominado fluxo de transporte. A Figura 3 ilustra o processo de codificação, multiplexação e modulação.

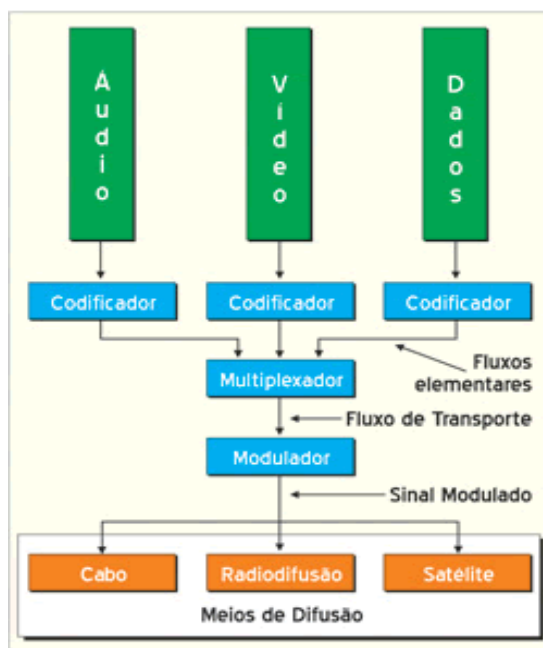


Figura 3 - Etapas de difusão sinal adaptada de (PICCIONI, 2005)

Podem ser multiplexados dois tipos de estruturas de dados em um fluxo de transporte: os fluxos elementares empacotados PES (*Packetized Elementary Stream*) e as seções. As seções são estruturas definidas para o transporte de tabelas que são conhecidas como *Program Specific Information* (PSI). A ABNT NBR 15603 (2007) especifica em detalhes a estrutura para a construção das informações básicas relacionadas à PSI que fazem parte do SBTVD.

Conforme mencionado, para este trabalho, duas tabelas são fundamentais: a tabela EIT e a tabela SDT definidas e padronizadas na norma NBR 15603-2 (2007). A tabela EIT é usada para apresentar informações específicas de programas, tais como: nome do programa, hora de início, duração, etc. A tabela EIT permite que mais informações sejam disponibilizadas pelos provedores de serviços através de seus descritores. Um exemplo de informação transportada pelos descritores são os gêneros dos programas, classificação etária e a descrição de eventos curtos ou estendidos. A tabela SDT contém informações que descrevem os serviços no sistema, tais como: o nome do serviço e provedor do serviço. Essas tabelas serão detalhadas na próxima seção.

2.3.2 Metadados em TV Digital Interativa

De acordo com LUGMAYR *et. al* (2004), metadados significam informações que descrevem outras informações, pelos quais é possível estruturar, manipular, representar e gerenciar as informações em diversos ambientes, essa definição é adotada por vários autores.

Os metadados são fundamentais no ambiente de TVDI. Nos padrões atuais de TVDI, a transmissão de informações está puramente baseada nas definições de metadados das tabelas de informações de serviços SI (*Service Information*). As tabelas SI estendem as tabelas PSI do padrão MPEG-2 definindo um conjunto de estruturas que possuem dados descritivos que carregam informações de serviços específicas do domínio da TVDI. O uso de tais tabelas facilita a criação, o tratamento e a rápida extração das informações (ALVES *et al.*, 2006).

Na TVDI os metadados devem ser usados, essencialmente, para representar as informações sobre os serviços e descrever os conteúdos multimídia transmitidos

por canal de difusão ou canal de retorno (ALVES *et al.*, 2006). A possibilidade de transmitir mais de um serviço simultaneamente torna o uso de metadados fundamentais para o STB identificar qual serviço será solicitado pelo usuário em determinado momento.

Os provedores de serviços são os responsáveis em preparar os metadados e difundir tais informações através da *transport stream*.

A tabela EIT transporta informações de data e hora do programa, gênero e subgênero, informações que descrevem a sinopse do programa, entre outras. Uma característica importante da tabela EIT é que a mesma transporta informações referentes à programação futura, a norma NBR 15603-2 especifica e define códigos para até oito dias de programação futura. No sistema TV Digital Europeu, as emissoras trabalham em média com 14 dias de programação (ZHANG, 2005).

A tabela EIT é composta por campos de identificação, dados e por descritores ilustrados na Figura 4.

Syntax	No. of Bits	Identifier
event_information_section(){		
table_id	8	uimsbf
section_sy	1	bslbf
reserved_1	1	bslbf
reserved	2	bslbf
section_length	12	uimsbf
service_id	16	uimsbf
reserved	2	bslbf
version_number	5	uimsbf
current_next_indicator	1	bslbf
section_number	8	uimsbf
last_section_number	8	uimsbf
transport_stream_id	16	uimsbf
original_network_id	16	uimsbf
segment_last_section_number	8	uimsbf
last_table_id	8	uimsbf
for(i=0;i<N;i++){		
event_id	16	uimsbf
start_time	40	bslbf
duration	24	uimsbf
running_status	3	uimsbf
free_CA_mode	1	bslbf
descriptors_loop_length	12	uimsbf
for(i=0;i<N;i++){		
descriptor()		
}		
CRC_32	32	rpchof
}		

Figura 4– Campos da Tabela EIT adaptado de (MORRIS; SMITH-CHAIGNEAU, 2005)

Os campos de identificação são necessários para que o STB seja capaz de identificar dentro da *transport stream* a tabela EIT (1) e, desta forma, reconstruir as informações que ela transporta, obtendo uma cópia idêntica a que foi originalmente transmitida pelo provedor de serviço.

Os dados (2) transportam informações referentes ao serviço, como identificador do serviço (2a), data e hora de início do programa (2b), duração do programa (2c), sendo esses os mais relevantes.

Os descritores da tabela EIT (3) são estruturas que transportam informações adicionais e são encapsulados dentro da própria tabela, de tal forma que, um determinado serviço possa ter associado a ele diversos descritores. Na Figura 4 a variável N representa o número de descritores associados. Os descritores definem, por exemplo, a classificação etária do programa (descritor de classificação indicativa), a possibilidade de gravação do programa (descritor de controle de cópia digital), o gênero e subgênero do programa (descritor de conteúdo), a sinopse do programa, que pode ser um texto limitado a 256 bytes (descritor de eventos curtos) ou um texto de até 4096 Kb (descritor de eventos longos).

Um importante descritor presente na tabela EIT é o descritor de conteúdo, sendo ele o responsável em transportar a classificação de gênero e subgênero do programa.

A norma NBR-15603-2 (2007) define 16 gêneros que devem ser utilizados pelos provedores de serviços ao transmitir sua programação. Além do gênero, a norma brasileira prevê a utilização de subgênero. Essa abordagem permite distinguir um programa classificado como Jornalismo Telejornal de outro, classificado como Jornalismo documentário. A Tabela 1 apresenta a classificação de gênero e subgênero definidos na norma brasileira. Essas informações são úteis em sistema de recomendação.

Tabela 1 – Classificação dos gêneros/subgêneros - Amostra

Classificação de Gênero	Classificação de Subgênero	Descritor de Conteúdo
0x00	0x00	Telejornais
0x00	0x01	Reportagem
0x00	0x02	Documentário
0x00	0x03	Biografia
0x01	0x00	Esportes
0x02	0x00	Educativo
0x03	0x00	Novela

Assim que a tabela EIT é reconstruída no STB, as informações de gênero e subgênero tornam-se disponíveis, podendo ser acessadas por *APIs* que compõe o Ginga-J e são definidas em (SUN DTV, 2008).

A tabela SDT tem como principal objetivo transportar informações sobre os provedores de serviços. No sistema analógico, os provedores de serviços são conhecidos como emissoras. De maneira análoga à EIT, a tabela SDT permite o uso de vários descritores, que transmitem informações adicionais. O principal descritor é o *service descriptor* que permite definir o nome do provedor de serviço. A Figura 5 ilustra a estrutura de dados do *service descriptor*. O campo intitulado **Char (service provider name)** é preenchido com o nome do provedor de serviço. No contexto do SBTVD, alguns valores válidos seriam Globo, SBT e *Record*, entre outros.




Figura 5– Estrutura de dados do descritor de serviços (NBR 15603-1, 2007)

Em linhas gerais, a tabela SDT traz informações sobre os provedores de serviços, entretanto, não oferece nenhuma informação sobre as programações disponíveis desses provedores de serviços.

A tabela SDT é amplamente utilizada em conjunto com a tabela EIT pelos aplicativos de EPG, enquanto a SDT informa os provedores de serviços, a EIT descreve os programas e horários, entre outras informações. (MORRIS; SMITH-CHAIGNEAU, 2005).

2.3.3 Carrossel de Dados

O carrossel de dados é uma das inovações nos provedores de serviço da TVDI responsável pela transmissão cíclica de um conjunto de dados / objetos através da *transport stream*. Essa característica é fundamental para que informações recebidas de forma incompleta, devido à perda na difusão ou problemas na demultiplexação no STB, possam ser completadas bastando aguardar o próximo ciclo do carrossel. No caso da tabela EIT, a norma NBR 15603-2 (2007) define um intervalo de no máximo 10 segundos entre transmissões. Os dados transportados na *transport stream* podem ser armazenados em cachê no STB, e essa característica é fundamental para o trabalho proposto nessa dissertação. A Figura 6 ilustra o funcionamento do carrossel de dados, dando ênfase na característica cíclica.

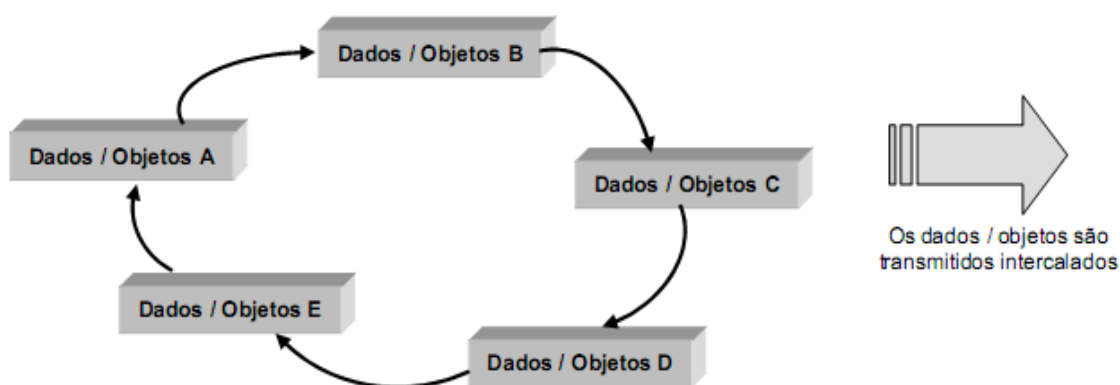


Figura 6 – Carrossel de dados / Objetos (Alves, 2008)

Segundo (PICCIONI, 2005; ALVES, 2008), existem dois tipos básicos de carrosséis padronizados: carrossel de dados e carrossel de objetos. O primeiro organiza as informações em módulos, sendo responsabilidade das aplicações interativas manipular os dados, já o segundo reproduz no STB a mesma estrutura de arquivos e diretórios existentes na emissora. A implementação do

carrossel de dados/objetos em fluxos de transporte MPEG-2 é baseado no protocolo DSM-CC (*Digital Storage Media – Command and Control*).

No contexto desse trabalho, o carrossel de dados é responsável em transmitir, de forma cíclica, as tabelas SI que transportam diversas informações, inclusive: nome do provedor de serviço, nome do serviço, data de início, tempo de duração, gênero, subgênero, classificação etária, entre outras. Essas informações são persistidas no cachê e posteriormente utilizadas para prover serviços de personalização.

2.3.4 Recepção

Na recepção, a principal novidade é a inclusão do STB ou terminal de acesso nos domicílios dos telespectadores. Esse novo dispositivo é o responsável em receber o sinal do provedor de serviço e realizar a demodulação, ou seja, sintonizar um determinado canal. Em seguida, o fluxo de bits da *transport stream* é encaminhado ao demultiplexador. Este separa os fluxos de áudio, vídeo e dados. Áudio e vídeo são encaminhados para o *hardware* responsável em tratá-los e os dados são entregues ao *middleware* (BARBOSA; SOARES, 2008).

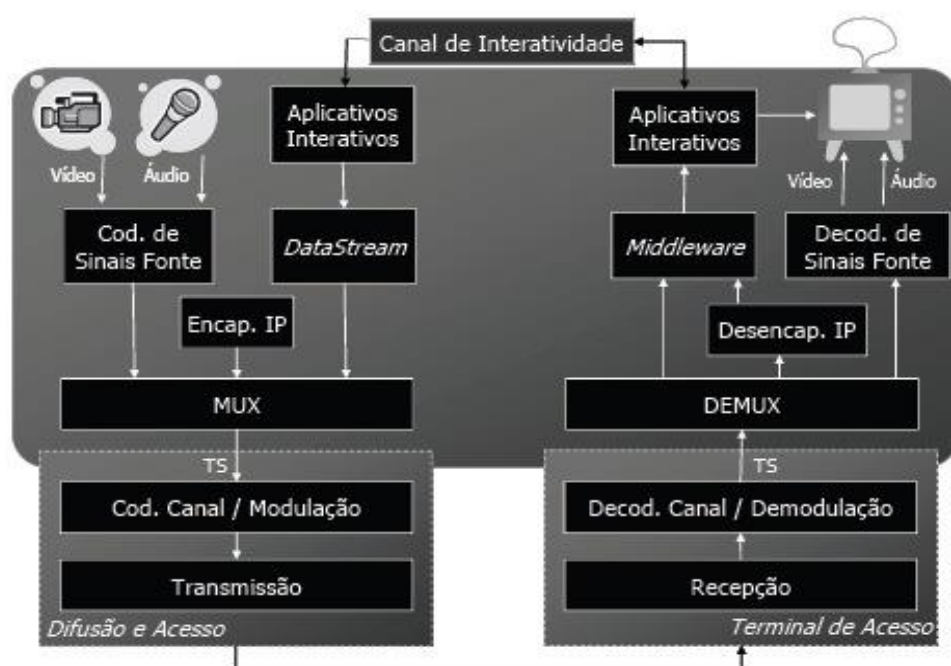


Figura 7 – Processo de transmissão e recepção de TVDI (BARBOSA; SOARES, 2008)

A Figura 7 ilustra o processo de transmissão e recepção. O processo de recepção pode ser visualizado observando-se o lado direito da figura 7.

Os terminais de acesso são produzidos e comercializados por diferentes fabricantes, esses por sua vez podem adotar diferentes arquiteturas e sistemas operacionais. As aplicações interativas devem ser capazes de executar em qualquer terminal de acesso, independente do fabricante ou da arquitetura utilizada. Para prover essa capacidade é necessário um *software* que permita às aplicações abstrair as especificidades de *hardware* e *software* dos diversos terminais de acessos. No cenário brasileiro, esse software é o *middleware* Ginga (FERNANDES; SOUZA FILHO, 2004 ; ALVES, 2008).

3

SISTEMAS DE RECOMENDAÇÃO

O principal objetivo do sistema de recomendação é conduzir o usuário, através de sugestões, conselhos e advertências, permitindo que de acordo com o perfil pré-determinado seja sugerido ou recomendado serviços diversos (CHORIANOPOULOS, 2008).

Sistemas de recomendação têm sido muito empregados em páginas Web, com relativo sucesso, principalmente em sistemas de comércio eletrônico. Com advento da TVDI e, conseqüentemente, com o aumento da quantidade de serviços é imprescindível que apareçam soluções para auxiliar os usuários na escolha de seus programas prediletos. Nesse contexto, sistemas de recomendação emergem como uma solução possível para atender às necessidades dos usuários.

Segundo CHORIANOPOULOS (2008), os dois principais desafios a serem solucionados no contexto de sistema de recomendação para TVDI são: coleta de informação e métodos empregados na recomendação.

3.1 Coleta de Conteúdo

Duas abordagens são adotadas atualmente para coleta de informação: a abordagem explícita e a abordagem implícita. No trabalho de XU *et al.* (2002), é apresentado a abordagem explícita. Nessa abordagem, o usuário informa ao sistema quais suas preferências de programas, sendo que o ponto positivo da coleta explícita é a maior precisão das informações para expressar interesses ou preferências, mas o ponto negativo é a dificuldade de se entrar dados em um sistema de TVDI que utiliza o controle remoto para interação do usuário com o STB.

Em BLANCO-FERNANDEZ *et al.* (2005), é apresentado um sistema de recomendação que adota abordagem implícita para coleta de dados. A abordagem implícita é transparente ao usuário e pode ser realizada por monitoramento

constante do seu comportamento. A coleta implícita é cômoda para o usuário que tem todas as ações monitoradas de forma transparente, sem até mesmo perceber que é monitorado. O ponto positivo da abordagem implícita reside no fato de ser prática do ponto de vista do sistema de TVDI, já que não exige do usuário informar nenhum dado, uma dificuldade quando se utiliza controle remoto para interação no sistema.

3.2 Métodos empregados na recomendação

Dentre os métodos empregados na recomendação de conteúdo, destacado por CHORIANOPOULOS (2008) como um desafio a ser solucionado, os mais conhecidos e utilizados são a Filtragem Baseada em Conteúdo (FBC) e a Filtragem Colaborativa (FC).

A **FBC** é uma técnica que utiliza informações anteriores ou preferências anteriores do usuário para inferir seu comportamento futuro. A FBC mede a similaridade entre os serviços. Sendo assim, se um usuário gostou de um determinado programa, é bem provável que no futuro ele goste de outro com as mesmas características. TORRES (2004) destaca que para efetuar recomendação baseada na técnica FBC basta recomendar programas similares ao perfil do usuário; o perfil é obtido através do monitoramento ou coleta de conteúdos.

A **FC** é uma abordagem baseada na similaridade de hábitos de comportamento entre os usuários para gerar recomendações (TORRES, 2004). A abordagem colaborativa assume que um usuário comporta-se de forma semelhante a outros usuários com características parecidas.

ALVES *et al.* (2008) adotada a abordagem de FC para a criação de um EPG, sendo que nessa proposta o usuário ao assistir determinado programa, tem a possibilidade de avaliá-lo com uma nota de 1 a 5. A avaliação é então submetida a um servidor através do canal de retorno do STB onde é feito todo o processamento dos dados recebidos e o agrupamento dos usuários com perfis semelhantes. Cada vez que determinado usuário acessa o EPG, é apresentada uma lista de programas

recomendados por outros usuários que tem em comum as mesmas preferências. A lista de programas recomendados é obtida através do canal de retorno. Os programas com maiores notas ocupam as primeiras posições no *ranking* de recomendações.

As abordagens comentadas podem ser utilizadas juntamente com outras técnicas para manipular as informações coletadas aprimorando as recomendações. Uma das técnicas utilizadas é a descoberta de conhecimento.

3.3 Descoberta de Conhecimento

Segundo FAYYAD *et. al* (1996), o objetivo da descoberta de conhecimento é extrair informações que seja inteligíveis e imediatamente utilizáveis para o apoio das decisões.

O processo de descoberta de conhecimento ou KDD (*Knowledge Discovery in Database*) é composto de várias etapas, sendo a mineração de dados uma importante fase desse processamento. A seguir são apresentadas as etapas envolvidas no processo.

O processo tem início com a coleta das informações, ou seja, os dados brutos que deseja-se extrair algum conhecimento. Em seguida, na segunda etapa, os dados coletados devem ser preparados para um formato adequado e também se deve eliminar eventuais inconsistências. A terceira etapa consiste na fase de transformação dos dados, onde com a utilização dos dados pré-processados e livres de inconsistências ocorre a adequação aos algoritmos de mineração, ou seja, os dados são formatados para um padrão de entrada para ser utilizado por algoritmos de mineração. A quarta etapa é a mineração de dados, onde ocorre a extração dos padrões propriamente ditos. Uma vez descoberto os padrões na fase de mineração tem-se início a quinta etapa, que é a interpretação dos padrões descobertos, a eliminação de padrões com pouca relevância e, se necessário, o retorno a algum passo anterior.

O trabalho apresentado nessa dissertação explora diversas fases do processo de KDD, como por exemplo, a coleta de informações, preparação e transformação

dos dados eliminando informações nulas e por fim a fase de mineração e interpretação dos padrões obtidos.

A fase de mineração de dados é com certeza a mais complexa, sendo considerada até sinônimo de KDD (HAN; KAMBER, 2006).

O processo de mineração consiste de três fases: escolha da tarefa de mineração, a escolha do algoritmo e a extração de padrões.

A tarefa de mineração é classificada pelo tipo de padrão que se deseja obter e as principais tarefas são: classificação, associação e agrupamento (SCHAFER, 2001).

A classificação permite definir novos grupos a partir de dados existentes mediante um modelo ou classificador. 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 busca encontrar relacionamento ou padrões frequentes entre os dados. Em um sistema de recomendação, regras de associação podem identificar itens de preferência de um usuário baseado em um histórico prévio.

O agrupamento, assim como a classificação, é uma tarefa que visa compor subgrupos a partir dos dados pesquisados. O objetivo é agrupar objetos similares (HAN; KAMBER, 2006).

A escolha do algoritmo é a segunda etapa do processo de mineração e baseia-se diretamente no tipo de tarefa escolhida. Existe uma gama de algoritmos de mineração, cada qual adaptado para uma determinada tarefa.

A terceira etapa é a extração de padrões. Uma vez definida a tarefa e o algoritmo empregado ocorre à extração dos padrões contidos nos dados.

No cenário de TVDI, as regras de associação se adequam de forma satisfatória na tarefa de prover personalização para os telespectadores. Regras de associação identificam com eficiência padrões em um histórico de visualização, com objetivo de evidenciar um comportamento. Há diversos algoritmos usados em regras de associação, dentre eles, Apriori, DHP, Tertius e Predictive Apriori. O algoritmo mais utilizado para regras de associação é o Apriori proposto por AGRAWAL e SRIKANT (1994). Na implementação de referência dessa proposta optou-se em utilizar regras de associação e o algoritmo Apriori.

3.4 Recomendação para multiusuários

Num ambiente doméstico é comum vários usuários compartilharem o mesmo aparelho de TV. Diferente dos computadores, onde a utilização de *login* e senha é uma prática comum, o que facilita a identificação do usuário, em um sistema de TVDI essa prática é pouco ou quase nunca utilizada devido à dificuldade imposta pelos dispositivos de entrada de dados.

Um dos maiores desafios é detectar implicitamente quem é o telespectador que está assistindo a TV em determinado momento. Algumas pesquisas foram realizadas a fim de prover mecanismos eficientes para detectar quem é o usuário e, desta forma, recomendar programas baseado no perfil desse usuário em questão. No trabalho apresentado por MIN-CHEOL HWANG *et al.* (2007), é discutido a utilização de câmeras equipadas com sensores que permitem identificar o usuário via *software* de reconhecimento facial. Nesse trabalho, uma vez que o telespectador foi identificado, essa informação é enviada ao sistema de recomendação. Identificado o telespectador, o sistema de recomendação tem a possibilidade de produzir resultados mais pertinentes ao usuário em questão. O índice de acerto da identificação do usuário do sistema de reconhecimento facial é em média de 92% em condições de luminosidade baixa, ou seja, o pior cenário possível.

Para o contexto do SBTVD, essa abordagem encontra-se longe de tornar-se realidade, em virtude das limitações de memória, capacidade de processamento do STB, mas acima de tudo, em virtude das questões de custos envolvidos. Entretanto, é uma alternativa futura que não deve ser totalmente descartada.

Prevendo a necessidade de identificação de perfil dos telespectadores, a implementação de referência do *middleware* Ginga implementa o módulo *Context Manager*, integrante do *Common Core* do Ginga responsável em gerenciar e oferecer diversas informações sobre o *hardware* disponível e também sobre os usuários do STB.

O gerenciamento de informações de usuários é feita por uma aplicação responsável em apresentar o *front-end*, onde é possível informar os dados que, posteriormente, serão persistidos em memória não volátil. A Figura 8 apresenta a

interface que permite aos usuários cadastrar informações pessoais como: nome, idade, CEP e sexo.

Create a new user account.

Ginga Live!
<http://www.ginga.org.br>

User Creation

Name: Paulo
Age: 32
Location (Zip): 37706254
Genre (m/f): m

> Create User

Press (Enter) to create this user.

Ginga® is a trademark of PUC-Rio and UFPB

Figura 8 – Aplicação interativa que permite a inserção de dados do usuário no STB

Apesar do *middleware* Ginga implementar o suporte ao gerenciamento de perfil, a detecção do usuário é feita de forma explícita, ou seja, o usuário tem que se identificar ao sistema, através do controle remoto, por exemplo. Segundo Zhiwen *et al.* (2006), em geral, o procedimento de *login* é rejeitado principalmente quando ocorre a troca constante de usuários no sistema.

A necessidade de identificação explícita do usuário é um ponto negativo, pois um sistema de recomendação que se baseie exclusivamente nessas informações parte da suposição que o usuário sempre irá se identificar o que pode não ocorrer. Diante desse problema, Zhiwen *et al.* (2006), propôs a junção do perfil de múltiplos telespectadores constituindo uma única base de perfil no ambiente televisivo, os resultados obtidos comprovaram que a união do perfil dos telespectadores pode refletir de forma adequada nas preferências da maioria dos membros de um grupo.

Apesar da rejeição do *login* por parte dos usuários, reportados por Zhiwen *et al.* (2006), essa técnica permite explorar um novo nicho de negócios conhecido como publicidade personalizada. As informações de idade, sexo e CEP são valiosas se levarmos em consideração que os provedores de serviço podem transmitir

aplicativos personalizados criando uma nova maneira de fazer publicidade. A informação CEP permite delinear regiões de perfil socioeconômico que pode ser mapeada em classes. As informações de sexo e idade são valiosas para prover publicidade personalizada visando um público alvo. Nesse sentido, técnicas alternativas de detecção implícita estão sendo desenvolvidas, superando os problemas de rejeição de *login*, como por exemplo, os controles remotos biométricos.

3.5 Apresentação das recomendações

A apresentação das recomendações para os usuários é a etapa final do sistema de recomendação, trata-se de uma fase onde a apresentação visual é extremamente importante, pois é onde toda interação ocorre. A apresentação dos resultados depende exclusivamente da maneira como a aplicação responsável em exibir os resultados foi desenvolvida, porém percebe-se uma preferência em apresentar os dados como uma lista ordenada e limitada aos itens mais relevantes ao usuário.

Segundo CHORIANOPOULOS (2008) a apresentação das recomendações pode seguir duas abordagens. Na primeira, a apresentação das recomendações ocorre sem que o usuário solicite a recomendação, essa abordagem é denominada tecnologia *Push*. A segunda abordagem, denominada como tecnologia *Pull* apresenta as informações somente quando o usuário solicita.

Do ponto de vista de um sistema TVDI a abordagem *Pull* é bem mais indicada, por permitir total liberdade ao usuário em solicitar recomendação quando lhe for apropriado.

No contexto de TVDI, a apresentação dos resultados é responsabilidade das aplicações interativas. Um dos objetivos desse trabalho é permitir aos desenvolvedores de tais aplicações total liberdade para implementar a interface gráfica, sem se preocupar com as questões de coletas, descoberta de conhecimento, mineração de dados e persistência das recomendações.

3.6 Observações Finais

Neste trabalho, adotou-se a abordagem de coleta implícita de dados, conforme mencionado, essa abordagem é transparente ao usuário e se adapta melhor ao ambiente de TVDI onde a inserção de dados é um fator limitante. A técnica de filtragem aplicada é a FBC, diferente do trabalho de ALVES *et al.* (2008) as recomendações serão processadas no STB e não está previsto comunicação por canal de retorno. Finalmente, adotou-se a possibilidade de utilizar o perfil de grupo de usuários ou o perfil individual, deixando como escolha do desenvolvedor da aplicação qual abordagem utilizar. Nesse sentido, tanto perfis individuais dos telespectadores quanto o perfil do grupo são armazenados. Essa decisão de armazenar perfis individuais e perfil do grupo tem como objetivo permitir que aplicações de publicidade dirigida tenham acesso e beneficiem-se das informações coletadas e persistidas no STB.

No próximo capítulo é apresentado o módulo *Recommender TV* para suporte ao desenvolvimento de sistemas de recomendação e sua integração ao *middleware* brasileiro Ginga.

4

MÓDULO RECOMMENDER TV

Este capítulo tem o objetivo de apresentar o módulo *Recommender TV* para suporte ao desenvolvimento de sistemas de recomendação em ambientes de TVDI. Sendo assim, esse capítulo está organizado da seguinte forma: A seção 4.1 apresenta uma visão geral do módulo *Recommender TV*. A seção 4.2 apresenta detalhes da comunicação entre o módulo *Recommender TV* e as aplicações interativas. A seção 4.3 apresenta a arquitetura do módulo *Recommender TV* e sua interconexão com a implementação de referência do *middleware* Ginga.

4.1 Visão Geral

O principal objetivo do módulo *Recommender TV* é permitir aos desenvolvedores de aplicações interativas, principalmente os desenvolvedores de sistema de recomendação e propaganda direcionada, abstraírem questões de coleta e persistência de dados, gerenciamento de perfil e mineração de dados, deixando essas tarefas como responsabilidade do módulo apresentado.

Em linhas gerais, o módulo visa disponibilizar recursos para que qualquer sistema de recomendação, executando no STB, possa ofertar serviços de personalização sem necessidade de implementar complexos algoritmos de mineração de dados, coleta e armazenamento de histórico de comportamento de usuário e gerenciamento de perfis.

Para isso, o módulo *Recommender TV* foi projetado como uma extensão ao *middleware* brasileiro, sendo incluído na camada *Common Core* do Ginga, conforme ilustra a Figura 9.

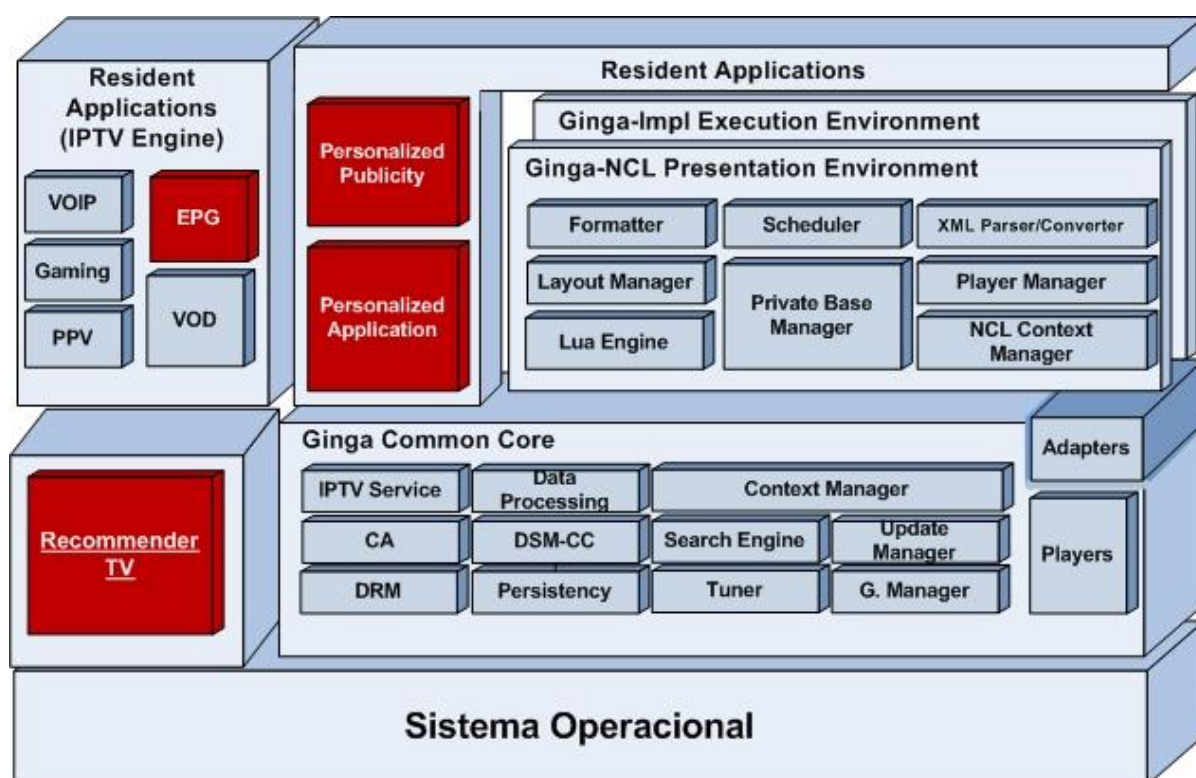


Figura 9 – Arquitetura do *Middleware* Ginga destacando a inserção do módulo *Recommender TV*

4.2 Interconexões do módulo *Recommender TV* e as aplicações interativas

Conforme mencionado, o módulo *Recommender TV* está implementado no *Common Core* da implementação de referência do *middleware* Ginga. Nesse sentido, é possível ao módulo *Recommender TV* comunicar-se com os demais módulos do *Common Core* do Ginga obtendo informações relevantes para o propósito desse trabalho. A extensão de *middleware* já foi apresentada em outros trabalhos como Zhang *et al* (2005) e P.Cesar *et al.* (2006) no contexto do *middleware* europeu MHP. A Figura 10 apresenta as interconexões que possibilitam aos aplicativos interativos utilizarem os serviços ofertados pelo módulo *Recommender TV*.

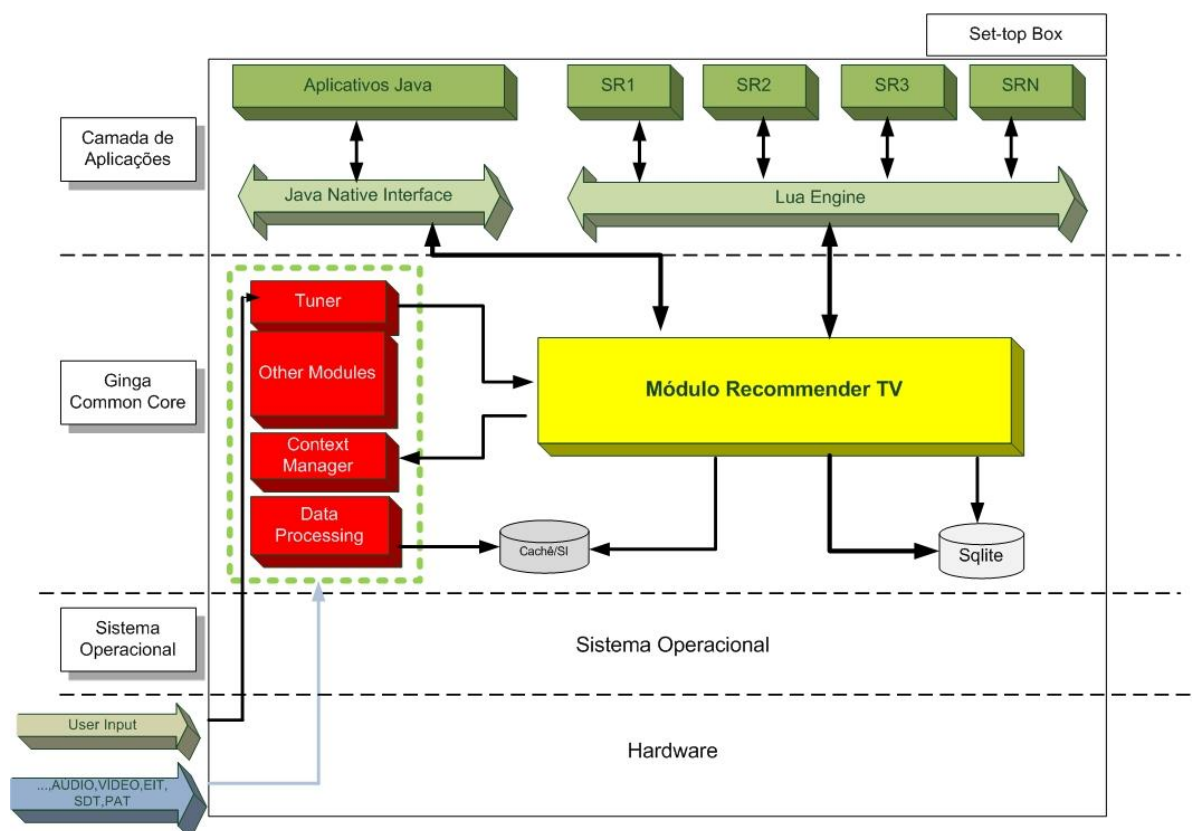


Figura 10 – Interconexão das aplicações interativas com o módulo Recommender TV

Na Figura 10, SR1, SR2, SR3, SRN, são sistemas de recomendação que utilizam os serviços ofertados pelo módulo *Recommender TV*. Dentro desse cenário, se ocorrer uma interação do usuário com o STB, como por exemplo, uma troca de canal, essa interação é detectada pela camada de *hardware* que solicita ao módulo *Tuner* no *Common Core* que proceda com a operação de *zapping*⁶. O módulo *Tuner* envia uma mensagem ao módulo *Recommender TV* notificando que ocorreu uma interação e qual foi a ação ocorrida. A cada mensagem recebida, o módulo *Recommender TV* persiste na base de dados *Sqlite* a ação e também informações de contexto como: horário, dia da semana, provedor de serviço sintonizado, serviço sintonizado, gênero e subgênero do serviço sintonizado. Essa etapa é conhecida como coleta de histórico de visualização do usuário.

Para persistir as informações obtidas, foi utilizado o banco de dados relacional *Sqlite*, sendo que a escolha foi motivada por três facilitadores: ter sido escrito em linguagem C/C++, de maneira análoga a implementação de referência do

⁶ Navegar entre os serviços (canais, no sistema analógico).

middleware Ginga; ter sido projetado para trabalhar em dispositivos embarcados e permitir acesso às informações armazenadas através de consultas SQL, processo bem mais rápido que fazer parser em arquivos *Extensible Markup Language* (XML).

Segundo ALESSIO *et al.* (2007), o baixo consumo de memória, algo em torno a 250 KB com todas as capacidades do banco instaladas, aliado ao fato de ser código fonte livre escrito em C, facilita a portabilidade desse banco de dados nas plataformas *Windows*, *Windows CE*, *Windows Mobile* e principalmente Linux, sistema operacional que equipa a grande maioria dos STBs.

Paralelo às interações do usuário, um fluxo contínuo de áudio, vídeo e dados é recebido pelo *hardware* do STB. Áudio e vídeo são encaminhados para placa de áudio e de vídeo respectivamente e os dados para o módulo *Data Processing* no *Common Core*. O módulo *Data Processing* filtra esses dados e persiste em cache as informações referentes as tabelas SI, entre elas: EIT e SDT. O módulo *Recommender TV* acessa essas informações e também as informações de histórico de visualização persistidas na base de dados relacional *Sqlite* sempre que uma mineração de dados é solicitada. Após concluir a mineração de dados, as recomendações são novamente salvas na base de dados *Sqlite* para que quando requisitadas estejam prontas. Diferente da arquitetura PC (*Personal Computer*) que dispõe de poderosos processadores e vasta quantidade de memória, os STBs na sua grande maioria, não dispõem de tais recursos. Sendo assim, se a cada solicitação de recomendação feita por um sistema de recomendação o módulo *Recommender TV* necessitar rodar seus algoritmos de mineração, o tempo de resposta ao usuário ficará comprometido, tornando inviáveis tais sistemas. Essa abordagem de realizar a mineração de dados e persistir as recomendações antecipadamente é necessária devido às restrições de *hardware* do STB.

A questão de recursos do STB é tão relevante que antes de selecionar os algoritmos responsáveis pela mineração dos dados, o módulo *Recommender TV* solicita ao módulo *Context Manager* informações referentes à *clock* da CPU, quantidade de memória disponível, uso da CPU; para decidir qual o melhor algoritmo de mineração a ser empregado, tendo como base o *hardware* disponível.

Nos sistemas de TVDI, os sistemas de recomendação são o *front-end* com usuário. Ao solicitar uma recomendação deve-se apresentar uma lista com as

sugestões ofertadas, sendo transparente aos usuários os mecanismos envolvidos na elaboração dessa listagem.

No contexto desse trabalho, os sistemas de recomendação solicitam serviços ao módulo *Recommender TV*. Dessa forma, o sistema de recomendação SR1 poderia solicitar ao módulo *Recommender TV* o histórico de visualização de comportamento dos usuários; o sistema de recomendação SR2, por sua vez, pode solicitar informações de *hardware* tais como: *clock* da CPU e memória, por exemplo, e o sistema de recomendação SR3 solicitaria uma lista de recomendação previamente processada, ou seja, três sistemas de recomendação distintos utilizando serviços diferentes do módulo *Recommender TV*. Em linhas gerais, a utilização dos serviços ofertados pelo módulo *Recommender TV*, permite aos desenvolvedores de sistemas de recomendação utilizar ou não os serviços oferecidos, dando flexibilidade de quais serviços disponíveis são interessantes para o contexto do sistema proposto.

O uso do módulo *Recommender TV* é facultativo. Entretanto, vale ressaltar que realizar uma coleta do comportamento do usuário não é uma tarefa trivial para um aplicativo interativo, pois surgem alguns questionamentos importantes como: onde salvar esse histórico ou como garantir que o usuário não finalize o aplicativo interativo e, dessa forma, deixe de coletar os dados. A resposta para esses questionamentos é bem simples. Não se pode garantir. A operação de coleta de histórico de visualização deve ocorrer durante todo o tempo que existir interação do usuário com o STB. Uma aplicação interativa pode ser encerrada a qualquer momento pelo usuário e nesse caso, todas as interações realizadas após o término da aplicação não seriam persistidas na base de dados.

4.3 Arquitetura do Módulo Recommender TV

O módulo *Recommender TV* é composto por duas camadas bem delineadas denominadas: ***Recommender Engine*** e ***Recommender API***.

A camada *Recommender Engine* é invisível aos aplicativos de recomendação, e tem como principal objetivo realizar processamento de dados e comunicação com os demais módulos da implementação de referência do *middleware* Ginga. É responsabilidade dessa camada, coletar e armazenar as informações de comportamento de visualização do telespectador em uma base de dados, realizar mineração de dados com essas informações e extrair padrões de comportamento, bem como realizar a manutenção na base de dados, tais como: excluir informações de comportamento de visualização depreciadas, realizar limpeza de arquivos temporários criados a partir dos algoritmos de mineração, entre outros. Essa camada comunica-se diretamente com módulos da implementação de referência do *middleware* Ginga e, por esse motivo, permanece invisível às aplicações de sistema de recomendação.

A camada *Recommender API* é visível aos aplicativos de recomendação, sendo responsável em prover um conjunto de APIs que possibilitem aos sistemas ofertarem serviços personalizados. No contexto do SBTVD, dois tipos de aplicações interativas são suportadas: as aplicações declarativas representadas pelo NCL e as procedurais implementadas utilizando a linguagem Java e baseadas em Xlets. As aplicações escritas em NCL são capazes de executarem *scripts* LUA (LUA, 2009) e estes, por sua vez comunicarem com a camada *Recommender API* solicitando serviços. As aplicações Xlets escritas em Java podem acessar os serviços ofertados de duas maneiras distintas.

A primeira é através da ponte que permite as aplicações Xlets acessarem aplicativos NCL e estes, por sua vez, acessarem a camada *Recommender API* através de um *script* LUA. A Figura 11 ilustra a arquitetura do *middleware* Ginga dando ênfase na ponte que permite a comunicação da máquina de apresentação (Ginga-NCL) com a máquina de execução (Ginga-J).

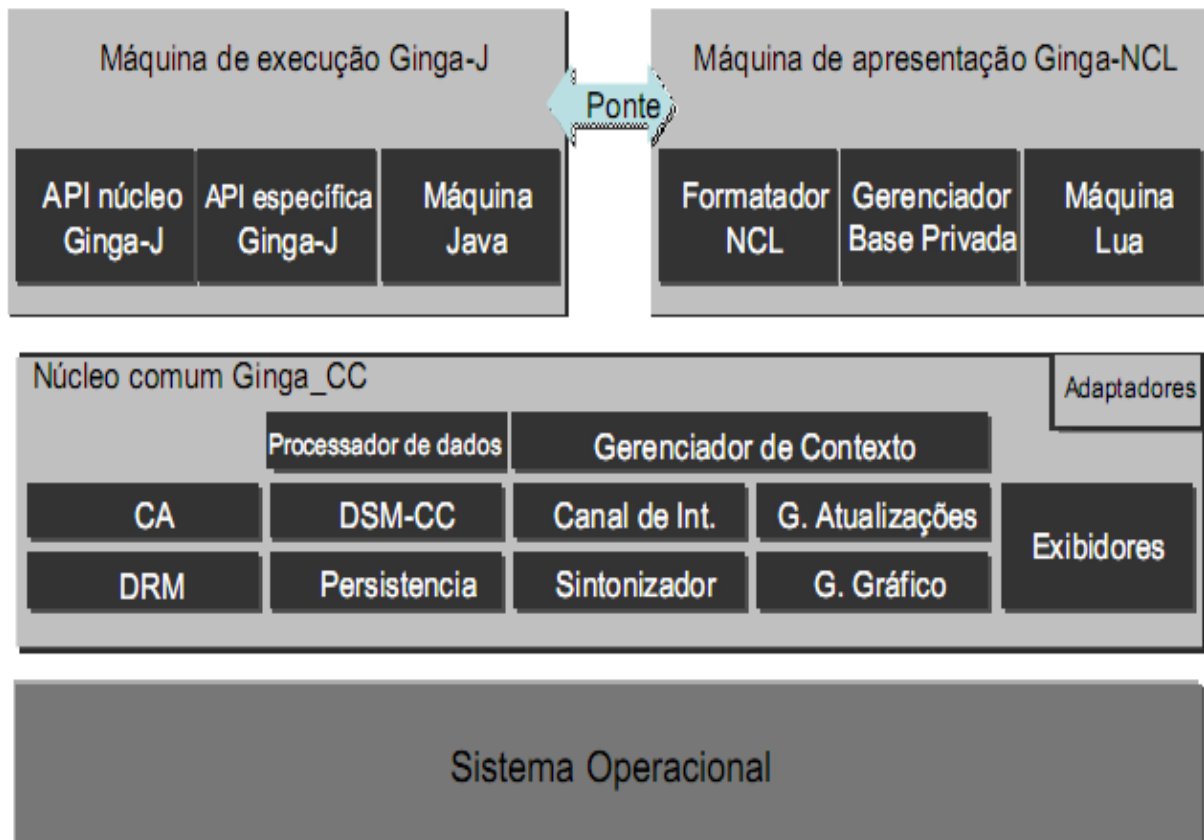


Figura 11 –Middleware Ginga destacando *Bridge* adaptado de (Soares, 2007)

A segunda maneira é acessando os serviços da camada *Recommender API* de forma direta. Aplicações Java podem chamar métodos desenvolvidos em linguagem C++ através da API *Java Native Interface* (JNI).

A Figura 12 destaca a interconexão das camadas do módulo *Recommender TV* e as demais partes do *middleware* Ginga.

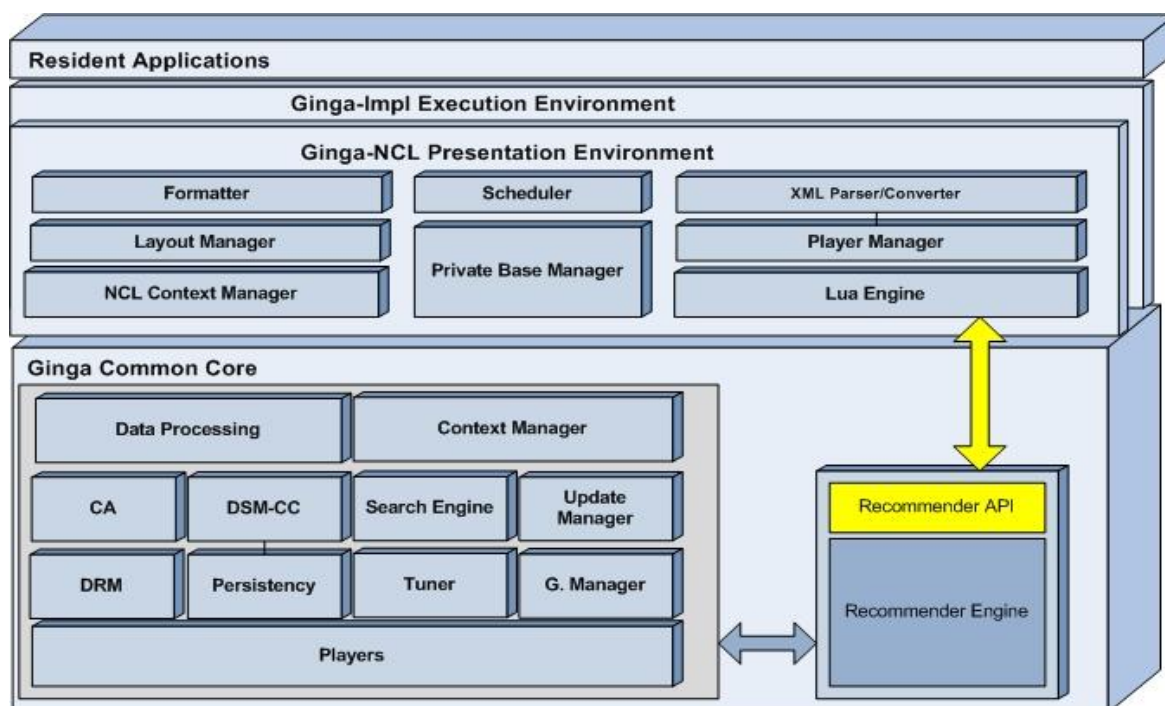


Figura 12–Interconexão das camadas do módulo Recommender TV e o *middleware* Ginga

Para implementação de referência do módulo *Recommender TV*, foi utilizado a implementação de referência do *middleware* Ginga que é distribuído como uma máquina virtual, onde é possível simular um ambiente televisivo, e, inclusive, executar aplicações declarativas desenvolvidas em NCL. O STB Ginga virtual está de acordo com as normas brasileiras de TV digital, sendo usado como referência em pesquisas e desenvolvimento para o ISDB-TB, conforme discutido em Freitas e Teixeira (2009).

A seguir serão abordados detalhes de funcionalidades das camadas *Recommender Engine* e da camada *Recommender API* que compõe o módulo *Recommender TV*.

4.3.1 Camada Recommender API

A camada *Recommender API* é composta por um conjunto de APIs que oferecem serviços aos sistemas de recomendação executando na camada de apresentação da implementação de referência do *middleware* Ginga. Basicamente, os sistemas de recomendação solicitam os serviços fazendo chamadas a métodos escritos em linguagem C/C++. Para chamar os métodos escritos em C/C++ é

necessário o módulo Lua *Engine* que permite a comunicação entre a linguagem Lua e os serviços implementados em C/C++ (LUA,2009).

A Tabela 2 ilustra as funções que compõe a camada *Recommender API*. Dessa forma, as aplicações interativas necessitam conhecer somente esses métodos para fornecer serviços aos usuários.

Tabela 2 - API disponibilizada as aplicações interativas

Métodos públicos disponíveis	Função do método
String getRecommenderBetween(String d1, String d2)	Retorna String com as recomendações especificadas entre duas datas.
String getRecommenderAfter(String hh, String mm, string ss)	Retorna String com todas as recomendações a partir do horário especificado nos parâmetros hh,mm,ss.
String getRecommenderBetweenType (String d1, String d2,String gen)	Retornar String com as recomendações especificadas entre duas a datas e de um determinado gênero. Ex: retornar todas as recomendações do gênero esporte.
String getRecommenderLimitBy(int n)	Retorna uma string com as recomendações a partir da data atual e hora atual limitada por n. Permite as aplicações interativas solicitarem um número variável de recomendações.
String getHistoryAll()	Retornar String com o todas as informações persistidas no histórico de visualização do usuário.
String getHistoryBetWeen(String d1, String d2)	Retorna String com todas as informações persistidas no

	histórico de visualização do usuário que estejam especificadas entre datas d1 e d2.
String getHistoryBefore(string d1)	Retorna String com todas as informações persistidas no histórico de visualização do usuário anteriores a data especificada por d1.
String getHistoryToday()	Retorna String com todas as informações persistidas no histórico de visualização do usuário da data atual.
String getHistoryMonthAgo()	Retorna String com todas as informações persistidas no histórico de visualização do usuário de um mês. anterior.
Float GetCPUClock()	Retorna o clock da CPU do STB.
Double GetMemorySize()	Retorna o tamanho máximo de memória disponível no STB.
String getOperationSystem()	Retorna o sistema operacional utilizado pelo STB
String getLuaVersion()	Retorna a versão da liblua instalada no distribuição de referência do Middleware Ginga.
Double getFreeMem()	Retorna a quantidade de memória disponível no STB.
Double getUsageMem()	Retorna a quantidade de memória utilizada pelo STB.

4.3.2 Camada Recommender Engine

A camada *Recommender Engine* é dividida em cinco partes, denominadas agentes, cada qual com um objetivo bem definido, sendo: *Scheduler Agent*, *Mining Agent*, *Local Agent*, *Filter Agent* e *Data Agent*. A seguir são apresentados detalhes sobre os cinco agentes que compõem a camada *Recommender Engine* e sua interconexão com os demais módulos do *Common Core* do Ginga. A Figura 13 apresenta a camada *Recommender Engine*.

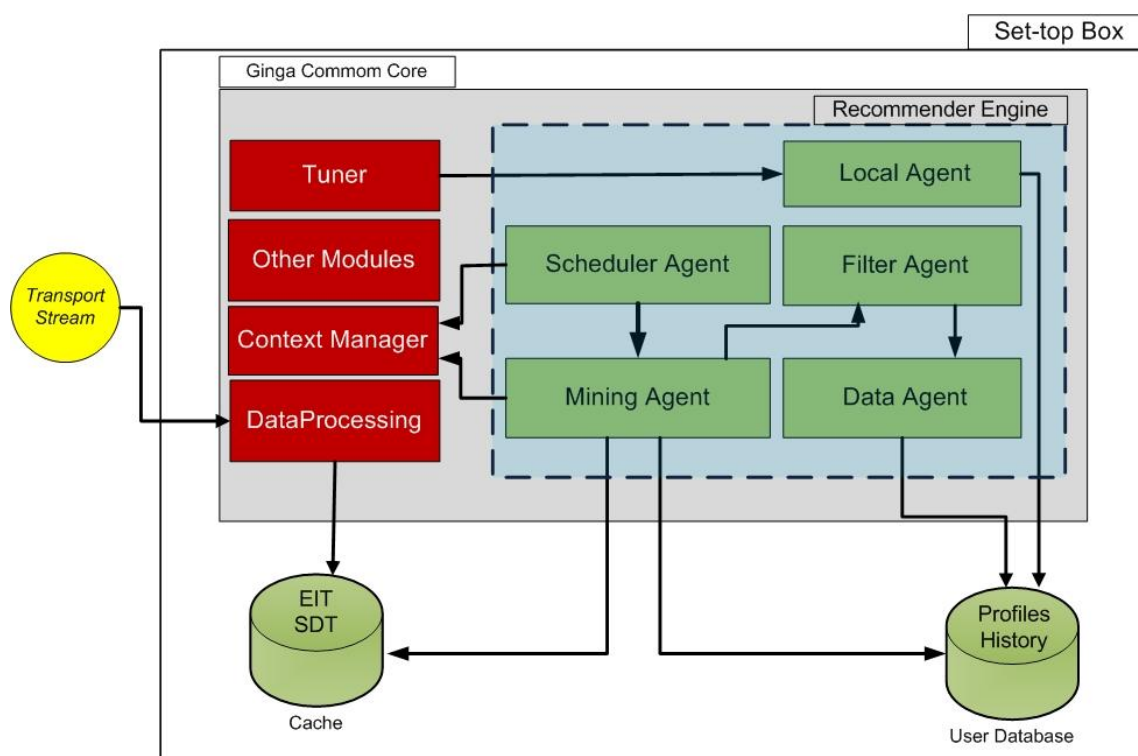


Figura 13–Camada Recommender Engine

Na camada *Recommender Engine*, o *Local Agent* é o responsável por monitorar constantemente os dispositivos de interação, por exemplo, o controle remoto e detectar qualquer interação do telespectador com o STB, persistindo em uma base de dados toda a interação. O *Local Agent* comunica constantemente com o módulo *Tuner* e para realizar essa comunicação foi necessário incluir no módulo *Tuner* um *listener* que notifica o *Local Agent* toda vez que ocorre uma troca de canal. Desta maneira, qualquer ação do telespectador é notificada ao *Local Agent* e persistida na base de dados de comportamento do telespectador.

A Tabela 3 exibe uma amostra das informações capturadas pelo módulo *Local Agent* e persistidas na base de dados.

Tabela 3 – Tabela histórico de comportamento do usuário

<i>Ação</i>	<i>User id</i>	<i>Cód.Interno Gínga</i>	<i>Programa</i>	<i>Gen</i>	<i>Sub</i>	<i>Data</i>	<i>Hora</i>	<i>Dia Sem.</i>	<i>Min</i>
Start	1	KEY_POWER	EU A PATROA E AS CRIANCAS	0x5	0x00	19/03/09	14:05	4	11
Canal +	1	KEY_UP	CINEMA EM CASA	0xC	0x00	19/03/09	14:16	4	15
Canal +	2	KEY_UP	ALDEIA GLOBAL VES	0x6	0X0F	19/03/09	14:32	4	60
End	2	KEY_POWER	ALDEIA GLOBAL VES	0x6	0x6	19/03/09	15:32	4	0
Start	0	KEY_POWER	HORAS NEW NOT	0x0	0x00	19/03/09	19:05	4	31

O *Local Agent* também é responsável em formatar e calcular o tempo em que o usuário permaneceu em determinado serviço. Assim que as informações estejam formatadas e calculadas, o *Local Agent* insere os dados na base *sqlite*.

Em virtude das limitações de memória existentes no STB, é responsabilidade do *Local Agent* gerenciar o tamanho da base de dados e proceder a exclusão de registros antigos toda vez que a quantidade de registros se aproxima do limite máximo do banco de dados. O limite máximo é definido tomando 10% do tamanho de memória total disponível no STB. O módulo *Context Manager* possui informações referentes às capacidades de *hardware* instaladas no STB.

Algumas das dificuldades encontradas para as aplicações que executam no STB são a escassez de recursos computacionais. No módulo *Recommender TV* a tarefa de mineração de dados é a que mais demanda recursos sendo inviável a execução de uma mineração de dados toda vez que o usuário solicitar uma recomendação.

Diante desse cenário, o *Scheduler Agent* é o responsável em disparar o processo de mineração sempre que os recursos necessários (CPU e memória)

estiverem disponíveis. Para inferir quais os melhores horários para realizar a mineração dos dados, é feito uma análise no histórico de comportamento do usuário e desta maneira, descidir em quais horários existe pouca interação com o STB. O *Scheduler Agent* utiliza os três fatores: horário, CPU e memória disponível para solicitar uma operação de mineração de dados. Para obter essas informações o *Scheduler Agent* comunica-se com o *Context Manager* que é responsável em gerenciar recursos do STB e perfis de usuários. O *Context Manager* disponibiliza uma pequena API que permite acessar seus serviços e nesse sentido não foi necessária nenhuma alteração em seu código fonte.

O *Mining Agent* encapsula os algoritmos de mineração necessários para produzir recomendação de programas televisivos e, além disso, é o responsável em escalonar quais algoritmos serão executados de acordo com os recursos de CPU e memória disponíveis no *hardware*. O *Mining Agent* tem acesso ao histórico de comportamento do usuário e também acesso as informações das tabelas SI, incluindo a EIT e a SDT, armazenadas em cache e que juntas transportam informações sobre a programação futura. Com essas informações, os algoritmos de mineração têm dados suficientes para produzir recomendação de programas aos usuários.

O *Filter Agent* recebe uma mensagem assim que o *Mining Agent* executa seus algoritmos. Os dados resultantes do processo de mineração são filtrados. Somente as informações relevantes como: provedor de serviço, horário de início do programa e programas recomendados são considerados.

O *Data Agent* gerencia a inserção das recomendações (nome do provedor, horário de início, duração, programa) na base de dados e posteriormente a exclusão dessas, assim que se tornam obsoletas.

5

EXPERIMENTOS E RESULTADOS

Este capítulo apresenta os experimentos conduzidos com o módulo *Recommender TV* que permitiu a avaliação das precisões obtidas com a aplicação protótipo. A seguir são descritos os dados utilizados no experimento e os resultados obtidos com a avaliação.

5.1 Ambiente de teste e dados do IBOPE⁷

Atualmente no Brasil, a transmissão digital limita-se a uma melhora significativa no áudio e vídeo. Os metadados que compõe as tabelas SI não são distribuídos pelos provedores de serviços, até mesmo porque não temos comercialmente um *middleware* totalmente pronto e disponível que possa tratar essas informações.

Diante dessa situação, a implementação do módulo *Recommender TV* foi testada em ambientes que simulam a TV Digital. Dois ambientes de testes encontram-se disponíveis atualmente. O primeiro é baseado na arquitetura PC com máquinas virtuais simulando a implementação de referência do *middleware* Ginga. O segundo ambiente é mais robusto, composto por um multiplexador profissional que permite a criação de tabelas SI, entre elas: EIT e SDT, um gerador de carrossel de dados, e a capacidade de transmitir áudio e vídeo em formato *High Definition* (HD). A recepção é feita em um STB que realiza a decodificação e demultiplexação em *hardware*. Para os testes da implementação do módulo *Recommender TV*, adotou-se o primeiro ambiente baseado em máquinas virtuais.

Uma vez definido o ambiente de testes, a segunda etapa consistiu em definir os metadados para condução dos experimentos, já que conforme mencionado, atualmente os metadados não são distribuídos nas transmissões digitais. Dois

⁷ <http://www.ibope.com.br>

conjuntos de dados são necessários: o comportamento de visualização do telespectador e os dados referentes a programação das emissoras. Visando submeter a implementação de referência a testes próximos do ambiente real, optou-se em adotar conjunto de dados fornecido pelo IBOPE e que correspondem a informações reais coletadas minuto a minuto durante quatro semanas em oito domicílios de diferentes regiões e com perfil socioeconômicos variados. Em relação a programação das emissoras, foram fornecidos dados referentes a dez canais abertos. A seguir é apresentado com detalhes esse conjunto de dados.

O primeiro conjunto de dados descreve as informações das emissoras, grade de programação, sinopse dos programas, entre outros. No ambiente real de TVDI, as informações referentes a emissoras, grade de programação, sinopse, etc., são encapsuladas nas tabelas EIT e SDT e, posteriormente, transmitidas pelos provedores de serviço através do componente carrossel de dados. No ambiente simulado, foi necessário implementar um gerador de tabelas EIT e SDT (Apêndice A) em *software* que permitiu encapsular os dados fornecidos pelo IBOPE. A Figura 14 ilustra uma amostra dos dados disponibilizados pelo IBOPE e que foram utilizados nos experimentos realizados.

codigoEmissora	codigoPrograma	nomePrograma	inicioPrograma	fimPrograma	genero	classsubgen	
001	002645	RELIGIOSO MAT	06:00:00	08:00:00	0xF	0x03	
001	005019	PRIMEIRO JORNAL EDUCAD BRASIL	08:01:00	09:00:00	0x0	0x00	
001	006955	BOL MEDALHINHO MAT	09:01:00	09:02:00	0x0	0x0F	
001	004934	BEM FAMILIA	09:03:00	11:26:00	0x8	0x00	
001	007046	QUE FIM LEVOU	11:27:00	11:28:00	0xF	0x0F	
001	001504	JOGO ABERTO MAT	11:29:00	12:29:00	0xE	0x00	
001	006329	JOGO ABERTO LOCAL	12:30:00	13:01:00	0xE	0x00	
001	005953	SÃO PAULO ACONTECE	13:02:00	13:32:00	0x0	0x00	

Figura 14 – Dados do IBOPE sobre a programação dos provedores de serviço

O segundo conjunto de dados é constituído pelo histórico de comportamento do telespectador monitorado minuto a minuto. Toda interação do usuário com a TV é monitorada pelo IBOPE que persiste essas informações para gerar estatísticas sobre os programas. A Figura 15 ilustra uma amostra dos dados monitorados pelo IBOPE, já processados e armazenados em um banco de dados relacional.

MySQL Query Browser - Connection: root@localhost:3306

Arquivo Editar View Query Script Ferramentas Janela Ajuda

Go back Next Refresh

SELECT * FROM ibope.new_domico n where domicilio='1';

Resultset 1

domicilio	data	emissora
1	2008-03-06 17:53:00	004
1	2008-03-06 17:54:00	004
1	2008-03-06 17:55:00	004
1	2008-03-06 17:56:00	004
1	2008-03-06 17:57:00	004
1	2008-03-06 17:58:00	004
1	2008-03-06 17:59:00	004
1	2008-03-06 18:00:00	004
1	2008-03-06 18:01:00	004
1	2008-03-06 18:02:00	004
1	2008-03-06 18:03:00	004
1	2008-03-06 18:04:00	004
1	2008-03-06 18:05:00	004
1	2008-03-06 18:06:00	004
1	2008-03-06 18:07:00	006
1	2008-03-06 18:08:00	006
1	2008-03-06 18:09:00	006
1	2008-03-06 18:10:00	006

Figura 15 – Dados do IBOPE minuto a minuto do domicilio

Definido o conjunto de dados, a próxima etapa foi implementar um ambiente que simulasse, da forma mais realista possível, o ambiente de TVDI. A seguir é apresentada a estrutura que permitiu realizar os experimentos e avaliar a eficiência do módulo *Recommender TV*.

A implementação de referência do *middleware* Ginga oferece suporte a recepção dos fluxos de transporte via protocolo *User Datagram Protocol* (UDP). Para fins de experiência e validação do sistema de recomendação, o gerador de carrossel transmitiu os dados utilizando esta abordagem.

Para simularmos os provedores de serviço foram utilizados dados reais de emissoras abertas e, em seguida, gerado a tabela EIT e SDT para cada emissora, considerando uma programação futura de três dias. As tabelas EIT, SDT e o arquivo de vídeo no formato *transport stream* foram multiplexados e transmitidos ao STB através de um gerador de carrossel de dados implementado em *software*. Para cada emissora simulada foi disponibilizado um gerador de carrossel de dados, criando dessa forma, um ambiente bem próximo ao real onde cada provedor de serviço é responsável pela geração de seu fluxo de transporte. A Figura 16 apresenta este ambiente de simulação composto por três computadores PC que, utilizando virtualização, simularam as emissoras abertas.




Figura 16 – Ambiente de teste do Recommender TV (ÁVILA; ZORZO, 2009a)

No lado do telespectador, o STB foi simulado por um computador *MiniPC* executando a implementação de referência do *middleware* Ginga com o módulo *Recommender TV* implementado.

Na implementação de referência do *middleware* Ginga foi configurado onde localizar cada provedor de serviço, atribuindo um endereço *Internet Protocol* (IP) a cada um dos provedores que compõem o ambiente de simulação.

Nesse ambiente, o telespectador tem a opção de navegar entre os provedores de serviços acionando a tecla “troca canal”, no controle remoto, que notifica ao *middleware* para receber o fluxo de transporte proveniente do próximo/anterior gerador de carrossel de dados.

5.2 Resultados

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

$$\delta = \frac{\beta}{\alpha} 100 \quad (1)$$

Onde δ corresponde à eficiência do sistema e varia de 0 a 100%, β é o número de recomendações visualizadas pelos telespectadores e α é o número de recomendações efetuadas. Quanto maior o resultado de δ , mais alta a precisão que o sistema de recomendação possui em ofertar conteúdo de acordo com as preferências do grupo de telespectadores.

Conforme já comentado, a implementação de referência do módulo *Recommender TV* adota regras de associação e o uso do algoritmo Apriori para realização da tarefa de mineração de dados. Nesses experimentos foi utilizado o perfil de grupo. A avaliação adotou a fórmula de precisão apresentada em (1).




Gráfico 1 - Precisão obtida após quatro semanas de uso do Recommender TV

O gráfico 1 apresenta os resultados obtidos após quatro semanas de monitoramento, considerando a média obtida entre os oitos domicílios investigados. Fica evidente que nas primeiras semanas, como são poucos os dados coletados, o algoritmo Apriori não extraiu informações relevantes das preferências do grupo. Com o aumento dos dados no histórico de visualização na terceira e quarta semana, o algoritmo obteve melhores resultados e o índice de aceitação das recomendações aumentou. Nesse mesmo período, observa-se uma tendência de

estabilização, reflexo da quantidade suficiente de dados coletados para o algoritmo recomendar.

O Gráfico 2 apresenta a precisão por domicílio ao final de quatro de semanas. A principal característica dos domicílios é a diferença socioeconômica existente entre eles. Independente disso, o algoritmo obteve um bom desempenho, nos oito domicílios testados. (ÁVILA; ZORZO, 2009c).




Gráfico 2 - Precisão obtida por domicílio após 4 semanas

O comportamento de acertos e erros do algoritmo Apriori das duas primeiras semanas pode ser observado no gráfico 3. É importante salientar que na primeira semana a precisão das recomendações é muito semelhante a um sistema de recomendação aleatório. Em Ávila e Zorzo (2009b) é apresentado um estudo com um sistema de recomendação aleatório que obtém valores de precisão na ordem de 0,20%.




Gráfico 3- Precisão dos domicílios durante as duas primeiras semanas

Isso se justifica, pois com poucos dados disponíveis, são produzidas poucas regras de associação, sendo necessário utilizar inclusive, um fator de confiança baixo, para que essas poucas regras sejam produzidas. A partir da segunda semana de monitoramento, percebe-se um aumento na precisão das recomendações. Nesse ponto, a base de dados com o histórico de visualização do usuário está mais completa e um número maior de regras podem ser geradas pelo algoritmo, refletindo em recomendações mais precisas.

A partir da terceira semana é possível observar uma estabilização no índice de precisão. Observa-se que o algoritmo Apriori já possui dados suficientes para gerar várias regras e diante desse fato é possível aumentar o fator de confiança, selecionando as regras mais pertinentes ao perfil do grupo de usuários.

O Gráfico 4 apresenta a precisão das recomendações por domicílio, evidenciando a estabilização no índice de precisão das recomendações.




Gráfico 4- Precisão dos domicílios terceira e quarta semanas

Os resultados demonstrados permitiu verificar que é possível oferecer conteúdo personalizado a grupo de telespectadores. A precisão do algoritmo de mineração adotado na implementação de referência foi de 65% após quatro semanas de uso, observando-se um desvio padrão de 3%. É importante salientar que os dados utilizados foram do IBOPE e não da utilização em tempo real pelo telespectador. A utilização do sistema em tempo real pelos telespectadores pode alterar os resultados, já que os mesmos ficam condicionados a aceitar alguma das sugestões ofertadas.

Diversos trabalhos apresentam valores próximos aos obtidos nesse experimento. Em Vildjiounaite *et al.* (2008) é apresentado um estudo com perfil de grupo obtendo um índice de precisão de 60%. Lucas e Zorzo (2009) apresentam um sistema de recomendação que utiliza regras de associação e o algoritmo Apriori baseado na implementação *Waikato Environment for Knowledge Analysis* (Weka). Nesse estudo são relatados índices de precisão de 59%. Hsu *et al.* (2007) apresenta o sistema AIMED que obtém índices de 72% segundo os autores. Entretanto, deve-se considerar que o sistema AIMED foi testado totalmente num

ambiente computacional livre das limitações impostas pelo *hardware* do ambiente televisivo.

Observando os resultados reportados nos trabalhos supracitados, conclui-se que a implementação de referência do módulo *Recommender TV* obteve resultados compatíveis com os valores apresentados na literatura. É importante salientar que outras implementações do módulo *Recommender TV* podem ser sugeridas com diferentes algoritmos, obtendo resultados diversificados.

5.3 Aplicação Protótipo

Para validar o módulo *Recommender TV* foi implementado um sistema de recomendação em NCL/LUA. A plataforma para teste e execução da aplicação foi a implementação de referência do *middleware* Ginga.

Para que fosse possível executar a aplicação NCL/LUA foi necessário incluir o código do módulo *Recommender TV* na distribuição da implementação de referência do *middleware* Ginga, em outras palavras, foi necessário recompilar o código do Ginga inserindo o código do módulo *Recommender TV*. O módulo *Recommender TV* assim como o Ginga foi desenvolvido em linguagem C/C++, sendo composto por diversas classes que fornecem serviços as aplicações interativas. A documentação completa do módulo *Recommender TV* pode ser encontrada no endereço: <http://tvdilab.inf.pucpcaldas.br/repositorioopenginga/recommenderTV.pdf>.

Para que seja possível disponibilizar serviços personalizados aos telespectadores através da aplicação protótipo aqui apresentada, um processo complexo envolvendo diversas etapas deve ser executado. A Figura 17 ilustra as diversas etapas desse processo.




Figura 17– Etapas do processo de recomendação no ambiente de TVDI

Para enfatizar os diversos elementos envolvidos no processo de personalização ao telespectador, o seguinte cenário é proposto como estudo de caso.

O provedor de serviços Rede Globo disponibiliza a tabela SDT com o serviço Jornal Nacional e a tabela EIT associada a esse serviço com os dados: início as 20h00min e duração de 30 minutos. Diversas outras tabelas que compõe a SI são disponibilizadas, mas, para o contexto desse trabalho, a tabela EIT e a SDT são as relevantes.

O provedor de serviço Rede Globo faz uso dos descritores que compõe a tabela EIT para associar outras informações ao serviço Jornal Nacional da seguinte forma: descritor de conteúdo que informa que o programa é “Jornalismo” com subgênero “Telejornal”, descritor de controle de cópia digital informando que o conteúdo apresentado é protegido contra cópia, descritor de classificação indicativa definindo a faixa etária do programa e um descritor de eventos curtos com uma breve sinopse.

Após esse processo que constitui a preparação dos metadados pelo provedor de serviço (etapa 1)⁸, os mesmos são codificados produzindo o fluxo elementar (etapa 2). Em seguida, os metadados em conjunto com o fluxo elementar de áudio e o fluxo elementar de vídeo são multiplexados gerando o fluxo de transporte (etapa 3), modulados (etapa 4) e distribuídos aos meios de difusão (etapa 5).

Ao ser recebido no STB (etapa 6), áudio e vídeo são encaminhados respectivamente para a placa de áudio e vídeo, as tabelas SI, incluindo a SDT e EIT são reconstruídas e as informações com o nome do serviço, hora de início, duração, classificação etária, gênero/subgênero e sinopse tornam-se disponíveis e podem ser acessados através das APIs definidas em (SUN DTV, 2008).

O usuário interage com o STB e essas informações são coletadas e processadas pelo módulo *Recommender TV* (etapa 7). Um sistema de recomendação que faz uso das APIs disponibilizadas pelo módulo *Recommender TV* oferece recomendações ao telespectador, sempre que ele solicita esse serviço. Esse sistema de recomendação pode estar residente no STB ou transmitido como uma aplicação interativa (etapa 8).

A etapa 8 desse processo é onde ocorre a interação do telespectador com a aplicação de personalização. A Figura 18 apresenta a interface gráfica da ferramenta protótipo desenvolvida como prova de conceito do módulo *Recommender TV*.

⁸ Ver figura 17.

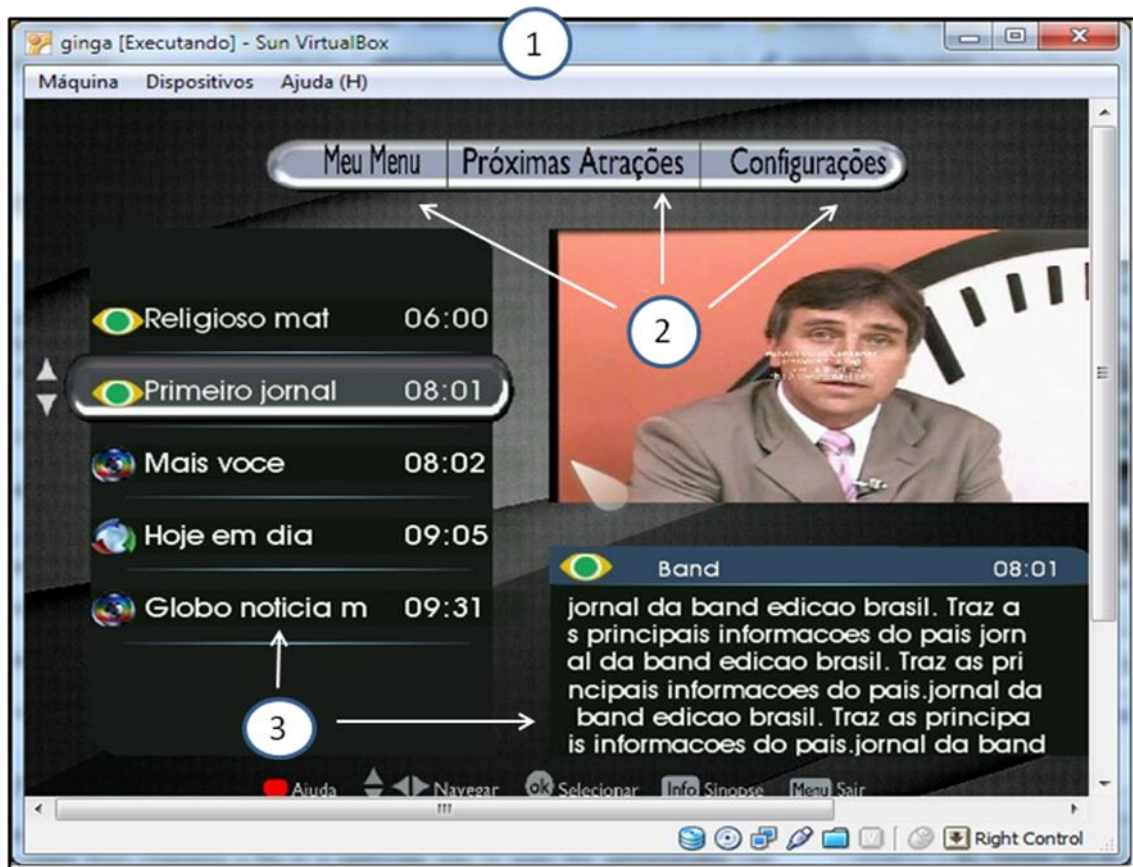


Figura 18– Aplicação protótipo executando no *middleware* Ginga

Conforme se observa na Figura 18 (etapa 1), a aplicação protótipo executa em uma implementação de referência do *middleware* Ginga em uma máquina virtual. A etapa 2 apresenta os componentes em NCL que permitem a exibição do vídeo e também dos menus. A etapa 3 apresenta as recomendações ao usuário acompanhada de uma breve sinopse sobre o programa. É nessa etapa que ocorre a comunicação do módulo *Lua Engine* com o módulo *Recommender TV*. Assim que o usuário solicita a recomendação através do controle remoto, o aplicativo protótipo é executado e o código em lua comunica-se com o módulo *Recommender TV* solicitando as recomendações a partir do horário atual.

Uma vasta quantidade de trabalhos exploraram personalização e sistemas de recomendação, seja no domínio da TVDI ou outras áreas de pesquisas. Neste capítulo são apresentados sistemas que possuem alguma intersecção com este trabalho.

6.1 AIMED – A personalized TV Recommendation System

O trabalho de HSU *et al.* (2007) - AIMED é um sistema de recomendação personalizado que não foca apenas as informações coletadas e armazenadas nos históricos do usuário. Neste sistema, é proposto um novo modelo, onde as recomendações levam em consideração aspectos como: atividades, interesses, humor, experiências e informações demográficas (AIMED – *Activities, Interests, Mood, Experiences, Demographic information*).

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 usuários quando estes pedem recomendações.

AIMED é um sistema de recomendação híbrido baseado nos métodos de filtragem de conteúdo e filtragem colaborativa.

A filtragem de conteúdo analisa o comportamento de visualização do telespectador, coletando dados dos programas como: autor, categoria e tempo de visualização de cada programa. Com base nesses dados ele constrói um perfil de usuário. Depois de construir o perfil de usuário, o sistema compara as informações dos programas (transmitidos pelos provedores de serviços) com o histórico de visualização do usuário procurando as similaridades entre esses componentes e recomendando os programas que mais se adequem ao perfil do usuário coletado anteriormente.

Na abordagem de filtragem colaborativa, são coletados dados de diversos telespectadores e o sistema recomenda os programas baseado nas classificações

de pessoas com perfis semelhantes. Este sistema forma uma comunidade virtual onde membros com perfis semelhantes compartilham informações com outros membros ou com programas de recomendação de outros telespectadores.

A arquitetura do sistema AIMED é composta pelos módulos: perfil do usuário e estereótipo do usuário, comunidade de telespectadores, metadados de programas e contexto de visualização.

O módulo perfil do usuário e estereótipo do usuário coleta informações básicas sobre o usuário. Para isso, é necessário que o usuário preencha um questionário. Esse questionário corresponde a dados demográficos, estilo de vida, interesses, atividades e preferências de categorias de programas. Estas informações são armazenadas no STB e o perfil do usuário é enviado para o sistema de recomendação sempre que ele solicita recomendações.

O módulo comunidade de telespectadores foi desenvolvido para prevenir a super-especialização, está ocorre quando o sistema de recomendação utiliza a abordagem filtragem de conteúdo que se baseia no histórico de visualização do telespectador e nas informações dos programas (fornecidas pelos provedores de serviços), buscando similaridade neste conjunto de dados. Essa busca de similaridade baseada no histórico de visualização dificulta a oferta de outras categorias de programas, além daquelas já presentes no perfil do usuário, tornando o sistema de recomendação até certo ponto “viciado”. As recomendações utilizando filtragem colaborativa emergem como um atenuante à super-especialização dos sistemas que adotam abordagem de filtragem de conteúdo. A principal característica dessa abordagem é a comparação entre um usuário individual e uma comunidade de telespectadores de acordo com semelhanças de perfil entre esses indivíduos e a posterior troca de informações entre indivíduos e comunidade.

O módulo metadados de programas implementa uma rede neural para inferir um conjunto de recomendações baseado no mapeamento entre dados de grupos de telespectadores e metadados de programas. Esses metadados incluem informações como: nome do programa, gênero do programa e idioma.

O módulo contexto de visualização é responsável por coletar e persistir o comportamento de visualização do usuário e efetuar um mapeamento com

diferentes tipos de humor. O sistema AIMED utiliza informações de humor que são informadas pelo usuário através de botões do controle devidamente mapeados. Estudos mostraram que o humor do telespectador afeta diretamente suas escolhas, sendo, portanto um bom previsor para recomendações.

AIMED é um sistema de recomendação de programa híbrido, utilizando abordagem de filtragem colaborativa e filtragem de conteúdo. Os resultados reportados indicaram que o sistema AIMED aumentou a precisão da recomendação e diminuiu os erros de predição em relação aos sistemas de recomendação tradicionais.

6.2 A Personalized TV Guide System Compliant with MHP

No artigo de ZHANG *et al.* (2005) é proposto um sistema de TV personalizado embarcado no STB compatível com o modelo MHP do padrão europeu de televisão digital. De acordo com os autores, o sistema foi implementado em uma solução comercial do *middleware* MHP e, para isto, foi necessário realizar alterações e inclusões de novos módulos neste *middleware*.

Neste sistema, para que seja possível oferecer recomendações, duas importantes informações devem estar disponíveis: descrição dos programas e o comportamento de visualização do telespectador.

As descrições dos programas são obtidas demultiplexando e decodificando as informações contidas na tabela EIT, esta é a tabela utilizada para transporte de informações específicas de programas, tais como: hora de início, duração e descrição dos programas.

A arquitetura *Personalized TV Guide System* é composta por duas camadas: A camada de aplicações Java ou camada de apresentação, e o núcleo do sistema.

A camada de aplicações é responsável em apresentar aplicações Java Xlets em conformidade com o MHP, já o núcleo do sistema (*core system*) foi desenvolvido em linguagem C++ como um módulo que tem como principal objetivo estender as

funcionalidades do *middleware* MHP, sendo dividido em três camadas: *SI Engine*, *Profile Acquire Engine* and *Recommending Engine*.

A camada *SI Engine* é responsável por filtrar as informações recebidas do fluxo de transporte e armazenar essas informações em memória não volátil. Segundo os autores é impraticável tentar recuperar informações em tempo real do fluxo de transporte, pois a latência envolvida nesta operação torna o sistema de recomendação inviável. Desta forma, um cache local com as informações fornecidas pela tabela EIT é absolutamente necessário. Depois que os dados que irão compor o EPG são recebidos e armazenados localmente no STB, o telespectador pode navegar, procurar e até solicitar recomendação de forma segura e rápida, pois as informações estão sempre disponíveis. A camada *SI Engine* também é responsável em atualizar os dados em cache sempre que uma atualização ou mudança da programação é disponibilizada pelo provedor de serviço.

A camada *Profile Acquisition Engine* monitora o comportamento de visualização do telespectador permitindo a construção do seu perfil. Esse módulo é responsável em receber as ações do telespectador com os dispositivos de entrada (tradicionalmente controle remoto) e persistir esse histórico de ações em memória não volátil. Para obter o grau de interesse do usuário em determinado programa, o *Profile Acquisition Engine* monitora o tempo total que o telespectador assiste a um determinado programa. Qualquer valor abaixo de 20% é considerado negativo, significando uma rejeição do programa por parte do usuário. Tal rejeição deve ser persistida na base de dados que gerencia os perfis de usuários. A mesma operação ocorre quando o tempo em que o telespectador permaneceu assistindo ao programa ultrapassa os 50%. Neste caso, um *feedback* positivo é produzido.

A terceira camada que compõe o núcleo do sistema é o *Recommending Engine* que adota a abordagem de filtragem baseada em conteúdo. Esta abordagem consiste em categorizar as informações e relacioná-las com os interesses dos usuários, também é chamada de correlação item-a-item e, frequentemente, encontram-se itens similares aos de interesse do telespectador para sugestão. Comparando as informações de programas recebidas através do fluxo de transporte com as informações de perfil do telespectador, o *Recommending Engine* classifica e faz sugestões de programas. A classificação é realizada através de um algoritmo

que considera gênero, canal, classificação do programa (livre, 10 anos, 16 anos) em conjunto com as informações obtidas implicitamente pela análise de histórico de visualização do telespectador.

Segundo os autores o sistema apresenta bom desempenho sendo capaz de realizar recomendações com um alto grau de eficiência.

Existem várias semelhanças entre o sistema proposto por ZHANG *et al.* (2005) e o módulo *Recommender TV*. A mais relevante é a extensão proposta e implementada no *middleware* para suporte ao sistema de recomendação. A coleta e a persistência dos dados do telespectador são motivadores fortes para extensão, já que o próprio *middleware* não fornece esses mecanismos.

6.3 TV program recommendation for multiple viewers based on user profile merging

Zhiwen *et al.* (2006) propõe a junção do perfil de múltiplos telespectadores constituindo uma única base de perfil no ambiente televisivo. O sistema TV4M considera que o ambiente televisivo é formado por grupo de telespectadores e adotou a estratégia de junção do perfil da seguinte forma: Aglomeram-se todos os perfis dos telespectadores para construir um perfil comum, ou seja, uma única base de perfil. Em seguida, são produzidas recomendações comuns a todos os indivíduos do grupo. 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. Um problema relatado é a falta de adaptabilidade e flexibilidade da estratégia, pois, é necessário que todo o grupo assista TV junto para que o sistema descubra as preferências de todos os telespectadores que compõe o 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. Diferente do módulo *Recommender TV*, o sistema TV4M foi testado em um computador sem as características inerentes da TVDI. O

uso de *login* nesse ambiente, com teclado, mouse e todas as facilidades fornecidas pelas interfaces do computador não representam de forma alguma as dificuldades encontradas pelos telespectadores no ambiente televisivo, onde a entrada de dados é feita através do controle remoto da TV. Mesmo com as facilidades oferecidas pelo computador, o autor relata que, em geral, os usuários rejeitam o login principalmente quando ocorre a troca constante de usuário no sistema. No ambiente televisivo real isso seria equivalente ao usuário ter que realizar *login* cada vez que tivesse acesso ao controle remoto.

O módulo *Recommender TV* de maneira semelhante ao sistema TV4M permite a união de perfis dos telespectadores e também a estratégia de identificação única do telespectador através do acesso às funções fornecidas pelo módulo *Context Manager* que faz parte do *Ginga Common Core*. Entretanto, para identificação única do telespectador é necessária sua explícita identificação, de maneira análoga ao *login* discutido acima. A implementação de referência do *middleware* Ginga fornece mecanismos que permitem a persistência e a posterior recuperação de perfis de telespectadores.

6.4 Personalization: Improving Ease-of-Use, Trust and Accuracy of a TV Show Recommender

Em Buczak *et al.* (2002) apresenta-se a possibilidade dos telespectadores que utilizam o EPG escolher uma programação que será gravada em formato digital no disco rígido. Isso é possível, pois a tecnologia de TVDI possibilita a utilização de *Personal Digital Recorders* (PDR), que permitem que programas sejam gravados, mudando drasticamente a forma como as pessoas assistem TV. Da mesma forma que o telespectador pode solicitar recomendações de programas, é possível agora, ao telespectador solicitar uma recomendação de programa que serão gravados. Para isso o sistema proposto por Buczak *et al.* (2002) faz uso do conhecimento das preferências do telespectador.

Os autores observaram durante os testes realizados que alguns

telespectadores necessitam de mais atenção que outros. Nesse sentido, foram definidos três tipos de usuários: os usuários passivos, que deixam o controle por conta do sistema de recomendação, os usuários que exigem algum controle, mas não desejam ficar alterando muitos parâmetros, e, por fim, os usuários que desejam controle completo do sistema de recomendação, por exemplo, inserindo de forma explícita suas preferências, configurando a quantidade de recomendações que serão ofertadas, entre outros.

Uma inovação no sistema de Buczak *et al.* (2002) é o método denominado de histórico de visualização refletivo. Os autores perceberam que quando se recomenda um programa que sempre é assistido, os usuários acreditam que o sistema está realizando um bom trabalho. O mesmo não acontece quando uma nova recomendação é apresentada de um programa nunca assistido, por exemplo, um novo programa vinculado na grade do provedor de serviço. Nesse sentido, o histórico de visualização refletivo detecta novos programas na grade do provedor de serviço, explicando ao telespectador que a recomendação ofertada trata-se de um novo programa.

Para melhorar a precisão das recomendações, os autores combinaram vários algoritmos e também utilizaram uma rede neural capaz de detectar correlações a fim de obter a recomendação final. Entretanto, no cenário de TVDI, fica claro que devido as limitações impostas pelo STB, o uso de vários algoritmos é ineficiente.

O sistema proposto por Buczak *et al.* (2002) apresenta alguns pontos semelhantes com o módulo *Recommender TV* apresentado nessa dissertação. A possibilidade de um EPG que permita diferentes níveis de configuração é o mais relevante. O módulo *Recommender TV* permite ao desenvolvedor da aplicação EPG implementar um sistema de recomendação totalmente automatizado, onde a interação do usuário limita-se a receber as recomendações, ou o oposto, onde o usuário pode interagir definindo uma série de parâmetros que alteram as recomendações. Por exemplo, definindo o número de recomendação, solicitando todas as recomendações somente do gênero "esporte", entre outras configurações possíveis.

6.5 Unobtrusive Dynamic Modelling of TV Program Preferences

Em Vildjiounaite *et al.* (2008) é apresentado um método que permite coletar dados de pessoas e suas ações em um ambiente multiusuário a partir de interações implícitas armazenadas em um log. Os *logs* são coletados e armazenados a partir das interações dos usuários nas chamadas casas inteligentes. Nesse sentido, os logs podem ser utilizados por um sistema de recomendação para adaptar o conteúdo a um determinado usuário ou grupo de usuários. Foi desenvolvido um sistema de recomendação de programas televisivos que utiliza os dados de cada casa individualmente e produz recomendações baseadas nos históricos coletados e armazenados nos logs. Uma desvantagem do sistema é a necessidade dos telespectadores terem de se identificar pelo controle remoto informando ao sistema 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. Essa observação é relevante, pois num ambiente televisivo a dificuldade de se inserir informações via controle remoto devem ser consideradas.

O sistema de recomendação desenvolvido por Vildjiounaite *et al.* (2008) requer a interação explícita por parte dos telespectadores, ou seja, a identificação pelo controle remoto. Diferentemente desse sistema, o trabalho apresentado nessa dissertação visou oferecer métodos que permitam aos sistemas de recomendação que utilizem o módulo *Recommender TV* coletar e armazenar dados de forma implícita, sem a necessidade de identificação do telespectador pelo controle remoto. Outra diferença importante é que o sistema de Vildjiounaite *et al.* (2008) é executado e testado em um computador, não considerando nenhuma característica da TVDI, como por exemplo, as diversas limitações de *hardware* do STB. Já o módulo *Recommender TV* foi desenvolvido em C/C++ e acoplado a implementação de referência do *middleware* Ginga, prevendo e tratando todas as limitações encontradas no ambiente de TVDI.

O sistema de Vildjiounaite *et al.* (2008) assemelha-se ao módulo *Recommender TV* ao predizer os interesses de determinado grupo baseado em

dados coletados (*logs* da casa inteligente) e prover de forma transparente aos telespectadores as recomendações televisivas.

6.6 FIT-recommending TV programs to family member

Em Goren-Bar e Glinasky (2004) é apresentado o sistema de recomendação FIT. A principal característica desse sistema é efetuar recomendações de programas para membros de uma família por modelos baseados em histórico de visualização. Nesse sentido, esse sistema baseia-se no tempo de visualização e na informação das categorias dos programas para efetuar recomendações. Para avaliação do sistema FIT foram coletados dados de nove famílias, as quais foram divididas em dois grupos. O primeiro grupo recebeu recomendações de forma aleatória, o segundo grupo recebeu recomendações do sistema FIT. O objetivo era avaliar a aceitação dos telespectadores em relação as recomendações aleatórias e o resultado mostrou que recomendações ofertadas pelo sistema FIT tiveram uma aceitação muito superior.

O módulo *Recommender TV*, assim como o sistema FIT, apresenta o modelo baseado em histórico de visualização. O *Recommender TV* através de seus mecanismos internos permite a coleta e persistência do histórico de visualização do telespectador que em conjunto com as informações fornecidas pelos provedores de serviços através das tabelas EIT e SDT são utilizadas para oferecer recomendações ao grupo de telespectadores.

Para processar as informações coletadas dos telespectadores, o sistema FIT faz uso do canal de retorno. Essas informações são coletadas no STB (lado cliente) e enviadas para um servidor (canal de retorno), diferenciando-se do módulo *Recommender TV* que é um sistema local e não faz uso do canal de retorno.

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

Em Lucas e Zorzo (2009) é apresentado o sistema de recomendação RePTVD. Para que o sistema RePTVD possa fazer recomendações são necessárias técnicas e estratégias para coleta e manipulação de informações, além da apresentação das sugestões aos telespectadores. Nesse cenário, o RePTVD coleta as informações de forma implícita mediante o monitoramento do comportamento de visualização dos telespectadores. O RePTVD armazena os dados coletados em um arquivo ARFF (*Attribute Relation File Format*), que é um formato próprio do pacote *Weka* e este pacote contém os algoritmos de mineração de dados. Para recomendar programas, além do histórico de visualização, o RePTVD utiliza metadados disponibilizados pelos provedores de serviços através das tabelas EIT e SDT, responsáveis em transportar informações dos programas televisivos. Segundo Lucas e Zorzo (2009), dentre os algoritmos testados observou-se que as regras de associação resultaram no melhor comportamento por serem aplicáveis a dados que não tenham uma classe determinada para efetuar a mineração, como a categoria e o tempo de visualização do programa. Deste modo, as regras de associação adaptaram exatamente as necessidades do sistema. Para testar o sistema RePTVD foi extraído dados de uma amostra de treze telespectadores subdivididos em quatro grupos: o primeiro, segundo e terceiro grupos possuíam três pessoas cada, e o quarto, quatro. O comportamento de visualização foi coletado conforme a grade de programação real da TV aberta e o tempo de visualização de cada telespectador variaram de acordo com a sua rotina. Durante quatro semanas, o histórico de visualização dos grupos foi submetido ao sistema de recomendação. Os dados referentes ao comportamento de visualização são informações reais, fornecidas pelo IBOPE. Após quatro semanas de histórico de visualização da TV coletado, o sistema obteve uma precisão entre 56% a 60%.

Segundo Lucas e Zorzo (2009), o sistema RePTVD foi implementado utilizando a linguagem de programação Java, mais especificamente a API JavaTV. A maioria

dos sistemas de TVDI utiliza a especificação JavaTV, pois permite o desenvolvimento de aplicações Xlets e fornece facilidade para o desenvolvimento de aplicações para TVDI.

O módulo *Recommender TV* assim como o RePTVD coleta o histórico de visualização do telespectador e persiste essas informações. Para recomendar programas, o módulo *Recommender TV* utiliza os metadados fornecidos pelos provedores de serviços, de maneira análoga ao RePTVD. Diferentemente, do RePTVD que persiste os históricos num arquivo ARFF e utiliza o algoritmos de mineração ofertados pelo pacote *Weka*, o módulo *Recommender TV* persiste o histórico de visualização um banco de dados relacional (*Sqlite*) acoplado a implementação de referência do *middleware* Ginga e implementa seus próprios algoritmos de mineração. A persistência em um banco de dados relacional torna a recuperação das informações rápidas e práticas e a implementação de seus próprios algoritmos de mineração evitam a necessidade de se instalar o pacote *Weka* para oferecer recursos de mineração de dados.

O sistema RePTVD é implementado em Java fazendo uso da API JavaTV, o módulo *Recommender TV* foi projetado para permitir tanto aplicações NCL utilizando linguagem Lua quanto aplicações Java através da ponte NCL/JAVA que permite a comunicação da máquina de apresentação (Formatador NCL) com a máquina de execução (Gerenciador Xlet) utilizarem seus serviços, o que o torna bem mais flexível.

6.8 Observações Finais

Na literatura existem diversas soluções que visam prover personalização através de sistemas de recomendação com o intuito de solucionar os problemas de sobrecarga de informação e ofertar serviços diferenciados a grupo de usuários. O módulo *Recommender TV* prove mecanismos que permitem a implementação de sistemas de recomendação com características semelhantes aos apresentados nessa seção, permitindo, inclusive, oferecer serviços

diferenciados dos sistemas de recomendação supracitados.

Todos os sistemas de recomendação discutidos nessa seção pertencem ao domínio da TVDI, entretanto, em quase sua totalidade, os testes e demonstrações realizados por esses sistemas não contemplam esse ambiente, desconsiderando características inerentes a TV como os metadados e as linguagens específicas para esse domínio. Como exemplo, o sistema AIMED (HSU *et al.*, 2007) testado totalmente num ambiente computacional livre das limitações impostas pelo *hardware* do STB. O sistema RepTVD (LUCAS ; ZORZO, 2009) e o trabalho de (ZHANG *et al.*, 2005) são exceções. Os testes e demonstrações desses sistemas consideraram e observaram as características que a TVDI possui. O primeiro utilizou o *middleware* brasileiro Ginga, enquanto o segundo desenvolveu sua aplicação baseada no *middleware* europeu MHP.

Para a concepção do módulo *Recommender TV*, considerou-se e observou-se as características que a TVDI possui atualmente, além da aplicação protótipo desenvolvida para testar as funcionalidades ofertadas ter sido implementada em uma linguagem que é específica para este domínio.

CONCLUSÕES E TRABALHOS FUTUROS

O principal objetivo desta dissertação consistiu na proposta de um novo módulo inserido na implementação de referência do *middleware* Ginga para suporte ao desenvolvimento de aplicativos de recomendação, no contexto do SBTVD. Este módulo visa permitir aos desenvolvedores de aplicações interativas concentrar esforços nas interfaces gráficas e navegabilidade de seus sistemas, abstraindo questões de baixo nível como: coleta e persistência do comportamento do usuário, recuperação das informações persistidas e tarefas de mineração de dados. Este objetivo foi alcançado com a concepção do módulo *Recommender TV*.

Para atingir tal meta foi necessário cumprir algumas etapas. Primeiro realizou-se um estudo detalhado do Ginga. Desse estudo, verificou-se a viabilidade da extensão do *middleware* através da inclusão de um novo módulo em sua arquitetura. A etapa seguinte consistiu no estudo detalhado dos metadados utilizados no cenário de TVDI e principalmente, na forma como esses metadados são processados pelo STB e tratados pelo *middleware*. Finalizada as etapas de pesquisa, iniciou-se a modelagem da arquitetura do módulo *Recommender TV*, aspectos de interconexão com os módulos da implementação de referência do *middleware* Ginga e principalmente com as aplicações interativas foram amplamente pesquisados. O objetivo era adaptar um novo módulo no *middleware* de forma transparente, ou seja, sem alterar as funcionalidades já disponibilizadas em sua arquitetura. Concluída a etapa de modelagem, a etapa final tratou da validação do módulo *Recommender TV*, através de uma implementação de referência.

Finalizada as etapas que possibilitaram a concepção do módulo *Recommender TV*, como prova de conceito, foi desenvolvida uma aplicação interativa com o intuito de testar e validar as funcionalidades da implementação

de referência num ambiente compatível com as normas do sistema brasileiro de televisão digital. Os resultados obtidos a partir dessa aplicação demonstram a eficácia e a aplicabilidade do módulo *Recommender TV* apresentado nessa dissertação.

Para realização de trabalhos futuros, espera-se estender as funcionalidades do módulo *Recommender TV* permitindo, com o canal de retorno, enviar os dados sobre o comportamento de visualização para um servidor remoto, que ficará responsável pelo processamento dessas informações permitindo gerar estatísticas, inclusive dados sobre quais programas e provedores de serviços são os mais assistidos, numa versão digital do IBOPE. Além disso, é possível oferecer serviços de recomendação através do canal de retorno, permitindo que todo o processamento para obtenção das recomendações seja executada no servidor remoto, livre das limitações de *hardware* existentes nos terminais de acesso.

O módulo *Recommender TV* através de suas camadas oferece serviços para personalização de conteúdo televisivo, estendendo as funcionalidades da implementação de referência do *middleware* Ginga permitindo aos desenvolvedores de aplicações personalizadas dedicarem esforços em questões de interface e navegabilidade, abstraindo questões de baixo nível. Nesse sentido, a principal contribuição dessa dissertação foi o projeto, modelagem e implementação desse módulo.

REFERÊNCIAS BIBLIOGRÁFICAS

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> . Acesso em: 20 de Novembro 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>. Acesso em: 20 de Novembro 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>. Acesso em: 20 de Novembro 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> . Acesso em: 20 de Novembro de 2009.

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

ALESSIO, E.; BRAGAGNINI, A.; PERBELLINI, G.; QUAGLIA, D. **Gateway and Middleware Design: trusted WSN-TLC network communication and enhanced WSN management.** In: Electronics, Circuits and Systems, 2007. ICECS 2007. 14th IEEE International Conference on , vol., no., pp.637-640, 2007

ALVES, L. G. P. ; SILVA, F. S. ; BRESSAN, G. . **CollaboraTVware: Uma proposta de Infra-estrutura Ciente de Contexto para Suporte a Participação Colaborativa no Cenário da TV Digital Interativa.** In: XIV Simpósio Brasileiro de Sistemas Multimídia e Web (WebMedia 2008), 2008, Vila Velha. XIV Simpósio Brasileiro de Sistemas Multimídia e Web (WebMedia 2008), 2008.

ALVES, L. G. P. **CollaboraTVware: Uma Infra-Estrutura Ciente De Contexto Para Suporte A Participação Colaborativa No Cenário Da TV Digital Interativa.** Dissertação de Mestrado. 203p. Universidade São Paulo. São Paulo, 2008.

ALVES, L. G. P.; KULESZA, R.; SILVA, F. S.; JUCA, P. ; BRESSAN, G. . **Análise Comparativa de Metadados em TV Digital.** In: XXIV Simpósio Brasileiro de Redes de Computadores / WTVD 2006 - II Workshop de TV Digital, 2006, Curitiba. Anais do XXIV Simpósio Brasileiro de Redes de Computadores, 2006.

ÁVILA, P. M. ; ZORZO, S. D. . **A personalized TV Guide System Compliant with Ginga.** In: Simpósio Brasileiro de Sistemas Multimídia e Web (WebMedia), 2009, Fortaleza. Anais do WebMedia'09, 2009.

ÁVILA, P. M. ; ZORZO, S. D. . **A personalized TV Guide System: An Approach to Interactive Digital Television.** In: IEEE International Conference on Systems, Man, and Cybernetics, 2009, San Antonio. Proceedings of the SMC, 2009.

ÁVILA, P. M. ; ZORZO, S. D. . **Recommender TV - A Personalized TV Guide System compliant with GINGA.** In: International Conference on Signal Processing

and Multimedia Applications, 2009, Milan. Proceedings of the SIGMAP 2009. Los Alamitos, CA : IEEE Computer Society, 2009.

ÁVILA, P. M. ; ZORZO, S. D. . **Suporte ao Desenvolvimento de Sistemas de Recomendação em Ambientes de Televisão Digital Interativa**. In: Conferência Latino-Americana de Informática (CLEI), 2009, Pelotas. Anais do Clei, 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, Rio de Janeiro, Brasil. Editora PUC-RIO, PP 105 – 174, 2008.

BITTENCOURT, F. **TV aberta brasileira: o impacto da digitalização. IEL/NC, TV Digital: qualidade e interatividade**, 2007. Disponível em: <http://www.iel.org.br/publicacoes/arquivos/tv_digital_web.pdf>. Acesso em: 11 de Novembro de 2009.

BLANCO-FERNANDEZ, Y.; PAZOS-ARIAS, J. J.; GIL-SOLLA, A.; RAMOS-CABRER, M.; LOPES-NORES, M.; BARRAGANS-MARTINEZ, B. **AVATAR: a multi-agent TV recommender system using MHP applications**. In: IEEE International Conference on E-Technology, E-Commerce and E-Service (EEE '05), pp. 660-665, 2005.

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 2nd International Conference on Adaptive Hypermedia and Adaptive Web Based Systems, Malaga, Espanha. **Proceedings...**pp. 3-12, 2002.

CESAR, P.; CHORIANOPOULOS, K. ; JENSEN, J. F. 2008. **Social television and user interaction**. In: Comput. Entertain. DOI= <http://doi.acm.org/10.1145/1350843.1350847>, 2008.

CESAR, P; VUORIMAA, P.; VIERINEN, J. 2006. **A graphics architecture for**

high-end interactive television terminals. In: ACM Trans. Multimedia Comput. Commun. DOI= <http://doi.acm.org/10.1145/1201730.1201735>, 2006.

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

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>. Acesso em: 20 Novembro de 2009.

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>. Acesso em: 10 de Novembro de 2009.

FAYYAD, U. M.; PIATETSKY-SHAPIO 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, 1996.

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.

FERNANDES, J.; SOUZA FILHO, G. L.; ELIAS, G. **Introdução à Televisão Digital Interativa: Arquitetura, Protocolos, Padrões e Práticas.** JAI – Jornadas de Atualização em Informática. XXIV Congresso da SBC, 2004.

FREITAS, G. B. ; TEIXEIRA, C. A. 2009. **Ubiquitous Services in Home Networks offered through Digital TV**. In Proceeding of the Twenty-fourth ACM Symposium on Applied Computing (Honolulu, Hawaii, USA, March 8 - 12, 2009). SAC '09. ACM, New York, NY, 2009.

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

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

HAN, J.; KAMBER, M.: **Data Mining: Concepts and Techniques**. Morgan Kaufmann, 2001.

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

LUA. Disponível em <<http://www.lua.org>>. Acessado em Dezembro de 2009.

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), Recife, Brasil, 2009.

LUGMAYR, A.; NIIRANEN, S.; KALLI, S. **Digital Interactive TV and Metadata**. Springer, 2004.

MIN-CHEOL HWANG; LE THANH HA; SEUNG-KYUN KIM; SUNG-JEA KO. **"Real-Time Person Identification System for Intelligent Digital TV"** In: Consumer

Electronics, 2007. ICCE 2007. Digest of Technical Papers. International Conference on , vol., no., pp.1-2, 10-14, 2007.

MONTEZ, C.; BECKER, V. **TV Digital Interativa: Conceitos e Tecnologias. Tópicos em Tecnologias Web e Multimídia.** WebMedia, 2004.

MONTEZ, C.; BECKER, V. **TV Digital Interativa: Conceitos, Desafios e Perspectivas para o Brasil.** Ed. da UFSC, 2ª Edição, Florianópolis, Brasil, 2005.

MORRIS, S. ; SMITH-CHAIGNEAU A.. **Interactive TV standards.** Editora Focal Press is an imprint of Elsevier 30 Corporate Drive, Suite 400, Burlington, MA 01803, USA Linacre House, Jordan Hill, Oxford OX2 8DP, UK. ISBN: 0-240-80666-2, 2005.

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

PICCIONI, C. A. **Modelo e Implementação de um Serviço de Datacasting para Televisão Digital.** Dissertação de Mestrado. 102p. Universidade Federal de Santa Catarina. Florianópolis, 2005.

SANTOS JUNIOR, J. B., ABRÃO, I. C., BARRÉRE, E., ÁVILA, P. M., PRADO, G. M., DOS SANTOS, M. 2008. **A platform for diffusion interactive multimedia content: an approach focused on IPTV system and broadcasting digital television system.** In *Proceedings of the 2008 Euro American Conference on Telematics and information Systems* (Aracaju, Brazil, September 10 - 12, 2008). EATIS '08. ACM, New York, NY, 1-5. DOI= <http://doi.acm.org/10.1145/1621087.1621132>, 2008.

SBTVD. **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.

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

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

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, 2007.

SUN DTV. **Sun Java DTV**. Disponível em: <https://cds.sun.com/is-bin/INTERSHOP.enfinity/WFS/CDS-CDS_Developer-Site/en_US/-/USD/ViewLicense-Start> . Acessado em Setembro de 2009.

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

VILDJOUNAITE, E.; KYLLONEN, V.; HANNULA, T.; ALAHUHTA, P.: **Unobtrusive Dynamic Modelling of TV Program Preferences**. In: 6th European Conference On Interactive Television (Euroitv): Changing Television Environments, 2008, Salzburg, Austria. Proceedings pp 82-91, 2008.

XU, J.; ZHANG, L.; LU, H.; LI, Y. **The Development and Prospect of Personalized TV Program**, In: Proceedings of the IEEE 4th International Symposium on Multimedia Software Engineering (MSE'02), 2002.

ZHANG, H.; ZHENG, S. **Personalized TV Program Recommendation based on TV-Anytime Metadata**. In: Proceedings of the Ninth International Symposium on Consumer Electronics, (ISCE 2005), 2005.

ZHANG, H.; ZHENG, S. YUAN J. **A personalized TV guide system compliant with MHP**. In: Consumer Electronics, IEEE Transactions on , vol.51, no.2, pp. 731-737, 2005.

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, 2006.

APÊNDICE A – GERADOR DE TABELAS EIT & SDT

Para simulação e testes foi implementando um gerador de tabela EIT & SDT que permite a geração das tabelas e seus descritores. A Figura 19 apresenta a interface do gerador de tabelas.

Gerador de tabelas SDT (Service Description Table) & EIT (Event Information Table)

Service Description Table | **Event Information Table**

event_information_section

table_id	0x4E ▼
section_syntax_indicator	1
reserved_future_use	1
Reserved	11
section_length	
service_id	
Reserved	11
version_number	
current_next_indicator	
section_number	
last_section_number	
transport_stream_id	
original_network_id	
segment_last_section_number	
last_table_id	
CRC_32	11111111111111111111111111111111

for(i=0;i<N;i++)

event_id	
start_time	
Duration	
running_status	Indefinido ▼
free_CA_mode	
descriptors_loop_length	

for(j=0;j<N;j++)

Selecione o descritor 1 de ?

descritor de evento estendido* ▼

Incluir Descritor Selecionado

Incluir Novo Evento ID

Gerar SDT
Gerar EIT
Fechar

Figura 19 – Interface do gerador de tabelas EIT

Os campos da tabela e os descritores implementados seguem exatamente o descrito na norma (NBR-15603-2, 2007). A Figura 20 apresenta o gerador de tabela SDT.

Gerador de tabelas SDT (Service Description Table) & EIT (Event Information Table)

Service Description Table Event Information Table

service_description_section()

table_id: 0x42

section_syntax_indicator: 1

reserved_future_use: 1

reserved: 11

section_length:

transport_stream_id:

reserved: 11

version_number:

current_next_indicator:

section_number:

last_section_number:

original_network_id:

reserved_future_use: 11111111

CRC_32: 11111111111111111111111111111111

Service

service_id:

reserved_future_use: 111111

EIT_schedule_flag: ☐

EIT_present_following_flag: ☐

running_status: Indefinido

free_CA_mode:

descriptor_loop_length:

Descriptor

Selecione o descritor 1 de ?

descritor de serviço*

Inserir Descritor

Gerar SDT Gerar EIT Fechar

Figura 20 – Interface do gerador de tabelas SDT

Desta maneira, certificamos que as informações utilizadas pelo módulo *Recommender TV* estão de acordo com as normas brasileiras de televisão digital.

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)