

# Modelo Conceitual de Serviço de Recomendações para TV 3.0

Arthur Poggy  
TeleMídia Lab - PUC-Rio

Rio de Janeiro, Brazil  
arthurpoggy@telemidia.puc-rio.br

Daniel de Sousa Moraes  
TeleMídia Lab - PUC-Rio

Rio de Janeiro, Brazil  
danielmoraes@telemidia.puc-rio.br

Paulo Victor Borges  
TeleMídia Lab - PUC-Rio

Rio de Janeiro, Brazil  
pvborges@telemidia.puc-rio.br

Sérgio Colcher  
TeleMídia Lab - PUC-Rio  
Rio de Janeiro, Brazil  
colcher@inf.puc-rio.br

## ABSTRACT

The evolution toward TV 3.0 establishes a hybrid broadcast–broadband ecosystem, application-oriented and characterized by new requirements for personalization and interoperability. Although recommender systems are widely explored on OTT platforms, their use in the television context still faces specific challenges, such as limited interaction, shared viewing, and constraints on data collection. This work proposes a conceptual model for a recommendation service based on multiple specialized agents coordinated by a central orchestrator. The proposal aims to provide a minimum viable abstraction, modular, extensible, and aligned with the constraints of the television environment. In addition to detailing the architecture, we present a hypothetical use case that illustrates the end-to-end flow and discuss implications for transparency, explainability, and governance of recommendations. The results are intended to support the adoption of personalization mechanisms in TV 3.0, reconciling technological innovation with requirements for reliability and usability.

## KEYWORDS

TV 3.0; serviços de recomendação; sistemas multiagentes

## 1 INTRODUÇÃO

No Brasil, a televisão tem passado por um processo contínuo de renovação tecnológica e cultural ao longo das décadas. A primeira grande transformação ocorreu em 2007, com a transição da transmissão analógica para a digital, inaugurando a TV 2.0, que trouxe recursos como mobilidade, interatividade e imagem em alta definição. Posteriormente, uma etapa intermediária, conhecida como TV 2.5, aprofundou a integração com a internet e dispositivos móveis, ampliando a interatividade e diversificando formas de consumo. Atualmente, o cenário aponta para a TV 3.0, uma geração disruptiva e orientada a aplicativos [13], marcada pela personalização de conteúdos, maior acessibilidade, perfis de telespectadores, identificação multiusuários, interação multimodal, etc [12] características que prometem redefinir a relação do público brasileiro com a televisão aberta.

Esse avanço ganhou marco regulatório com o Decreto nº 11.484, de 6 de abril de 2023, que estabeleceu princípios fundamentais como eficiência espectral, interoperabilidade baseada em IP e suporte a serviços personalizados [5]. Nesse contexto, o Projeto TV 3.0, conduzido pelo Fórum do Sistema Brasileiro de Televisão Digital Terrestre (Fórum SBTVD), com ampla participação de empresas e instituições acadêmicas, resultou na recomendação ao Ministério das Comunicações das tecnologias a serem adotadas no novo padrão. Entre essas recomendações estão soluções de ponta, como a codificação de vídeo VVC/LCEVC, o áudio imersivo MPEG-H e a sinalização compatível com ATSC 3.0, que possibilitam a entrega híbrida de conteúdo por broadcast e broadband [11].

Nesse sentido, embora o consumo de OTT (Over-the-top) esteja em expansão, a televisão linear ainda concentra a maior parte da audiência domiciliar no Brasil, respondendo por 79% do *share* (participação percentual do consumo total de televisão)<sup>1</sup>. Esse predomínio, contudo, convive com uma mudança clara nas expectativas do público: pesquisas indicam que a maioria dos consumidores deseja experiências personalizadas e tende a se frustrar quando elas não acontecem [14].

Nesse cenário, a personalização deixa de ser apenas uma prática recomendada e passa a constituir um diferencial competitivo, em especial na era da chamada hipersegmentação. O fenômeno não se limita ao varejo digital, no qual já responde por parcela relevante da receita de e-commerce [4], mas também se consolida em plataformas de mídia: no caso da Netflix, aproximadamente 80% do conteúdo assistido advém de recomendações personalizadas [9].

Entregar personalização no contexto televisivo envolve desafios que diferem substancialmente daqueles enfrentados em ambientes web ou mobile. Enquanto interfaces digitais tradicionais contam com interações ricas via teclado, mouse ou toque, o ecossistema das *Smart TVs* permanece condicionado por restrições estruturais que limitam tanto a coleta de sinais quanto a precisão das recomendações. Um dos principais fatores é o uso predominante do controle remoto, que reduz a densidade das interações e gera registros esparsos de comportamento.

Além disso, o consumo televisivo caracteriza-se majoritariamente como *lean-back*, no qual o espectador adota uma postura passiva, com baixo nível de engajamento explícito. Pesquisas recentes sugerem, entretanto, que essa condição não deve ser entendida de forma binária (*lean-back* vs. *lean-forward*), mas sim como parte

In: VIII Workshop Futuro da TV Digital Interativa (WTVDI 2025). Anais Estendidos do XXXI Simpósio Brasileiro de Sistemas Multimídia e Web (WTVDI'2025). Rio de Janeiro/RJ, Brasil. Porto Alegre: Brazilian Computer Society, 2025.

© 2025

ISSN 2596-1683

<sup>1</sup>[https://kantariopemedia.com/wp-content/uploads/2023/03/Kantar-IBOPE-Media\\_Inside-Video-2023.pdf](https://kantariopemedia.com/wp-content/uploads/2023/03/Kantar-IBOPE-Media_Inside-Video-2023.pdf)

de um espectro contínuo de engajamento, que abrange diferentes graus de envolvimento e atenção. Esse entendimento mais granular tem implicações diretas na eficácia publicitária e na forma como recomendações televisivas devem ser concebidas [6].

A natureza multiusuário e compartilhada do aparelho de televisão é outro aspecto que pode dificultar a individualização dos perfis, reduzindo a eficácia de técnicas tradicionais como a filtragem colaborativa [3]. Esses fatores combinados reforçam a necessidade de modelos conceituais adaptados ao contexto da TV Digital, capazes de lidar com sinais incompletos e heterogêneos sem comprometer a qualidade da recomendação.

Nesse cenário, este trabalho apresenta um modelo conceitual para um serviço de recomendação orientado à TV 3.0, fundamentado em agentes especializados e projetado para lidar com dados heterogêneos provenientes de múltiplas fontes do ecossistema televisivo. O objetivo é viabilizar recomendações de conteúdos audiovisuais e inserções publicitárias personalizadas, que sejam ao mesmo tempo explicáveis e adaptadas ao contexto do usuário, considerando fatores como localização, histórico de consumo e preferências declaradas.

O restante do trabalho organiza-se da seguinte forma: a Seção 2 discute os trabalhos relacionados, com ênfase nas abordagens existentes em sistemas de recomendação. A Seção 3 apresenta em detalhe a arquitetura proposta, incluindo sua modelagem conceitual e os principais componentes. A Seção 4 descreve um estudo de caso hipotético, que ilustra o funcionamento do sistema em um cenário realista. Por fim, a Seção 5 sintetiza as contribuições alcançadas e aponta direções para trabalhos futuros.

## 2 TRABALHOS RELACIONADOS

Nesta seção, apresentamos duas frentes que servem de fundamentação para o desenvolvimento da proposta neste trabalho. Primeiro, o uso de IA/LLMs em recomendação, no qual modelos de linguagem atuam como codificadores universais de itens/usuários, trazendo ganhos em cold-start, contextualização e explicabilidade, ainda que com desafios de latência, custo e controle [10, 17]. Segundo, abordagens multi-agentes para recomendação, que estruturam papéis especializados e coordenação entre agentes, incluindo frameworks recentes de orquestração [2, 7, 16].

Entre as abordagens baseadas em LLM, a metodologia de *Recommendation as Language Processing* apresentada por Geng et al. [8] converte interações, metadados e avaliações em sequências de texto e pré-treina um encoder-decoder estilo T5 (*Text-to-Text Transfer Transformer*) com prompts personalizados. Arquiteturalmente, é um modelo *text-to-text* único que unifica predição, recomendação sequencial e explicações, usando geração condicional para produzir top-K. Na plataforma Amazon, dentre as categorias de itens dos quais foram aplicados a abordagem, obteve em Sports uma melhora de 33% na recomendação dos 10 primeiros itens em pesquisa e 18% da mesma métrica na categoria beauty. Sun et al. [15] também apresenta um framework eficiente nesse contexto. O projeto RankGPT posiciona LLMs como reordenadores *listwise* via *permutation generation*, encaixando-se como estágio final (*retrieval + re-ranking*) e incluindo destilação para modelos menores. Em modo zero-shot, o GPT-4 alcançou 62,39% de melhora na recomendação dos 10 primeiros itens.

Entre os trabalhos que empregam multi-agentes, dois são particularmente interessantes. Fang et al. [7] apresenta o MACRS, que organiza a recomendação conversacional em múltiplos agentes LLM: um planejador decide entre perguntar, recomendar ou dialogar; agentes executam a ação escolhida e um laço de reflexão atualiza perfil e política a partir do feedback do usuário. A recomendação é produzida dentro do próprio diálogo, combinando elicitação progressiva de preferências e seleção de itens. Em avaliações com simulador, o MACRS atingiu Success Rate de 0,61 (vs. 0,39 do ChatGPT e 0,42 do Llama2).

Já o MACRec [16] apresenta um arcabouço geral de colaboração com um Manager que orquestra agentes especializados (User/Item Analyst, Searcher, Reflector, Task Interpreter) em ciclos pensamento-ação-observação. A ferramenta de recomendação aparece em quatro instâncias diferentes apresentadas no trabalho (predição de nota, sequencial, explicações e conversacional) por meio da delegação de subtarefas e posterior agregação das respostas. Os resultados são de caráter demonstrativo, evidenciando adaptabilidade e reutilização de papéis em diferentes tarefas, ainda que sem comparativos padronizados com baselines.

Em síntese, as duas linhas convergem em um ponto comum: a recomendação deixa de ser um processo monolítico e passa a ser vista como a composição de módulos interpretáveis, sejam eles LLMs aplicados em diferentes pontos da *pipeline* ou como agentes especializados coordenados por um orquestrador. O presente trabalho se apoia nessa perspectiva para propor um modelo orientado a agentes no contexto da TV Digital, explorando tanto a capacidade de inferência contextual quanto a necessidade de explicabilidade e governança.

## 3 MODELO DO SERVIÇO DE RECOMENDAÇÕES

Pensando nas particularidades do ambiente da TV Digital, esta seção apresenta uma proposta de serviço de recomendações modelado como uma arquitetura multiagentes extensível, para auxiliar a personalização de conteúdo no contexto da TV 3.0. Um modelo conceitual que permitirá às emissoras, seguindo as regras de privacidade, explorar os recursos oferecidos pela arquitetura da TV 3.0, tais como acesso a dados contextuais do dispositivo, perfis de usuários criados no contexto das emissoras e até de plataformas OTT externas integradas, para criar e oferecer experiências personalizadas para os telespectadores.

O modelo, ilustrado na Figura 1, organiza-se em torno do fluxo de requisições oriundas do *Broadcaster Application*, da aquisição de dados contextuais e do enriquecimento progressivo da informação, com o objetivo de fornecer recomendações personalizadas para cada telespectador e explicáveis para a emissora.

O *Broadcaster App* é o ponto inicial, reunindo dados provenientes de múltiplas fontes: informações contextuais do dispositivo (como configurações, conectividade e geolocalização), perfis de usuários mantidos pela emissora e integrações com plataformas externas, como serviços de streaming. Esses dados, uma vez selecionados e agregados, são então encaminhados ao serviço de recomendação.

Nesse cenário, o núcleo da proposta é um **orquestrador central**, responsável por receber os dados do *Broadcaster App*, processá-los

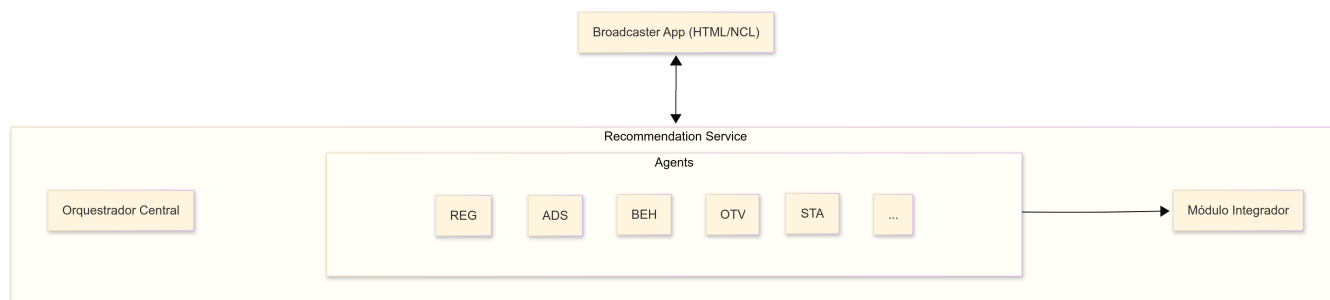


Figura 1: Fluxo de comunicação entre aplicação, orquestrador, agentes especializados e módulo integrador.

e distribuí-los aos agentes especializados conforme as tarefas identificadas. Cada agente atuará, de forma paralela, em um domínio específico, gerando avaliações parciais e explicações locais que, em conjunto, fundamentam a recomendação. Em seguida, o orquestrador consolida essas saídas e as encaminha ao módulo integrador para unificação final.

Para minimizar a complexidade inicial de recomendações (*cold-start*) e reduzir a sobrecarga de contexto durante a execução, cada agente é modelado como uma chamada independente a um **LLM**, no qual apenas as informações estritamente necessárias são incluídas no *prompt*. O modelo adota, assim, um conjunto mínimo de agentes especializados, projetados para cobrir os principais domínios de análise da TV Digital. Como cada agente utiliza um LLM como núcleo de inferência, é capaz de interpretar dados heterogêneos, gerar avaliações locais e produzir explicações em linguagem natural. Essa modelagem garante flexibilidade para expansão progressiva, permitindo a inclusão de novos agentes ou fontes de dados conforme os recursos disponíveis e as necessidades específicas de cada emissora.

Para assegurar interoperabilidade e modularidade, cada agente é definido por um contrato explícito de *input* e *output*, que especifica os dados de entrada esperados, o formato de processamento e o tipo de resposta gerada. Esses contratos funcionam como base de evolução da arquitetura, viabilizando a incorporação de novos agentes ou ajustes nos existentes sem comprometer o sistema, ao mesmo tempo em que preservam a flexibilidade operacional e a governança no processo de recomendação.

### 3.1 Os Agentes Especializados e os Domínios de Conhecimento

A camada de agentes é composta por módulos autônomos, cada um dedicado a um contexto específica do processo de recomendação. Embora cada agente atue de forma independente, eles compartilham conhecimento entre si e têm consciência do conjunto existente, podendo avaliar a necessidade de complementar ou agregar resultados produzidos por outros agentes. Apresentamos a seguir um conjunto de agentes definidos a partir dos atributos básicos estabelecidos para a TV 3.0. Importante ressaltar que esse conjunto não se limita apenas aos agentes aqui descritos.

**3.1.1 Agente de Preferências Regionais (REG).** O agente **REG** tem como finalidade ajustar a recomendação ao contexto geográfico e cultural do telespectador. Para isso, pode considerar registros de audiência segmentados por região, dados de geolocalização do

dispositivo, fusos horários e calendários de eventos locais. No plano conceitual, tais informações poderiam ser obtidas a partir de recursos já disponíveis no ecossistema televisivo, como a localização aproximada derivada do *endereço IP*, dados cadastrais vinculados ao perfil DTV+ ou ainda preferências regionais observadas em plataformas de streaming. A partir dessa base territorial e cultural, o **REG** estabelece um ponto de partida sobre o qual outros agentes, dedicados à segmentação publicitária, ao comportamento individual ou à exploração de catálogos, podem acumular análises adicionais, resultando em recomendações progressivamente mais precisas e contextualizadas.

**3.1.2 Agente de Segmentação Publicitária (ADS).** O agente **ADS** tem como foco alinhar os perfis de audiência às estratégias de monetização da emissora. Para isso, poderia utilizar dados demográficos, como idade, gênero, combinados com sinais comportamentais extraídos do histórico de exposição a anúncios ou do nível de engajamento com campanhas anteriores. Essas informações podem ser obtidas de diferentes formas: a partir do perfil cadastrado no DTV+, de dados de login associados a plataformas de streaming, ou ainda por meio de integrações com outros sistemas utilizados pela emissora. Em alguns casos, até mesmo interações simples, como a frequência com que um usuário pausa ou ignora determinado tipo de anúncio, podem servir como insumo para refinar a segmentação. O desafio central do **ADS** está em conciliar a necessidade de granularidade suficiente para tornar a publicidade eficaz com mecanismos de anonimização e pseudonimização que garantam a preservação da privacidade. Ainda que hipotético neste modelo, tal agente poderia evoluir para incorporar modelos preditivos de propensão à compra, ajustando em tempo real a probabilidade de conversão de um anúncio ou apoiar técnicas de inserção dinâmica de publicidade (*dynamic ad insertion*), em que diferentes usuários recebem variações de um mesmo intervalo comercial de acordo com seu perfil.

**3.1.3 Agente de Histórico de Comportamento (BEH).** O agente **BEH** foca nos hábitos concretos de cada telespectador. Seu objetivo é transformar o histórico de interações em evidências de preferência, registrando desde conteúdos assistidos até métricas de permanência, padrões de abandono e avaliações explícitas ou implícitas.

No ecossistema da TV 3.0, esse histórico pode ser construído a partir de diferentes meios já disponíveis às emissoras: o *Broadcaster App* pode enviar periodicamente registros de navegação; aplicativos *companion* podem adicionar feedback explícito, como curtidas ou

comentários; controles remotos interativos, por sua vez, capturam sinais mínimos de engajamento, como mudanças frequentes de canal ou velocidade ao avançar um conteúdo; e, em contextos OTT, maratonas de séries ou abandonos precoces fornecem sinais ricos sobre preferências e rejeições.

O desafio central do BEH é a esparsidade e o ruído desses dados, poucos usuários expressam feedback direto, e a maioria das pistas precisa ser inferida a partir de fragmentos de comportamento. Em uma perspectiva evolutiva, o BEH pode integrar sinais multimodais, ampliando a capacidade de leitura do engajamento. Comandos de voz captados durante a navegação, ou expressões faciais associadas a reações emocionais, podem ser incorporados como partes do contexto, enriquecendo a interpretação do comportamento do usuário. Assim, o BEH não se limita a um repositório de histórico, mas funciona como um motor analítico capaz de revelar trajetórias personalizadas de consumo.

**3.1.4 Agente de Conteúdo de TV Aberta (OTV).** O agente **OTV** é responsável por integrar à recomendação os conteúdos lineares da televisão aberta, com ênfase em transmissões ao vivo, que costumam concentrar maior atratividade e imprevisibilidade. Ele lida com informações como grade de programação, metadados de títulos, gênero, horários previstos e classificação indicativa, usualmente disponibilizadas por meio de tabelas EPG, sinalizações digitais ou captura via middleware.

O desafio central não está no processamento, mas na **aquisição confiável da programação**. Alterações de última hora, atrasos em novelas, prolongamento de partidas esportivas ou inserções emergenciais de jornalismo, comprometem a consistência das informações divulgadas, tornando guias e metadados muitas vezes incompletos ou desatualizados. Para mitigar esse problema, o agente deve ser capaz de cruzar múltiplas fontes de dados, validar atualizações em tempo real e acomodar diferenças de granularidade entre emissoras.

No caso de fluxos ATSC 3.0 [1], por exemplo, além do sinal audiovisual são transportados serviços auxiliares que incluem guias detalhados, identificadores de conteúdo, sinalização de eventos ao vivo e recursos de acessibilidade. Quando corretamente adquiridos e integrados, esses elementos permitem que o OTV enriqueça a recomendação com atributos adicionais, como gênero, duração real ou restrição etária, e forneça ao módulo integrador uma visão mais precisa do que está efetivamente disponível em cada momento.

**3.1.5 Agente de Catálogos de Streaming (STA).** O agente **STA** é planejado, neste modelo, como o módulo responsável por explorar os conteúdos sob demanda que podem ser disponibilizados por meio de fluxos OTT. O foco está nos serviços oferecidos pela própria emissora, que passa a dispor de um canal padronizado para distribuir conteúdos adicionais além da transmissão linear.

Com a sinalização do guia eletrônico de conteúdo (ECG), os serviços de TV 3.0 podem anunciar e expor metadados de vídeos sob demanda vinculados à programação linear, como reprises de programas recém-exibidos, conteúdos complementares (entrevistas estendidas, estatísticas em eventos esportivos) ou catálogos proprietários de séries e documentários. Os metadados associados incluem título, descrição, gênero, idioma e janelas de disponibilidade, fornecendo ao sistema de recomendação insumos estruturados e alinhados com o contexto da própria emissora. O agente OTT permite enriquecer

a recomendação ao combinar o “tempo real” da TV aberta com o “sob demanda” oferecido pela emissora. Em um cenário evolutivo, esse mecanismo pode ser estendido para incorporar indicadores de popularidade capturados em tempo real ou métricas colaborativas derivadas da própria base de usuários, criando uma camada de personalização adicional sem depender de plataformas externas.

## 3.2 Módulo Integrador

O módulo integrador transforma as avaliações isoladas dos agentes em uma decisão coerente. Sua função não é apenas somar escores, mas aplicar estratégias de fusão capazes de balancear dimensões distintas, em um ranking unificado de recomendações. Esse ranking é acompanhado por indicadores de confiança e explicações textuais que tornam o resultado mais inteligível e útil para a emissora.

Diferentemente de um agregador estático, o integrador é concebido como uma camada de governança. Ele mantém rastreabilidade sobre a origem de cada decisão, explicita o peso relativo de cada agente e permite calibrar prioridades conforme políticas editoriais ou comerciais. Ao adotar princípios de *explainable AI*, o módulo oferece transparência e auditabilidade, de modo que gestores técnicos compreendam não apenas *o que* foi recomendado, mas também *por que* essa recomendação emergiu do processo. Essa capacidade torna-se crucial em um cenário televisivo em que personalização, regulação e confiança do público precisam coexistir.

## 3.3 Síntese do Fluxo e Escopo Conceitual

O funcionamento do modelo pode ser entendido como um ciclo de enriquecimento progressivo. O processo inicia-se com o orquestrador central, que recebe a requisição de recomendação a partir do *Broadcaster App* e a distribui para os agentes especializados relevantes ao contexto da solicitação (REG, ADS, BEH, OTA, OTT). Cada agente interpreta os dados sob sua ótica e retorna escores parciais acompanhados de explicações locais. Essas saídas fragmentadas são então consolidadas no módulo integrador, que aplica estratégias de fusão para compor um ranking unificado de conteúdos e anúncios, posteriormente entregue à aplicação em tempo real.

É importante ressaltar que tal modelagem não deve ser entendida como uma solução rígida, mas como uma abstração mínima viável. Trata-se de um modelo conceitual inicial, pensado para ser adaptado de acordo com os recursos técnicos e organizacionais de cada emissora. Assim, a arquitetura oferece uma base extensível: novos agentes podem ser incorporados, diferentes tipos de dados contextuais podem ser adicionados, e múltiplas estratégias de fusão podem ser experimentadas. Essa flexibilidade assegura que o sistema possa evoluir gradualmente, sem perda de governança, em direção a recomendações mais sofisticadas e personalizadas no ecossistema da TV 3.0.

## 4 CASO DE USO

Para ilustrar a arquitetura proposta, descrevemos o caso de 1: Seja um telespectador, um jovem de 20 anos residente em Copacabana (Rio de Janeiro), consumidor ativo de mídia audiovisual, com preferências claras por esportes e séries de comédia, além de forte engajamento com conteúdos médicos. Seu consumo televisivo ocorre majoritariamente entre 18h e 22h, período de pico de audiência na região. Ele mantém conta na plataforma OTT de uma emissora X,

onde assiste séries médicas, avalia episódios e deixa comentários públicos, comportamento que fornece sinais explícitos de preferência e feedback.

Os dados de entrada refletem um perfil multifacetado:

- (1) **Demográficos (ADS):** gênero masculino, universitário, estilo de vida ativo ligado à praia; obtidos a partir do cadastro do usuário na plataforma OTT da emissora X, complementados por dados obtidos em um formulário de uma aplicação secundária de TV 3.0. Essas informações alimentam o **agente de Segmentação Publicitária (ADS)** para a construção do perfil de audiência.
- (2) **Preferências Regionais (REG):** Cidade: Rio de Janeiro; Microrregião: zona sul; Outros: moradores da mesma região têm consumo predominante de conteúdo esportivo.
- (3) **Histórico de consumo (BEH/STA):** acesso tipicamente por smartphone Android, em tela reduzida; informações coletadas via identificação do dispositivo e metadados de sessão registrados pelo *Broadcaster App*. Visualização completa de “Plantão Médico”, alta avaliação de “Comédia Carioca” e fidelidade a programas esportivos como “Arena Esportiva”; reconstruído a partir dos registros de visualização armazenados no servidor da emissora (logs de OTT) e do retorno de interações. Esses dados são processados pelo **agente de Histórico de Comportamento (BEH)**, em complemento ao **agente STA** para conteúdos sob demanda.
- (4) **Interações explícitas (BEH):** elogios a séries médicas e cômicas, rejeição a dramas românticos e programas de culinária; capturados a partir de comentários e avaliações fornecidos na plataforma OTT, bem como feedback registrado em aplicativos companion vinculados ao mesmo perfil. O **agente BEH** interpreta esses sinais explícitos e os combina com o histórico implícito de visualização.
- (5) **Preferências publicitárias (ADS):** anúncios ligados a esportes e tecnologia; inferidos a partir do histórico de cliques em campanhas digitais da própria emissora e da categorização de interesses declarados no perfil OTT. Essas informações retroalimentam o **agente ADS**, permitindo segmentação publicitária mais precisa.

Do ponto de vista da emissora, o objetivo é fornecer uma camada de recomendação que valorize tanto os conteúdos lineares (OTA) quanto os sob demanda (OTT) disponibilizados pela própria emissora X. A meta é maximizar engajamento e retenção de audiência, ao mesmo tempo em que se otimiza a entrega de anúncios segmentados a partir dos perfis construídos.

No modelo proposto, o serviço de recomendação recebe uma requisição contendo os dados contextuais e preferências do telespectador e, a partir disso, aciona os agentes especializados (REG, ADS, BEH, OTV e STA). Cada agente processa sua esfera de competência e retorna escores parciais e justificativas locais. Esses resultados são então consolidados pelo **módulo integrador**, que aplica estratégias de fusão e produz um ranking final de conteúdos e anúncios relevantes.

#### 4.1 Exemplo de Output do Módulo Integrador

A seguir, apresenta-se um exemplo *hipotético* da resposta gerada para o caso do Fulano. O formato JSON mostra como o ranking pode

ser estruturado, incluindo não apenas os conteúdos priorizados, mas também a explicação consolidada de cada agente (REG, ADS, BEH, STA, OTT, OTV), de forma a reforçar os princípios de *explainable AI* e permitir rastreabilidade das decisões.

#### Listing 1: Saída simulada do módulo integrador para o caso telespectador

```
{
  "timestamp": "2025-08-28T20:45:00Z",
  "user": "telespectador",
  "recommendations": [
    {
      "title": "Arena Esportiva",
      "genre": "Esporte",
      "platform": "OTA",
      "score": 0.92,
      "confidence": "high",
      "explanation": {
        "REG": "Alta audiência no Rio de Janeiro em horários noturnos",
        "ADS": "Segmento jovem com afinidade a esportes",
        "BEH": "Histórico de fidelidade em transmissões esportivas",
        "OTV": "Jogo transmitido ao vivo",
        "STA": "Reprises disponíveis sob demanda"
      }
    },
    {
      "title": "Comédia Carioca",
      "genre": "Comédia",
      "platform": "OTT",
      "score": 0.81,
      "confidence": "medium",
      "explanation": {
        "REG": "Alta relevância cultural no contexto local",
        "ADS": "Compatibilidade com anúncios de tecnologia",
        "BEH": "Avaliação positiva em episódios anteriores",
        "OTV": "Programa exibido anteriormente em horário nobre",
        "STA": "Catálogo proprietário disponível para maratona"
      }
    }
  ]
}
```

Esse exemplo evidencia como os diferentes sinais processados pelos agentes convergem em um ranking final personalizado. Além disso, a estrutura de explicação anexa a cada item assegura transparência e auditabilidade, fornecendo à emissora subsídios claros para justificar decisões de recomendação e otimizar continuamente suas estratégias.

## 5 CONCLUSÃO

Este trabalho apresentou um modelo conceitual de um serviço de recomendações para TV 3.0, baseado em multi-agentes especializados e coordenado por um orquestrador central. O modelo mostrou como dados heterogêneos podem ser processados e consolidados em recomendações personalizadas, respeitando princípios de privacidade. Como próximos passos, destacamos a implementação de um protótipo funcional e a realização de estudos de validação com usuários, de modo a avaliar a eficácia prática da proposta em cenários reais.

Em síntese, ao propor uma arquitetura multiagentes para recomendações em TV 3.0, este trabalho busca contribuir para a construção de experiências televisivas mais personalizadas, transparentes e responsáveis. A proposta apresentada fornece uma base que poderá ser expandida em protótipos e evoluções arquiteturais, de modo a apoiar a transição da televisão brasileira para uma nova geração de interatividade e personalização.

## REFERÊNCIAS

- [1] 2024. *ATSC A/300: ATSC 3.0 System*. Technical Report. Advanced Television Systems Committee (ATSC). <https://www.atsc.org/wp-content/uploads/2024/04/A300-2024-04-ATSC-3-System-Standard.pdf> Approved 17 July 2025.
- [2] Kushagra Agrawal and Nisharg Nargund. 2025. Neural Orchestration for Multi-Agent Systems: A Deep Learning Framework for Optimal Agent Selection in Multi-Domain Task Environments. *arXiv preprint* (2025). <https://doi.org/10.48550/arXiv.2505.02861> arXiv:2505.02861 [cs.MA]
- [3] Iftikhar Alam, Shah Khusro, and Mumtaz Khan. 2019. Factors Affecting the Performance of Recommender Systems in a Smart TV Environment. *Technologies* 7, 2 (2019), 41. <https://doi.org/10.3390/technologies7020041>
- [4] Barilliance. 2024. Ecommerce Personalization Statistics: Personalized Recommendations Account for 31% of Revenue. <https://www.barilliance.com/ecommerce-personalization-statistics/> Estudo aponta que 31% da receita de e-commerce vem de recomendações personalizadas.
- [5] Brasil. 2023. Decreto nº 11.484, de 6 de abril de 2023: Dispõe sobre as diretrizes para a evolução do Sistema Brasileiro de Televisão Digital Terrestre (TV 3.0). Diário Oficial da União. [https://www.planalto.gov.br/ccivil\\_03/\\_ato2023-2026/2023/decreto/D11484.htm](https://www.planalto.gov.br/ccivil_03/_ato2023-2026/2023/decreto/D11484.htm)
- [6] Sylvia Chan-Olmsted, Lisa-Charlotte Wolter, and Elisa Dorothee Adam. 2020. Towards a Video consumer leaning spectrum: A medium-centric approach. *Nordic Journal of Media Management* 1, 2 (2020), 129–185.
- [7] Jiabao Fang, Shen Gao, Pengjie Ren, Xiuying Chen, Suzan Verberne, and Zhaochun Ren. 2024. A Multi-Agent Conversational Recommender System. *arXiv preprint* (2024). <https://doi.org/10.48550/arXiv.2402.01135> arXiv:2402.01135 [cs.IR]
- [8] S. Geng, S. Liu, Z. Fu, C. Zhang, F. Li, et al. 2022. Recommendation as Language Processing: A Unified Pretrain, Personalized Prompt & Predict (P5) Paradigm. *arXiv preprint arXiv:2203.13366* (2022). <https://arxiv.org/abs/2203.13366>
- [9] Carlos A Gomez-Urbe and Neil Hunt. 2015. The netflix recommender system: Algorithms, business value, and innovation. *ACM Transactions on Management Information Systems (TMIS)* 6, 4 (2015), 1–19.
- [10] Xu Huang, Jianxun Lian, Yuxuan Lei, Jing Yao, Defu Lian, and Xing Xie. 2023. Recommender AI Agent: Integrating Large Language Models for Interactive Recommendations. *arXiv preprint* (2023). <https://doi.org/10.48550/arXiv.2308.16505> arXiv:2308.16505 [cs.IR]
- [11] Ministério das Comunicações. 2025. *Televisão 3.0*. <https://www.gov.br/mcom/pt-br/assuntos/radio-e-tv-aberta/tv-30> Página institucional.
- [12] Marcelo Moreno, Carlos Pernisa Júnior, Eduardo Barrere, Li-Chang Shuen, Carlos de Salles Soares Neto, Débora Christina Muchaluat Saade, Joel AF dos Santos, Sérgio Colcher, Daniel Moares, Derzu Omaia, et al. 2023. R&D progress on TV 3.0 application coding layer. *SET INTERNATIONAL JOURNAL OF BROADCAST ENGINEERING* 9 (2023).
- [13] Li-Chang Shuen, Paulo Borges, Iago Costa, Ingrid Carvalho, Carlos Soares Neto, and Marcelo Moreno. 2023. App-based TV 3.0 experience: Proposing a new viewer's journey. In *Anais Estendidos do XXIX Simpósio Brasileiro de Sistemas Multimídia e Web* (Ribeirão Preto/SP). SBC, Porto Alegre, RS, Brasil, 131–135. [https://doi.org/10.5753/webmedia\\_estendido.2023.236173](https://doi.org/10.5753/webmedia_estendido.2023.236173)
- [14] Eli Stein, Kelsey Robinson, Alexis Wolfer, Gaelyn Almeida, and Wilow Huang. 2025. *Unlocking the next frontier of personalized marketing*. <https://www.mckinsey.com/capabilities/growth-marketing-and-sales/our-insights/unlocking-the-next-frontier-of-personalized-marketing>
- [15] Weiwei Sun, Lingyong Yan, Xinyu Ma, Shuaiqiang Wang, Pengjie Ren, Zhumin Chen, Dawei Yin, and Zhaochun Ren. 2023. Is ChatGPT Good at Search? Investigating Large Language Models as Re-Ranking Agents. In *Proceedings of EMNLP 2023*. <https://aclanthology.org/2023.emnlp-main.923.pdf>
- [16] Zhefan Wang, Yuanqing Yu, Wendi Zheng, Weizhi Ma, and Min Zhang. 2024. MACRec: a Multi-Agent Collaboration Framework for Recommendation. In *Proceedings of the 47th International ACM SIGIR Conference on Research and Development in Information Retrieval*. 2760–2764. <https://doi.org/10.1145/3626772.3657669> Also available as arXiv:2402.15235.
- [17] Likang Wu, Zhi Zheng, Zhaopeng Qiu, Hao Wang, Hongchao Gu, Tingjia Shen, Chuan Qin, Chen Zhu, Hengshu Zhu, Qi Liu, Hui Xiong, and Enhong Chen. 2024. A Survey on Large Language Models for Recommendation. *arXiv preprint* (2024). <https://doi.org/10.48550/arXiv.2305.19860> arXiv:2305.19860 [cs.IR]